



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**FOTOAKUSTİK YÖNTEMİ İLE KATI CİSİMLERDE TAHRİBATSIZ
KUSUR TESPİTİ**

DOKTORA TEZİ

Zekeriya BALCI

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Doktora Programı

NİSAN 2024

T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

FOTOAKUSTİK YÖNTEMİ İLE KATI CİSİMLERDE TAHRİBATSIZ
KUSUR TESPİTİ

DOKTORA TEZİ

Zekeriya BALCI
(181261344002)

Mekatronik Mühendisliği Anabilim Dalı
Mekatronik Mühendisliği Doktora Programı

Tez Danışmanı: Prof. Dr. Ahmet MERT

NİSAN 2024

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 181261344002 numaralı Doktora Öğrencisi Zekeriya BALCI, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "FOTOAKUSTİK YÖNTEMİ İLE KATI CİSİMLERDE TAHRİBATSIZ KUSUR TESPİTİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Ahmet MERT**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Dr. Öğr. Üyesi A. Remzi ÖZCAN**
Bursa Teknik Üniversitesi

Dr. Öğr. Üyesi Mustafa ÖZDEN
Bursa Teknik Üniversitesi

Doç. Dr. Ömer KASIM
Kütahya Dumlupınar Üniversitesi

Dr. Öğr. Üyesi Ulvi BAŞPINAR
Marmara Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 19/04/2024



20.04.2016 tarihli Resmî Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin aboneliği olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, Bursa Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğünün 210D003 numaralı projesi ile desteklenmiştir.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Zekeriya BALCI

İmza



*Fedakarlıkları ve destekleri ile beni her süreçte yalnız bırakmayan
eşime, anneme ve aileme.*

ÖNSÖZ

Bu tezin tüm süreçlerinde her daim teşvik edici, bilgilendirici yönlendirmeleri ve değerli destekleri için tez danışmanın değerli hocam Prof. Dr. Ahmet MERT hocama teşekkürlerimi sunarım.

Doktora ve eğitim sürecim boyunca her türlü desteklerini esirgemeyen eşime, anneme ve aileme şükran ve sevgilerimi sunarım.

Nisan 2024

Zekeriya BALCI

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
SEMBOLLER	xii
ÇİZELGE LİSTESİ.....	xiv
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xvii
SUMMARY	xviii
1. GİRİŞ	1
2. FOTOAKUSTİK.....	4
2.1 Fotoakustik Etkinin Tarihçesi	4
2.2 Fotoakustik Teori	5
2.3 Fotoakustik Dalga Oluşumu	6
3. MATERYAL VE YÖNTEM.....	9
3.1 Çalışma Düzenegi	9
3.1.1 Analiz ve kontrol birimi	9
3.1.2 Osiloskop ve veri toplama birimi	10
3.1.3 Donanım tutucu ve sabitleyiciler	11
3.1.4 Lazer ve güç sağlayıcı.....	11
3.1.5 Akustik algılayıcı	11
3.1.6 Lazer sürücü	12
3.2 Malzeme ve Veri Setin Hazırlanması.....	13
3.2.1 Veri toplama ve malzeme örnekleri	13
3.2.2 Veri artırımı.....	15
3.3 Görgül Kip Ayrışımı	17
3.4 Hilbert-Huang Dönüşümü	22
3.5 Özellik Çıkarımı	23
3.6 Yapay Öğrenme.....	27
3.6.1 Veri ve veri seti	28
3.6.2 Yapay öğrenme türleri	30
3.6.2.1 Denetimsiz öğrenme.....	30
3.6.2.2 Denetimli öğrenme.....	31
3.6.2.3 Pekiştirmeli öğrenme	31
3.6.3 Destek vektör makineleri	32
3.6.3.1 Doğrusal destek vektör makineleri.....	33
3.6.3.2 Doğrusal olmayan destek vektör makineleri.....	34
3.6.4 k -en yakın komşu	36
3.6.5 Karar ağacı	41
3.6.6 Çapraz doğrulama	45
3.6.6.1 Birini dışarıda bırak çapraz doğrulama	46

3.6.7 ReliefF özellik seçim algoritması	48
4. FA SİSTEM ÇALIŞMALARI VE SONUÇLARI.....	51
4.1 EPC9126 Lazer Sürücü Kartı	51
4.2 EPC9126 ile FA Sinyalin Elde Edilmesi.....	56
4.3 Kapasitif Deşarj Topolojisine Dayalı Lazer Sürücü Kart Tasarım	58
4.4 Tasarlanan Lazer Sürücü ile FA Sinyalin Elde Edilmesi.....	59
4.5 Lazer Optik Gücü ile Fotoakustik Sinyal İlişkisi	61
4.6 Tasarlanan ve Tezde Kullanılan Çalışma Düzenegi.....	63
4.6.1 FA Sinyal Üzerindeki Anahtarlama Etkisinin Azaltılması.....	65
5. MALZEME FA VERİLERİNİN GKA ANALİZİ VE SINIFLANDIRMA ...	67
5.1 Malzemelerden Elde Edilen FA Veri Seti	67
5.2 GKA'nın FA Sinyal Üzerindeki Taban Kaymasına Etkisi	68
5.3 Orijinal Sinyali Temsil Eden ÖKF'lerin Araştırılması	69
5.4 FA Sinyalin Zaman-Frekans Bileşenleri	70
5.5 Özelliklerin Çıkarımı ve Özelliklerin Ağırlık Analizi	71
5.6 Sınıflandırma Sonuçları.....	75
6. SONUÇ VE ÖNERİLER.....	77
KAYNAKLAR	79
EKLER.....	86
ÖZGEÇMİŞ.....	89

KISALTMALAR

AD2	: Analog Discovery 2
AID	: Automatic Interaction Detector
ASS	: Aktif Sinyal Süresi
BDBÇD	: Birini Dışarıda Bırak Çapraz Doğrulama
ÇD	: Çapraz Doğrulama
DA	: Doğru Akım
DT	: Decision Tree
DVM	: Destek Vektör Makinesi
E	: Entropi
EMD	: Empirical Mode Decomposition
FA	: Fotoakustik
FAE	: Fotoakustik Etki
FF	: Form Faktör
GKA	: Görgül Kip Analizi
HA	: Hjort Activity
HC	: Hjort Complexity
HD	: Hilbert Dönüşümü
HHD	: Hilbert-Huang Dönüşümü
HM	: Hjort Mobility
Hz	: Hertz
KA	: Karar Ağaçları
kHz	: kiloHertz
k-KÇD	: k Katmanlı Çapraz Doğrulama
k-NN	: k En Yakın Komşuluk
k-NN	: k-Nearest Neighbor
LOO	: Leave-one-out
m	: Eğim
MEMS	: Mikro Elektro-Mekanik Sistem
ML	: Machine learning (ML)
mm	: milimetre (ışık dalga boyu)

MÖ	: Makine Öğrenmesi
NDT	: Non-destructive Testing
nm	: Nanometre (ışık dalga boyu)
OA	: Optoakustik
OG	: Ortalama Genlik
ÖKF	: Özgül Kip Fonksiyonu
PA	: Photoacoustic
SD	: Standart Sapma
SS	: Standart Sapma
SVM	: Support Vector Machine
TG	: Tepe Genlik
TM	: Tahribatsız Muayene
TTG	: Tepeden Tepeye Genlik
TTL	: Transistör-Transistör-Lojik
YK	: En Yakın Komşu
YÖ	: Yapay Öğrenme

SEMBOLLER

$\Phi_i(t)$: Özgül kip fonksiyonu anlık faz
$a_i(t)$: Özgül kip fonksiyonu anlık genlik
$f_i(t)$: Özgül kip fonksiyonu anlık frekans
p_0	: Bölgesel basınç değişimi
\bar{x}	: Örneklerin ortalaması
α_j	: Lagrange çarpanları
τ_s	: Gerilme gevşeme süresi
τ_{th}	: Termal gevşeme süresi
$\varphi_{A_i}(t)$: Özgül kip fonksiyon analitik format
$d(a,b)$: Öklid uzaklığı
$e_{max}(n)$: Üst zarf
$e_{min}(n)$: Alt zarf
EnRat	: Artık ile sinyal enerji oranı
EnRes	: Özgül kip fonksiyonu ile sinyal enerji oranı
H_j	: İsabetler
k	: k yakın komşu
K	: Örnek sayısı
$M(i)$: Yerel maksimum noktaları
$m(j)$: Yerel minimum noktaları
$m(n)$: Zarfların ortalaması
$M_j(C)$: Hata katkıları
nm	: Nano metre (ışık dalga boyu)
$P(C)$: Sınıfın bir önceki olasılığı
$r(n)$: Kalıntı
R_i	: Rastgele örnek
$W[A]$: Öznitelik ağırlıkları
σ	: Standart sapma
σ^2	: Varyans
$\varphi(t)$: Eleme işlem aracı

- $\varphi_{\mathbf{k}}(\mathbf{n})$: Özgül kip fonksiyonu
 $\mathbf{H}\{\varphi_{\mathbf{i}}(\mathbf{t})\}$: Özgül kip fonksiyonu Hilbert dönüşümü
 $\mathbf{K}(\mathbf{x}_j, \mathbf{x}_k)$: Çekirdek fonksiyonu
 Γ : Grueneisen parametresi



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Malzemelere ait örnek sayıları.....	15
Çizelge 3.2: Veri artırımı sonucu oluşturulan toplam örnek veri sayısı.	17
Çizelge 3.3 : Örnek veri seti.....	29
Çizelge 3.4: Normalize edilen örnekler.	30
Çizelge 3.5 : DVM çekirdek fonksiyonlarından bazıları.	36
Çizelge 3.6 : k -NN için sentetik veri kümesi ve sınıfları.	39
Çizelge 3.7 : Y bilinmeyen örnek ile eğitim seti arasındaki Öklid uzaklıkları.	40
Çizelge 3.8: k komşuluk değerine göre Y 'nin en yakın komşuları.	41
Çizelge 3.9 : KA için geliştirilen algoritmalar.	44
Çizelge 4.1: Lazer sürücüsü darbe genişlik kombinasyonları.....	54
Çizelge 4.2: Deneme çalışmalarında kullanılan lazerler.....	61
Çizelge 5.1: Ham sinyal ve ÖKF'ler arası korelasyon katsayısı değerleri.	70
Çizelge 5.2: Öznitelikler.	72
Çizelge 5.3: Sınıflandırıcıların doğruluk değerleri.	75

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Fotofon cihazının tasarım şeması [28].	5
Şekil 2.2: FA etki ve sinyal formasyonu süreçleri.	6
Şekil 3.1: Çalışma düzeneği (1- PC, 2- Osiloskop, 3- Gripper, 4- Mikrofon, 5- Lazer sürücü, 6- Güç kaynağı, 7- Lazer, 8- Lazer ve malzeme sabitleme tablası, 9-Örnek materyal).	9
Şekil 3.2: WaveForms arayüzünün görseli.	10
Şekil 3.3: Lazer sürücü devresinin basitleştirilmiş şeması.	12
Şekil 3.4: Tasarlanan lazer sürücü devresinin şematik çıktısı.	13
Şekil 3.5: Lazer sürücüsü kartının üç boyutlu görseli.	13
Şekil 3.6: Veri toplama sistemi akış şeması.	14
Şekil 3.7: Malzemelerin kusurlu ve sağlam görselleri.	15
Şekil 3.8: Orijinal veri ve veri artırımı ile elde edilen veri grafikleri.	16
Şekil 3.9: GKA'nın eleme sürecinin grafiksel gösterimi.	19
Şekil 3.10: Enerji çözünürlüğüne dayalı GKA akış şeması.	21
Şekil 3.11: FA sinyal ve EMD algoritması sonucu elde edilen ÖKF ve artık bileşenleri.	22
Şekil 3.12: FA sinyalin Hilbert-Huang anlık genlik izgesi.	24
Şekil 3.13: FA sinyalin Hilbert-Huang anlık frekans izgesi.	24
Şekil 3.14 : Yapay öğrenme süreci.	28
Şekil 3.15 : Yapay öğrenme türleri.	31
Şekil 3.16: Örnekleri sınıflandırabilecek olası doğrular (a) ve örnekleri en iyi sınıflandırabilecek doğru (b) için temel DVM yapısı.	33
Şekil 3.17: Doğrusal DVM'nin sınıflandırma uygulanmasının grafiksel temsili.	34
Şekil 3.18: Çekirdek fonksiyonu yardımı ile örneklerin daha yüksek boyuta dönüştürülmesi.	35
Şekil 3.19 : Örneklere ait öznelik vektörlerinin dağılımı.	37
Şekil 3.20: k -NN örneği için verilen özneliklerin dağılım grafiği.	40
Şekil 3.21: Basitleştirilmiş karar ağacı yapısı şeması.	42
Şekil 3.22: İş teklifi için oluşturulan basit bir KA yapısı örneği.	45
Şekil 3.23: k -KÇD yönteminin adımlarının blok gösterimi.	47
Şekil 3.24: Dört örnekten oluşan bir modelin birini dışarda bırak çapraz doğrulama blok şeması.	47
Şekil 3.25: ReliefF algoritmasının sözde kodu.	49
Şekil 4.1. EPC9126 kartı ile kurulan çalışma düzeneği.	51
Şekil 4.2. Çalışma düzeneği bileşenlerinin birbiriyle olan bağlantı ilişkileri.	52
Şekil 4.3: Basitleştirilmiş kapasitif deşarj lazer sürücü şematigi (sol) ve zaman genlik grafiği (sağ)[92].	52
Şekil 4.4: EPC9125 lazer akımı ve mosfet gate gerilim eğrileri.	55
Şekil 4.5: Mikrofon ve lazer diyot yerleşim görseli.	56

Şekil 4.6: Kaynak [94]'ten alınan farklı lazer akımı darbe genişlikleri neticesinde elde edilen akustik görseller.	57
Şekil 4.7: Tasarlanan sürücünün üretilmiş görseli.	58
Şekil 4.8: Tasarlanan lazer sürücü gate ve akım sinyal grafikleri.	59
Şekil 4.9: Tasarlanan sürücü gate sinyali(mavi) ve MEMS mikrofon sinyali (turuncu) grafikleri.	60
Şekil 4.10: Deneme için kullanılan malzemeler demir, izole bant, sünger ve bakır plak et (soldan sağa).	60
Şekil 4.11: Lazer diyotun 437mA akımla sürüldüğünde oluşan mikrofon sinyali. ..	62
Şekil 4.12: Lazer diyotun 758mA akımla sürüldüğünde oluşan mikrofon sinyali. ..	62
Şekil 4.13: Çalışma düzeneği (1- Osiloskop, 2- Lazer sürücü, 3- Lazer, 4- Lazer ve malzeme sabitleme tablası, 5- Gripper, 6- Mikrofon, 7- 125x7,67mm içi boş silindir).	64
Şekil 4.14: Çalışma düzeneğindeki lazerden geçen akım grafiği.	64
Şekil 4.15: Tez malzemelerinden elde edilen ham FA sinyal grafikleri.	65
Şekil 4.16: Mikrofon ile doğrudan alınan sinyal grafiği.	66
Şekil 4.17: Mikrofonu içi boş silindir monte edilerek alınan sinyal grafiği.	66
Şekil 5.1: Önerilen yöntemin blok şeması.	67
Şekil 5.2: Malzemelerin kırılmış FA sinyal grafikleri.	68
Şekil 5.3: GKA'nın FA sinyal üzerindeki taban kaymasına etkisi.	69
Şekil 5.4: Malzemelerin anlık frekans grafikleri.	70
Şekil 5.5: Malzemelerin anlık genlik grafikleri.	71
Şekil 5.6: Alüminyum örneklerinden elde edilen özelliklerin dağılım grafiği.	72
Şekil 5.7: Demir örneklerinden elde edilen özelliklerin dağılım grafiği.	73
Şekil 5.8: Plastik örneklerinden elde edilen özelliklerin dağılım grafiği.	73
Şekil 5.9: Tahta örneklerinden elde edilen özelliklerin dağılım grafiği.	74
Şekil 5.10: Malzemelere ait özellik ağırlıkları.	74

FOTOAKUSTİK YÖNTEMİ İLE KATI CİSİMLERDE TAHRİBATSIZ KUSUR TESPİTİ

ÖZET

Fotoakustik (FA) yöntemi, ışık enerjisinin malzeme üzerinde ısı enerjisiye dönüşmesiyle oluşan akustik dalgaları analiz etme esaslı bir tekniktir. Tahribatsız muayene (TM) için kullanılması, malzemeye zarar vermeden kusurların tespit edilmesini sağlaması ve çeşitli malzemelerde kullanılabilmesi gibi avantajlara sahiptir. Bu yöntemde, lazer ışığı malzemeye gönderilir ve malzeme tarafından emilen ışık, termal enerjiye dönüşür. Termal enerjinin neden olduğu termal genleşme, ses dalgalarının oluşmasına yol açar. Bu ses dalgaları, akustik algılayıcılar tarafından algılanır ve analiz edilir. FA sinyaller, sağlam ve kusurlu malzemelerde farklı özellikler gösterir. Bu özellikler, sinyal genliği, frekans, periyot ve zaman-frekans özellikleri gibi parametrelerle tanımlanabilir. Bu parametreler, makine öğrenmesi (MÖ) yöntemleri aracılığıyla sınıflandırılarak kusurların tespit edilmesi mümkündür.

FA sunduğu avantajlardan dolayı son yıllarda malzeme kusur tespitinde popüleritesi giderek artan bir yöntem olmuştur. Bu çalışmada, lazer, mikrofon ve veri toplama kartı ile tasarlanan düzenek ile alüminyum, demir, plastik ve tahta malzemelerinden elde edilen FA sinyallere Görgül Kip Analizi (GKA) tabanlı, zaman ve zaman-frekans düzleminde öznelik çıkarma yöntemine dayanan, malzemelerde kusur tespiti için bir çerçeve çalışma önerilmiştir. Her malzeme gurubu içerisinde 120 adet sağlam, 120 adet kusurlu toplam 240 örnek ve toplamda 960 örnek kullanılmıştır. Bu örneklerden elde edilen 14 adet öznelik ile k -en yakın komşu (k -NN), karar ağacı (KA) ve destek vektör makineleri (DVM) sınıflandırıcıları kullanılarak kusurlu ve sağlam malzemeler tespit edilmiştir. Malzemeler hem aynı sınıf içinde hem de tüm malzeme gruplarının dahil olduğu doğrulama teknikleri ile test edilmiştir. Birini dışarıda bırak çapraz doğrulama yöntemi ile sınıf içi ve tüm malzemeler için kusurlu ve sağlam tespit oranı sırasıyla DVM’de % 100 ve k -NN’de %97.77 olarak elde edilmiştir.

Bu çalışmada önerilen yöntem, FA yönteminin farklı malzemelerdeki yüzey kusurları için etkinliğini artırmaya yönelik önemli bir katkı sağlamaktadır. GKA ile FA sinyaldeki gürültüler süzölmüş, taban kaymasının etkisi azaltılmış ve aynı zamanda özellik çıkarımı için faydalı sinyal elde edilmiştir. Bu şekilde önerilen metodoloji ile FA sinyallerindeki taban kayması elimine edilerek sinyal işleme sürecinin iyileştirdiği gösterilmiştir. Bu sayede, FA sinyal ve GKA yöntemi ile farklı malzemelerdeki kusur tespitinin başarı oranı önemli ölçüde artırılmıştır. Literatürde bir malzeme özelinde yapılan çalışmaların aksine, önerilen yöntem ile farklı kusurların bulunduğu ve farklı malzemeler için ortak bir sınıflandırma çerçevesi geliştirilmiştir.

Anahtar kelimeler: Fotoakustik, Görgül kip ayrışımı, Destek vektör makinesi, K -en yakın komşuluk, Karar ağaçları, Kusur tespiti.

NON-DESTRUCTIVE DEFECT DETECTION IN SOLID OBJECTS USING THE PHOTOACOUSTIC METHOD

SUMMARY

Photoacoustic (PA) is a technique that utilizes acoustic waves generated by the conversion of light energy into thermal energy to detect material defects. The PA method is advantageous since it allows for non-destructive testing (NDT), thereby enabling defect detection without causing any damage to the material, and it can be applied to a wide variety of materials. In this method, laser light is sent into the material and the light absorbed by the material is converted into thermal energy. The thermal energy results in thermal expansion, which in turn results in the generation of sound waves. The sound waves are then detected by the acoustic sensors for analysis. PA signals show different characteristics from intact and defective materials. These characteristics can be described by parameters such as signal amplitude, frequency, duration and time-frequency characteristics. Machine learning (ML) methods are used for classification of these parameters to detect defects.

Photoacoustic has become an increasingly popular method for material defect detection in recent years due to its advantages. In this study, we propose a framework for material defect detection based on Empirical Mode Decomposition (EMD) based feature extraction in time and time-frequency domain for PA signals obtained from aluminum, iron, plastic and wood materials using a laser, microphone and data acquisition board. Within each material group, a total of 240 samples (120 intact samples and 120 defective samples) and a total of 960 samples were used. With 14 features extracted from these samples, k -nearest neighbor (k -NN), decision tree (DT) and support vector machine (SVM) classifiers were used to classify defective and intact materials. Materials were classified both within the same class and within the class including all material groups. With the leave-one-out cross-validation method, the defective and intact detection rates for all materials and within the class were 100% for SVM and 97.77% for k -NN, respectively.

The method proposed in this study makes a significant contribution to improve the effectiveness of the PA method for surface defects in different materials. With EMD, the noise in the PA signal is filtered out, the effect of the baseline drift is reduced and at the same time a useful signal is obtained for feature extraction. The proposed method effectively improves the signal processing by eliminating the baseline drift in the PA signals while performing two different tasks at the same time. In this way, the accuracy rate of defect detection in different materials is significantly improved. In contrast to the material-specific studies in the literature, with the proposed method, a common classification framework was developed for different materials with different defects.

Keywords: Photoacoustic, Empirical mode decomposition, K-NN, Decision tree, Support vector machine, Defect detection.

1. GİRİŞ

Son yıllarda giderek ilgi çeken Fotoakustik (FA) veya Optoakustik (OA), gelişmekte olan teknoloji tabanlı görüntüleme ve tahribatsız muayene yöntemidir [1]. FA etkiye dayanan bu teknik Alexander Graham Bell tarafından 1880 yılında keşfedilmiştir [2]. Sistemin temel bileşenleri, lazer kaynağı, hedef nesne ve akustik algılayıcıdır. Lazer kaynağı, genellikle kısa darbeler halinde yollanan lazer ışığı üretir. Bu ışık, hedef nesne tarafından emildiğinde, termal enerjiye dönüşür ve enerji emiliminden ortaya çıkan termal genişleme ile ses dalgalarının oluşumuna yol açar. Akustik algılayıcı, bu ses dalgalarını algılayarak ilgili bilgileri toplar ve bu bilgiler daha sonra analiz için işlenir [3–5].

FA biyomedikal alanında, 266nm lazer ve mikrofon ile insan nefesinden temel bileşen analizi ile astım teşhisi [6], 1535 nm lazer ve odaklı ultrasonik transdüserle FA sinyaldeki doğrusallık özelliğinden yararlanarak glikoz ölçümü [7], geniş dalga boyundaki lazerle FA sinyalin spektral özellikleri ve makine öğrenmesiyle moleküler meme kanseri tanıma [8] ve FA veriden dalgacık dönüşümü ile elde edilen özellikler ve Resnet-18 ağı kullanılarak prostat kanseri teşhisi [9], kandaki oksijen, kandaki glukoz, lipid ve tümör takibi ile insan sağlığı görüntüleme [10], farklı diş örneklerinden alınan FA sinyale dayalı yeniden oluşturulan görüntüden yoğunluk analizi ile diş çürüğü tespiti [11] ve bir çok çalışmada yer bulmuştur [12,13]. FA yöntem metan [14], ozon [15] ve SO_2F_2 [16] gazı ve bir çok çevresel gaz izlemede ve endüstriyel uygulamada giderek artan bir araştırma yöntemi olmuştur [17–19].

Son yıllarda FA yöntem tahribatsız muayenede [20], malzeme kusur tespiti ve analizinde popüleritesi giderek artan bir yöntem olmuştur [1]. Kaynak [21–23]'de araştırmacılar metallerdeki yüzey kusurlarını FA yöntem ile görüntülemek ve çatlak tespiti için çalışmalar yapmışlardır. Kaynak [21]'de lazer kaynaklı FA görüntülemeye ek piezoelektrik transdüserle metal plakaya farklı frekanslarda yükleme yaparak, doğrusal olmayan çatlak görüntüleme üzerine çalışmışlardır. Doğrusal olmayan sistem etkileri sonucu oluşan karışık frekanstaki akustik sinyal, bir ivme ölçer tarafından algılanmıştır ve çatlakların doğrusal ve doğrusal olmayan fotoakustik görüntülenmesine katkı sağlayan çeşitli fiziksel mekanizmalar incelenmiştir. Kaynak

[22]'de arařtırmacılar, lazer ve mikrofondan oluřan deneysel sistemleri ile elde edilen FA sinyale yazılım tabanlı fourier dnřm uygulamıřlardır. Sinyal genliđini lme yoluyla mikro atlakları tespit etmeye alıřmıřlardır. Sistemin, yzeyinde mikro atlakları olan bir nesnenin FA bir grntsn retebilecek yetenekte olduđunu belirmiřlerdir. Kaynak [23]'te ise metal plakadan elde edilen FA sinyaller kullanılarak oluřturulan grnt zerinde kenar belirleme ve siyah/beyaz resimde uzunluk lm ile grnt iřleme tabanlı metal plakada atlak tespiti yapılmıřtır. Kaynak [24]'de kaynak kusurları FA yntem ile arařtırılmıřtır. Wang ve diđerleri [25]'te kompozit malzemeler iin FA yntem ile tahribatsız muayene yntemi nermiřlerdir. Piko saniye darbeleri lazer, ultrasonik algılayıcı, veri iřleme ve hesaplama alt sistemlerinden oluřan FA grntleme sisteminin, CFRP kompozitlerin hasar tespiti iin son derece yksek znrlkl yeni bir temaslı olmayan yaklařım sađlayabildiđini rapor etmiřlerdir.

Kaynak [5, 26, 27]'de arařtırmacılar FA ile tren raylarındaki yzey kusurlarının tespiti ve grntlenmesi zerine alıřmalar gerekleřtirmiřlerdir. Kaynak [5]'de ultrasonik algılayıcı, 532nm ve 160mJ gcndeki lazer den oluřan sistem ile tren raylarından elde ettikleri FA sinyalleri kullanarak gerek zamanlı grntleme sistemi nermiřlerdir. FA sinyal kullanılarak yeniden oluřturulan grntye gre, ray kusurunun grnm, uzanma eđilimi ve derinliđi gibi hasar bilgileri etkili bir Őekilde tanımlanabileceđini rapor etmiřlerdir. Kaynak [26]'da arařtırmacılar 20W 445nm lazer ve dar bant piezoelektrik kontak probu ile oluřturdukları alıřma dzenekleri ile FA sinyal parametrelerinin optimizasyonu zerine alıřmıřlardır. Lazer darbe sayısının, lazer darbe sresinin ve darbeler arası srenin sinyal kalitesi zerinde etkisinin olduđunu rapor etmiřlerdir. Ayrıca bu alıřmada kusurlu blgenin belli uzađında da sinyal karakteristiđinin korunduđu rapor edilmiřtir. Yan ve diđerleri kaynak [27]'deki arařtırmada 850 nm lazer ve piezo transdser ile tren rayındaki kusurların grntlenmesi zerine alıřmıřlardır. Ayrıca modlasyon frekansının, FA grnt rekonstrksiyonu kalitesi zerinde etkisinin olduđunu rapor etmiřlerdir.

Bu alıřmaya zg 450 nm dalga boyuna sahip lazer ve mikro-elektromekanik mikrofon, veri toplama kartı ile sinyal iřleme algoritması tasarlanmıřtır. Alminyum, demir, plastik ve tahta malzemeleri zerinde tasarlanan dzenek denenerek elde edilen FA sinyalleri, geliřmiř sinyal iřleme teknikleri ile incelenerek oluřan sađlam ve kusurlu sinyallerdeki ayırt edici zellikler belirlenmeye alıřılmıřtır. GKA yntemi

uygulanması ile elde edilen Özgül Kip Fonksiyonu (ÖKF) kullanılarak, zaman ve zaman-frekans düzlemindeki özelliklerin çıkarılması ve bu özelliklerle eğitilen sınıflandırıcılarla tahribatsız kusur tespiti gerçekleştirilmesi amaçlanmıştır. Yukarıda verilen literatürde FA ile kusur tespiti çalışmalarında genel olarak bir malzeme özelinde ve görüntüleme üzerine çalışmaların yoğunlaştığı görülmüştür. Bu çalışmadaki amaç GKA ile FA sinyaldeki taban kaymasının elimine edilmesi ve FA sinyal işleme ile farklı malzemeler için ortak bir kusur tespiti çerçevesinin oluşturulmasıdır. Çalışmada ilk önce dört malzemedен elde edilen ham FA sinyallere GKA uygulanmıştır. Daha sonra birinci ÖKF'ler üzerinden zaman ve zaman-frekans düzleminde 14 adet özellik çıkarılmıştır. Son olarak çıkarılan özellikler ile DVM, KA ve k -NN sınıflandırıcıları eğitilerek önerilen yöntemin başarımı incelenmiştir.


2. FOTOAKUSTİK

Bir ışık kaynağı ile katı, sıvı ve gaz ortamların uyarılması sonucu üretilen mekanik gerilmelerin algılanması prensibine dayanmaktadır. Bu disiplinde, yüksek frekanslı modüle edilmiş lazer ışımalarını kullanarak ortamın lazer ışınlarına maruz bırakılmasıyla, hızlı termal genişleme yoluyla yüksek frekanslı akustik dalgalar üretilir. Anlatılan bu metodolojiye dayanan FA bu yönüyle malzeme veya ortam hakkında temassız bir araştırma, bilgi edinme ve inceleme yapmanın bir yaklaşımı olmuştur. Ayrıca malzeme yapısı özelliklerinin elde edilmesi ve malzemelerdeki kusurların tahribatsız tespit edilmesi içinde uygun bir yöntemdir.

2.1 Fotoakustik Etkinin Tarihçesi

Modüle edilmiş lazer darbeleri ile uyarılan maddenin, lazer ışınlarını soğurması ile termal genişleme sonucu oluşan akustik basınç dalgalarının üretilmesi fotoakustik etki (FAE) olarak bilinmektedir. FAE, ilk kez 1880 yılında Alexander Graham Bell ve Charles Sumner Tainter tarafından Fotofon olarak bilinen bir cihaz aracılığıyla güneş ışınlarını kullanarak işitilebilir sesin taşındığı bir keşif olarak ortaya çıkmıştır [2]. Bu keşif, tarihte gerçekleştirilmiş ilk optik modülasyon örneği olarak kabul edilir ve pratik olarak uygulanmış ilk optik ve kablosuz iletişim aracı olarak tanımlanmıştır.

Fotofon (şekil 2.1), güneş ışınlarını kullanarak sesin ışık aracılığıyla modüle edilerek taşınmasını sağlayan ses iletim cihazıdır. Fotofon, alıcı ve verici çiftinden oluşmaktadır. Verici, sesi güneş ışıkları ve bir ayna sistemi aracılığıyla modüle ederken, alıcı tarafı ise modüle edilmiş ışık girdisini kullanarak sesi geri elde eder. Alıcı tarafında selenyum hücresi kullanılan bu cihazda, üzerine düşen ışık yansınmasıyla elektriksel olarak direnci değişen selenyum ile modüle edilmiş ışık tekrar sese dönüştürülür. Bu cihaz elektriksel bir bağlantı olmadan sesin iletilmesi ile yapılan iletişimin ilk örneği olmuştur [2, 28].



Şekil 2.1: Fotofon cihazının tasarım şeması [28].


2.2 Fotoakustik Teori

Fotoakustik etkiyi, emici bir ortam veya malzemenin lazer darbeleri ile uyarılması sonucunda malzemede veya ortamda soğurulan enerji neticesinde termoelastik genişlemenin neden olduğu akustik dalgaların oluşması şeklinde tanımlayabiliriz. Fotoakustik, ışığın ve akustik dalgaların etkileşimi üzerine odaklanan bir araştırma alanıdır. Bu alanda yapılan çalışmalar, bilim adamlarına malzemelerin ve ortamların iç yapısını ve özelliklerini inceleme imkânı verir.

Genellikle bir madde ışığı emdiğinde, enerjinin gidebileceği birkaç yol bulunur. Işık her zaman korunur ve bunu ifade eden bağıntı aşağıda (2.1) numaralı bağıntıda verilmiştir.

$$1 = \alpha + T + R_{ref} \quad (2.1)$$

Verilen bağıntıda α emilim, T geçirim ve R_{ref} yansımaya olarak tanımlanmıştır. Bir madde üzerine uygulanan ışımaya ya emilir ya malzemenin içinden geçer veya malzeme yüzeyinden yansır. FA, ısının açığa çıktığı yer olan emilim sürecine odaklanan bir yaklaşımdır. Işık bir maddeye çarpmasıyla fotonların emilimiyle bir enerji oluşur ve bu enerji sonucunda elektronlar uyarılır. Bu enerji sonucu ısı açığa çıkar ve ısınma ile malzemede termal genişleme gerçekleşir, malzeme genişledikçe akustik ses dalgaları oluşur. Bu süreç şekil 2.2’de görsel olarak açıklanmaktadır.



Şekil 2.2: FA etki ve sinyal formasyonu süreçleri.

2.3 Fotoakustik Dalga Oluşumu

Lazer ışığının verilmesi gereken gerekli zaman ölçeği, enerji dağılımının zaman ölçeği ve lazer ışığına maruz kalan nesnenin fiziksel özellikleri, özellikle termal ve gerilme gevşeme zamanları ile belirlenir. Termal gevşeme süresi 2.2 numaralı bağıntı ile tanımlanır.

$$\tau_{th} = \frac{d_c^2}{\alpha_{th}} \quad (2.2)$$

Burada d_c ısıtılmış bölgenin karakteristik boyutunu, α_{th} termal difüzyon hızı (m^2/s) ifade etmektedir. Yumuşak dokular için termal difüzyon hızı yaklaşık $10^{-7} m^2/s$ civarındadır. Bu durumda 2 mm boyutundaki bir nesne için termal gevşeme süresi 20 saniye civarında olacaktır. Gerilme gevşeme süresinin hesabı ise aşağıda verilen (2.3) numaralı bağıntı ile gerçekleştirilir.

$$\tau_s = \frac{d_c}{v_s} \quad (2.3)$$

Burada v_s akustik hızı ifade etmektedir [29]. Maddede lazer enerjisinin sebep olduğu sıcaklık artışı için bağıntı aşağıdaki gibi yazılabilir.

$$T = \frac{n_{th}\mu_a F}{\rho C_V} \quad (2.4)$$

Verilen (2.4) numaralı bağıntıda n_{th} olarak ışığın ısıya çevrilme yüzdesini, μ_a optik emilim katsayısını (cm^{-1}), F optik akıyı, ρ yoğunluğu ve C_v ise sabit hacimdeki ısı özgül kapasitesini ifade etmektedir.

Termal ve stres sınırlama kriterlerinin karşılanması koşuluyla, bölgesel basınç değişimi aşağıdaki bağıntıda ifade edilmiştir.

$$p_0 = \frac{\beta T}{\kappa} \quad (2.5)$$

Beş numaralı bağıntıda verilen β , hacimsel termal genişleme katsayısını (K^{-1}) ve κ ise izotermal sıkıştırılabilirliği (Pa^{-1}) ifade etmektedir. Birimsiz olan Grueneisen parametresi basınç artışını optik ile bağlamaktadır ve (2.6) numaralı bağıntı ile tanımlanır.

$$\Gamma = \frac{\beta}{\kappa \rho C_v} = \frac{\beta v_s^2}{C_p} \quad (2.6)$$

Yukarıda verilen Grueneisen parametresindeki C_v (J/gK) sabit basınçtaki özgül ısı kapasitesini ifade etmektedir.

Eğer ışıktan ısıya dönüşümün kayıpsız olduğu varsayılırsa, bir materyal için yerel basınç artışını tanımlayan ifade aşağıdaki gibidir.

$$p_0 = \Gamma \mu_a F \quad (2.7)$$

FA etki sonucu oluşan basınç dalgalarının yayılımını tanımlamak için kullanılan genelleştirilmiş dalga denklemi (2.8) numaralı bağıntıda verilmiştir [30].

$$\left(\nabla^2 - \frac{1}{v_s^2} \frac{\partial^2}{\partial t^2} \right) p(r, t) = \frac{\beta}{\kappa v_s^2} \frac{\partial^2 T(r, t)}{\partial t^2} \quad (2.8)$$

Yukarıda verilen dalga denkleminde " $p(r, t)$ " akustik basıncı ifade eder ve r konumu, t ise zamanı ifade etmektedir. Denklemin sol tarafı akustik dalga yayılımını ifade etmektedir, sağ tarafı ise akustik dalga oluşumunun sebebi olan kaynağı ifade etmektedir. Isıl sınırlama koşulu altında, sıcaklıktaki değişim doğrudan enerji birikimine bağlıdır:

$$\rho C_v \frac{\partial T(r, t)}{\partial t} = H(r, t) \quad (2.8)$$

burada sıcaklık zamana bağılı bir değişken halini almıştır ve $H(r, t)$ ise t anında ve r konumundaki ısı artış operatörünü ifade etmektedir. Yukarıda verilen (2.8) numaralı bağıntı ısı sınırlama altındaki dalga oluşumunu tanımlamak için tekrar yazılırsa (2.9) numaralı bağıntıdaki halini alır.

$$\left(\nabla^2 - \frac{1}{v_s^2} \frac{\partial^2}{\partial t^2} \right) p(r, t) = -\frac{\beta}{C_p} \frac{\partial H(r, t)}{\partial t} \quad (2.9)$$

Denklemin sağındaki terim kaynak terimini ifade etmektedir ve $H(r, t)$ 'nin birinci dereceden zamana göre türevi ile ilişkili olduğundan, sabit bir ısıtma fonksiyonunun basınç dalgası üretemeyeceği görülmektedir.

Yukarıda verilen (2.9) numaralı bağıntının çözümü, homojen olmayan diferansiyel denklemlerin çözümünde de yaygın olarak kullanılan Green fonksiyonu yaklaşımı ile gerçekleştirilmektedir. Elde edilen çözümün bağıntısı aşağıda verilmiştir.


$$p(r, t) = \frac{1}{4\pi v_s^2} \frac{\partial}{\partial t} \left[\frac{1}{v_s t} \int dr' p_0(r) \delta \left(t - \frac{|r-r'|}{v_s} \right) \right] \quad (2.10)$$

Verilen denklem, delta ısıtma fonksiyonu nedeniyle oluşan basınç tepkisini hesaplamak için kullanılmaktadır. Denklemdaki r parametresi kaynağın konumunu ve t parametresi ise zamanını ifade eder. Delta ısıtma fonksiyonu nedeniyle oluşan ilk basınç cevabı ise p_0 ile ifade edilmiştir.

3. MATERYAL VE YÖNTEM

3.1 Çalışma Düzenegi

FA çalışma düzeneklerinde genel yapı bir ışık kaynağı, üzerinde çalışılacak örnek ve bir algılayıcı sistem ana bileşenleri çevresinde şekillenmektedir. Bu çalışmada tasarlanan çalışma düzeneginin üç boyutlu tasarımı şekil 3.1’de verilmiştir. Her bir bileşen şekil üzerinde numaralandırılmıştır. Sistem bileşenlerinin özellikleri aşağıda takip eden başlıklar altında açıklanmıştır.



Şekil 3.1: Çalışma düzenegi (1- PC, 2- Osiloskop, 3- Gripper, 4- Mikrofon, 5- Lazer sürücü, 6- Güç kaynağı, 7- Lazer, 8- Lazer ve malzeme sabitleme tablası, 9- Örnek materyal).

3.1.1 Analiz ve kontrol birimi

Çalışmada yazılım analiz ve sistem kontrollerinin tümü (şekil 3.1’de (1) numara olarak belirtilmiştir), aşağıda teknik özellikleri verilen bilgisayar ve Matlab R2022b yazılım ortamı kullanılarak gerçekleştirilmiştir.

Bilgisayar sistem özellikleri:


- Intel(R) Core(TM) i7-10750H CPU @ 2.60GH işlemci
- 8 GB Ram
- Nvidia Geforce GTX 1650 TI GPU
- 515 GB SSD sabit disk
- Windows 10 Pro işletim sistemi

3.1.2 Osiloskop ve veri toplama birimi

Mikrofondan akustik sinyallerin alınması ve lazer sürücü kartı için bilgisayardan gelen komut doğrultusunda tetikleme sinyallerinin üretilmesi süreçlerinin gerçekleştirildiği birimdir. Şekil 3.1’de (2) olarak işaretlenmiştir ve bu birimde aşağıda teknik özellikleri verilen Analog Discovery 2 (AD2) donanımı kullanılmıştır. AD2 teknik özellikleri:

- 2-kanal osiloskop (1M Ω , \pm 25V, differential, 14-bit, 100Mörnek/sn, 30MHz+ bant genişliği)
- 2-kanal sinyal üretici (\pm 5V, 14-bit, 100Mörnek/sn, 12MHz+ bant genişliği)
- 16-kanal lojik analizör (3.3V CMOS, 100Mörnek/sn)
- 16-kanal dijital patern üretici (3.3V CMOS, 100Mörnek/sn)
- 16-kanal sanal dijital I/O
- Harici hoparlör ve kulaklıklar için stereo audio amplifier
- Tek Kanal Voltmetre (AC, DC, \pm 25V)
- Spektrum Analizör
- Network Analizör
- Dijital Bus Analizör (SPI, I²C, UART, Paralel)
- Voltmetre
- Dijital I/O
- İki adet programlanabilir güç kaynağı (0...+5V, 0...-5V).

AD2 şekil 3.2’de görseli verilen WaveForms arayüzü üzerinden konfigüre ve kontrol edilmektedir.



Şekil 3.2: WaveForms arayüzünün görseli.

3.1.3 Donanım tutucu ve sabitleyiciler

Mikrofon ve lazerin tüm ölçümler için sabit kalması sistem performansı için önemli bir etken olduğundan, bu bileşenler çalışma boyunca sabitlenmiştir. Mikrofonu sabitlemek için şekil 3.1'de (3) numara ile belirtilen timsah ağızlı gripper kullanılmıştır. Ayrıca lazeri ve örnek malzemeleri sabitlemek için şekil 3.1'de (8) numarası ile belirtilen lazer sabitleme tablası tasarlanarak üretilmiştir.

3.1.4 Lazer ve güç sağlayıcı

Deneysel sistemin elektriksel güç gereksinimi için, şekil 3.1'de (6) numara ile işaretlenen ayarlanabilir laboratuvar tipi hassas güç kaynağı kullanılmıştır (AA TECH ADC-3303D).

Çalışma düzeneğinin ana bileşenlerinden lazer modülünün görseli şekil 3.1'de (7) numara ile işaretlenmiştir. Lazer modülünün teknik özellikleri aşağıda verilmiştir.

- Dalga boyu: 445 – 450 nm (mavi)
- Çıkış gücü: 15W (darbeli çalışmada)
- Modülasyon frekansı: PWM <9kHz
- Ayarlanabilir odak uzaklığı
- Çalışma sıcaklığı: 15° – 45° derece arası
- Odak nokta boyutu: $\leq 0.12\text{mm}$

3.1.5 Akustik algılayıcı


Bu tez çalışmasında FA etki sonucu oluşan akustik dalgaların algılanması için Mikro Elektro-Mekanik Sistem (MEMS) mikrofon kullanılmıştır. MEMS mikrofon (SparkFun Analog MEMS Mikrofon Breakout - ICS-40180) şekil 3.1'de (4) numara ile işaretlenmiştir ve teknik özellikleri aşağıda listelenmiştir.

- 65 dBA SNR
- -38 dBV hassasiyet
- 60 – 20 kHz aralığında çalışma frekansı
- Single-Ended analog çıkış
- 1.5 – 3.6V doğru akım besleme gerilimi
- 600 Ω çıkış empedansı


3.1.6 Lazer sürücü

Bu çalışmada yüksek akımlı, nano saniyelik darbeleri yüksek tekrarlama seviyelerinde sunmak için şekil 3.3'te basitleştirilmiş devre şeması verilen lazer diyot sürücüsü tasarlanmıştır. Şarj deşarj topolojisine dayanan bu sürücü, lazerli radar uygulamaları için geliştirilmiş sürücünün [31], tekrar düzenlenerek ve basitleştirilmiş yeni bir versiyonudur.

Aşağıda şekil 3.3'te verilen devrenin çalışma prensibi şu şekildedir: C kapasitörü, RL-C- RM yolu üzerinden yüksek gerilim doğru akım (DA) HV gerilimine şarj edilir. Harici bir Transistör-Transistör-Lojik (TTL) darbesi (şekilde PULSE olarak adlandırılmıştır), Q güç mosfetini tetikler ve mosfet iletme geçer. Güç mosfeti iletimdeyken, C kapasitesi LD lazer diyotu ve mosfet üzerinden deşarj olur. Bu devrede C kondansatörü ve Q mosfeti teknik belgelerindeki sınır şartlar içerisinde yüksek gerilimlerde çalıştırılabilir. Bu devrede RL akımı istenen değerde sınırlamaktadır. Bu tasarım topolojisi akım genliğinin yüksek gerilim genliğine bağlı olarak kontrol edilmesini sağlamaktadır. Burada deşarj akımının yükselme süresi Q mosfetinin açma süresine bağlıdır, fakat bu akımın boşalma süresi yalnızca RM-C-LD-Q yolunun zaman sabitine bağlıdır. Lazer üzerinden geçecek akımın darbe süresi, bu tasarım sayesinde C kapasitesinin değeri değiştirilerek ayarlanmasına imkân sağlamaktadır.




Şekil 3.3: Lazer sürücü devresinin basitleştirilmiş şeması.



Şekil 3.4: Tasarlanan lazer sürücü devresinin şematik çıktısı.

Bu tez çalışmasında tasarlanan lazer sürücü devresinin şematiği şekil 3.4’te verilmiştir. Lazer sürücüsünün tasarım süreçleri KiCAD ortamında gerçekleştirilmiştir. Ayrıca tasarlanan lazer sürücü kartının üç boyutlu görseli aşağıda şekil 3.5’te verilmiştir.

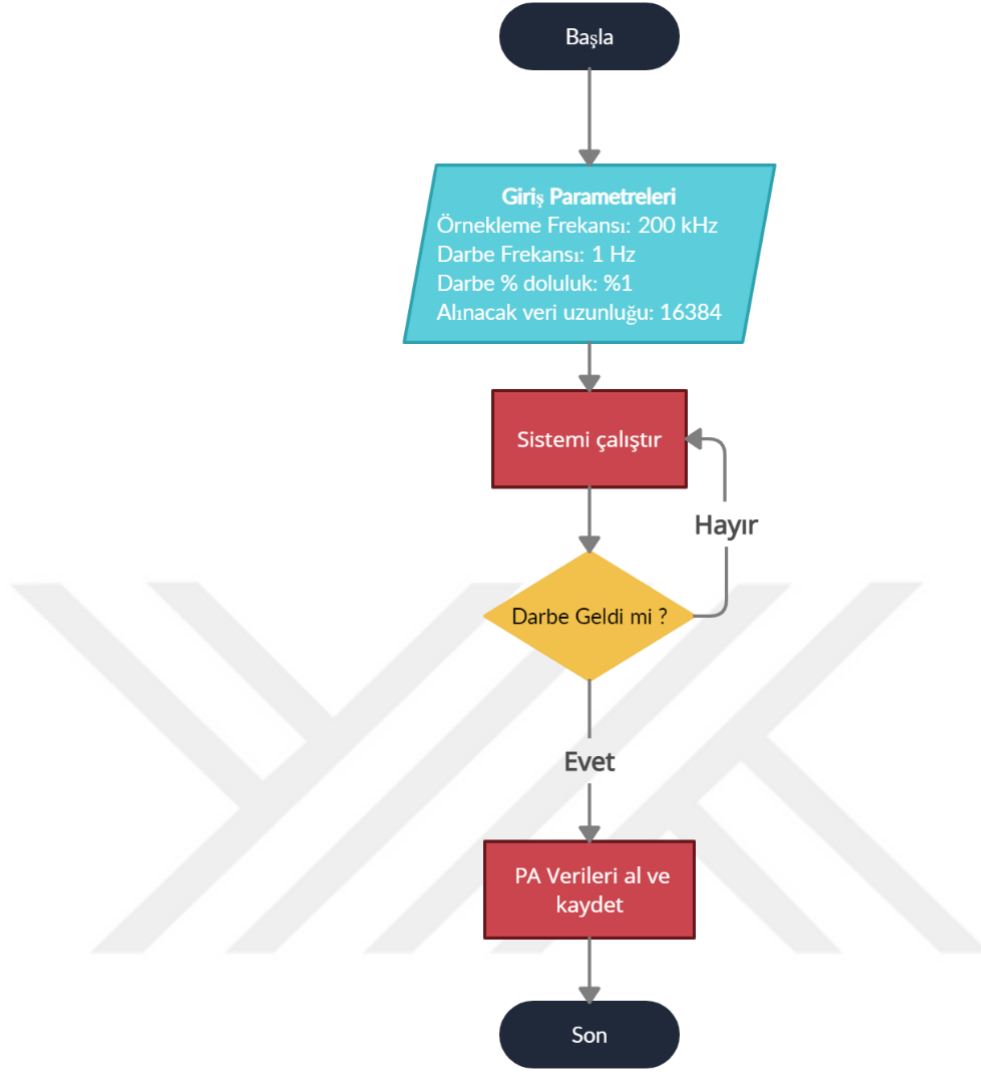


Şekil 3.5: Lazer sürücüsü kartının üç boyutlu görseli.

3.2 Malzeme ve Veri Setin Hazırlanması

3.2.1 Veri toplama ve malzeme örnekleri

Şekil 3.1’de görseli verilen deneysel sistem aracılığıyla, örneklerden veriler alınarak bilgisayar ortamında kaydedilmiştir. Veriler şekil 3.1’de (2) numara ile belirtilen ve özellikleri materyal bölümünde verilen AD2 donanımı ve yazılımı kullanılarak alınmıştır. Örneklem frekansı tüm veriler için 200kHz olarak ayarlanmıştır. Sistem süreçlerinin akış şeması aşağıda şekil 3.6’da verilmiştir.




Şekil 3.6: Veri toplama sistemi akış şeması.

Tezde kullanılacak verilerin elde edileceği malzemeler için demir, alüminyum, tahta ve plastik malzemeleri belirlenmiştir. Bu malzemelerin temin edilmesinin ardından malzeme gurupları oluşturulmuştur. Ayrıca malzeme guruplarının içerisinde sağlam ve kusurlu örnekleri barındıran alt guruplar oluşturulmuştur. Malzeme guruplarının örnek sayıları çizelge 3.1’de malzeme öreklerine ait görseller şekil 3.7’de verilmiştir. Şekil 3.7’deki malzemelerde delik ve kesik olmak üzere iki tip kusur olduğu gözükmetedir. Bu kusurlar yapay olarak yapılmıştır. Kesik kusuru için 22mmx0.8mm dairesel testere, delik kusuru için 2.30mm matkap ucu kullanılarak çeşitli derinliklerde kusurlar oluşturulmuştur.

Çizelge 3.1: Malzemelere ait örnek sayıları.

	Sağlam	Kusurlu	Toplam
Demir (ST-37)	30	30	60
Alüminyum (6063)	30	30	60
Tahta (Çam)	30	30	60
Plastik (PVC)	30	30	60
Toplam	120	120	240



Şekil 3.7: Malzemelerin kusurlu ve sağlam görselleri.


3.2.2 Veri artırımı

Sınıflandırıcı modellerinin performansını iyileştirmenin bir yolu, daha fazla veriye sahip olmaktır. Ancak, gerçek dünyadaki veri toplama süreçleri genellikle zaman alıcı ve maliyetli olabilir. Bu nedenle, mevcut verileri çoğaltarak modellerin daha fazla veriyle desteklendiği bir teknik olan veri artırımı yöntemleri kullanılmaktadır. Veri artırımı, mevcut örnek verileri kullanılarak yeni veri örnekleri üretilmesiyle, veri miktarının yapay olarak artırılmasını amaçlayan teknikleri içermektedir. Bu teknikler, verilerde küçük değişiklikler yapmayı veya derin öğrenme modellerini kullanarak yeni veriler üretmeyi içermektedir.

Çoğu sınıflandırıcı modelinin performansı eğitim verilerinin kalitesine, miktarına ve model için uygunluğuna bağlıdır. Fakat yetersiz veri, modellerin eğitiminde karşılaşılan en yaygın zorluklardan biridir. Bunun nedeni, bu tür verilerin toplanmasının birçok durumda maliyetli ve zaman alıcı süreçleri barındırmasından kaynaklanmaktadır. Veri artırımıyla, modeller eğitim için daha fazla varyasyona sahip verilere maruz bırakılır, bu sayede genelleme ve görülmeyen veriler üzerinde modelin doğru tahminler yapma yetenekleri artırılır. Bu durum özellikle veri kümesi sınırlı veya dengesiz olduğunda daha önemli hale gelmektedir.

Bu tez çalışmasında önceki bölümlerde verilen deneysel düzenekle elde edilen malzeme örneklerine ait orijinal örnek veri sayıları çizelge 3.1’de verilmiştir. Her bir malzeme gurubu için 60 adet örnek ve tüm guruplar için toplamda 240 örnek verisi alınmıştır. Bu çalışmada kullanılan sınıflandırıcı modellerinin performansını arttırmak için bu örnekler kullanılarak veri artırımı gerçekleştirilmiştir.

Veri artırımı için orijinal veriler 5us, 10us ve 15us kaydırılarak orijinal örnek verisine göre faz farkı oluşturulmuştur. Bu sayede orijinal veri ile aralarında faz farkı olan yeni veriler elde edilmiştir ve örnek gurupları kullanılarak veri artırımı yapılmıştır.



Şekil 3.8: Orijinal veri ve veri artırımı ile elde edilen veri grafikleri.

Orijinal veriler kullanılarak faz farkına dayalı veri artırımı ile elde edilen örnek veri grafikleri yukarıdaki şekilde verilmiştir. Burada darbe sinyali (yeşil) ile lazer sistemi

tetiklenmiştir ve oluşan FA sinyal mikrofon aracılığıyla alınmıştır. Şekil 3.8’de verilen $x(t)$ orijinal verinin grafiğini (mor), $x(t-5)$ $x(t)$ ’nin 5 us kaydırılması sonucu oluşan grafiği (sarı), $x(t-10)$ $x(t)$ ’nin 10 us kaydırılması sonucu oluşan grafiği (turuncu) ve $x(t-15)$ $x(t)$ ’nin 15 us kaydırılması sonucu oluşan grafiği (mavi) ifade etmektedir.

Bu tezde faz farkı ile çizelge 3.1’deki orijinal veriler kullanılarak örnek veri sayısı dört katına çıkarılmıştır. Orijinal ve veri artırımı sonucu elde edilen verileri içeren toplam örnek sayısı aşağıdaki çizelge 3.2’de verilmiştir.

Çizelge 3.2: Veri artırımı sonucu oluşturulan toplam örnek veri sayısı.

	Sağlam	Kusurlu	Toplam
Demir	120	120	240
Alüminyum	120	120	240
Tahta	120	120	240
Plastik	120	120	240
Toplam	480	480	960

3.3 Görgül Kip Ayrışımı

Görgül Kip Ayrışımı (GKA), doğrusal ve durağan olamayan sinyalleri fiziksel olarak anlamlı bileşenlere ayırmak için, Huang ve arkadaşları tarafından önerilen veri uyarlamalı sinyal işleme yöntemidir [32]. Bu teknik temelde sinyalin üst ve alt zarflarının kübik eğri interpolasyonu kullanılarak bulunması ve bunların ortalamasının alınması esasına dayanmaktadır. Bu sayede bir sinyal, kendisini oluşturan ve yarı ortogonal özellikler gösteren Özgül Kip Fonksiyonları (ÖKF) olarak adlandırılan salınımlar cinsinden ifade edilir. Bir sinyale bu yöntemin uygulanması sonucunda elde edilen salınımların ÖKF olarak kabul edilebilmesi için aşağıdaki koşulları sağlaması gerekmektedir:

- ÖKF lokal maksimum ve minimum noktalarının sıfır geçiş noktasına eşit veya farkının en fazla bir olmalı.
- Lokal maksimum ve minimum zarflarının ortalamasının sıfır olması gerekmektedir.

GKA'nın taban fonksiyonu seçimi gerektirmemesi, GKA'nın en önemli avantajlarından biridir. GKA, sinyaldeki doğal frekansları temsil eden özgül kip fonksiyonları üretir. Bu fonksiyonlar, herhangi bir taban fonksiyonuna ihtiyaç duymadan sinyalden elde edilir.

GKA'nın sinyale uyarlanabilir olması bir diğer önemli özelliğidir. Bu özellik sayesinde GKA, doğrusal olmayan ve durağan olmayan sinyalleri de analiz edebilmektedir.

Eleme işlemi, işlenen sinyal üzerinde durdurma kriteri sağlanana kadar yinelemeli olarak devam eden GKA'nın ana konseptidir. Burada zaman serisi sinyallerini, eleme işlemi aracılığıyla $\varphi(n)$, ÖKF ve $r(n)$, artık adı verilen sonlu bir genlik ve frekans modülasyonu salınımlı bileşenler kümesine ayırıştırır. Eleme sürecinin adımları, örnek bir $x(n)$ sinyali için aşağıdaki gibidir.

- $x(n)$ sinyalinin yerel maksimum ($M(i), i = 1,2,3, \dots$) ve minimum ($m(j), j = 1,2,3, \dots$) noktaları bulunur.
- İnterpolasyon ile yerel maksimum ve minimum noktalarını kesen zarf bulunur. $e_{min}(n), e_{max}(n)$.
- Zarfların ortalaması hesaplanır $m(n) = (e_{min}(n), e_{max}(n))/2$
- $m(n)$ ÖKF şartlarını sağlıyorsa $\varphi_k(n) = m(n)$ olarak sakla. Sağlamıyorsa $m(n), x(n)$ 'den çıkarılır, $x(n) = x(n) - m(n)$.
- Durdurma kriteri $x(n)$ için sağlanıyorsa $r(n) = m(n)$ olarak atanır.

GKA'da eleme süreci $r(n)$ artık fonksiyonu elde edilene kadar özyinelemeli olarak uygulanır. Orijinal sinyal ÖKF'lerin ve artık sinyalin toplamına eşittir ve bağıntısı aşağıdaki (3.1) numaralı bağıntıda verilmiştir.

$$x(n) = r(n) + \sum_k^L \varphi_k(n) \quad (3.1)$$

L burada toplam ÖKF sayısını temsil etmektedir.

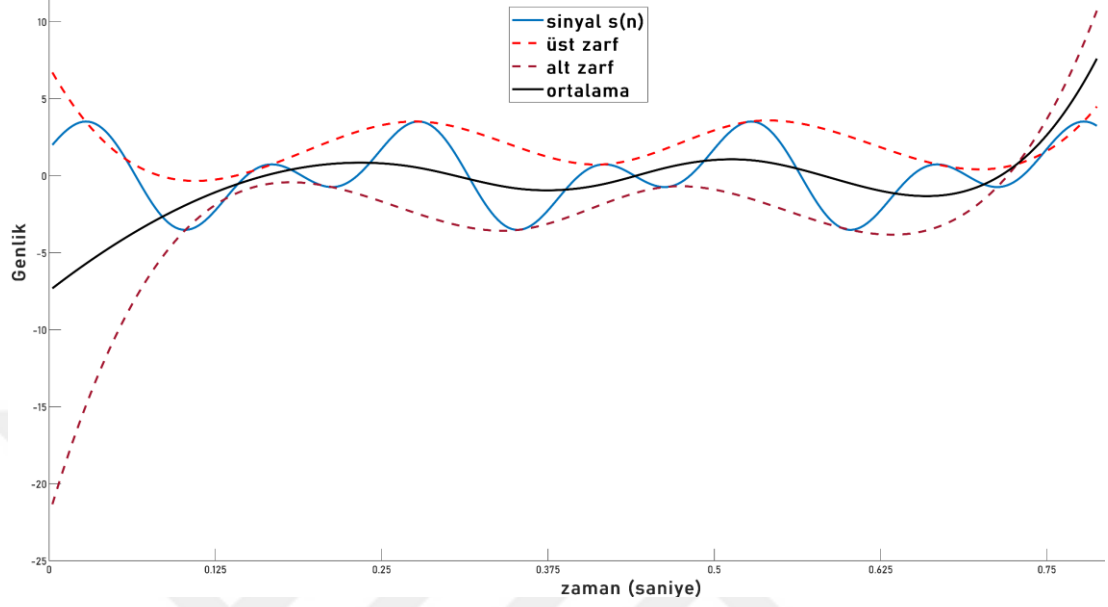
Aşağıdaki şekil 3.9'da GKA algoritmasının eleme süreçleri görsel olarak özetlenmiştir. Grafikteki sinyali temsil eden bağıntılar aşağıda verilmiştir.

$$s_1(n) = A \cos(2\pi f_1 t) \quad (3.2)$$

$$s_2(n) = A \sin(2\pi f_2 t) \quad (3.3)$$

$$s(n) = s_1(n) + s_2(n) \quad (3.4)$$

Burada t zamanı, A genliği ifade etmektedir ve değeri 2 olarak atanmıştır. f_1, f_2 frekansı ifade etmektedir ve değerleri ise sırasıyla $\pi, 2\pi$ olarak atanmıştır.



Şekil 3.9: GKA'nın eleme sürecinin grafiksel gösterimi.

GKA algoritmasının eleme süreçlerinin iyileştirilmesi için farklı çalışmalar gerçekleştirilmektedir. GKA'da eleme algoritması üzerinde alt ve üst zarf çıkarmada enterpolasyondan kaynaklanan hatalar sonucu bitiş ve ortak mod-karıştırma etkisi gibi problemler oluşmaktadır[33, 34].

Elde edilen üst ve alt zarflarının birinci ve sonuncu örneklerinin, elde edildiği sinyalin gerçek üst ve alt noktaları arasındaki fark sonucu hatanın büyük olması bitiş etkisi probleminin temel oluşum nedenidir.

Çok bileşenli bir $s(n)$ sinyalinin kendini oluşturan tek bileşenlerinin elde edilememesi ise ortak mod hatası şeklinde tanımlanmaktadır. Yani GKA ile elde edilen $\varphi_k(n)$ 'nin bileşeninin tek bileşen olamaması halidir.

GKA algoritması, sinyalleri ÖKF bileşenlerine ayırtırmak için eleme işlemine dayanır. Eleme işlemi sürekli sinyaller için uygulanır, bu da GKA'nın performansının örneklemeyle ilgili olduğu anlamına gelir. Bu nedenle, eleme işleminde aşırı ayırtırmadan kaçınmak için bileşenin fiziksel anlamının korunması gerektiğinden durdurma kriteri performansı etkileyen bir faktördür [35]. Genel olarak, farklı uygulamalar sinyal farklılığına bağlı olarak farklı durdurma kriterleri gerektirebilir.

Durdurma kriteri belli sınırlar içerisinde uygulamada ÖKF'lerin sayısı ve iterasyon sayısı gibi kıstaslar uygulanmasına olanak sağlamaktadır.

Cauchy tipi durdurma kriter ilk olarak Huang ve diğerleri [32] tarafından önerilmiştir. Bu kritere göre, Standard sapma (SD) olarak tanımlanan fark, önceden ayarlanmış bir değerden küçük olduğunda eleme işlemi duracaktır.

$$SD = \sum_{t=0}^T \left[\frac{|h_{(k-1)}(t) - h_k(t)|^2}{h_{(k-1)}^2(t)} \right] \quad (3.5)$$


Burada o andaki alt zarf ile üst zarfın ortalaması $h_{(k)}(t)$ ve bir önceki alt ve üst zarfın ortalaması $h_{(k-1)}(t)$ olarak tanımlanmıştır. Bu tanıma göre, yakınsama koşulu matematiksel olarak, verilen herhangi bir küçük ε sayısı için, eleme sayısı K , M 'den büyük olduğunda $SD < \varepsilon$ olacak şekilde büyük bir M yineleme sayısı vardır şeklinde tanımlanır [36].

Yukarıda (3.5) numaralı bağıntıda standart sapmaya dayanan durdurma kriterinde iki yineleme arasındaki değişim incelenerek ÖKF'nin anlamlı olup olmadığına karar verilmiştir. Bu tez çalışmasında ise standart ÖKF koşullarına ilave olarak enerji temelli çözünürlük seçeneği sunan ve $m(n)$ 'nin ÖKF veya artık şartlarını sağlamıyorsa süreci durduran koşulların dayandığı bağıntılar aşağıda verilmiştir [37].

$$EnRes = 10 \log \left(\frac{\sigma_{x(n)}^2}{\sigma_{h(n)}^2} \right) \quad (3.6)$$

$$EnRat = 10 \log \left(\frac{\sigma_{x(n)}^2}{\sigma_{r(n)}^2} \right) \quad (3.7)$$

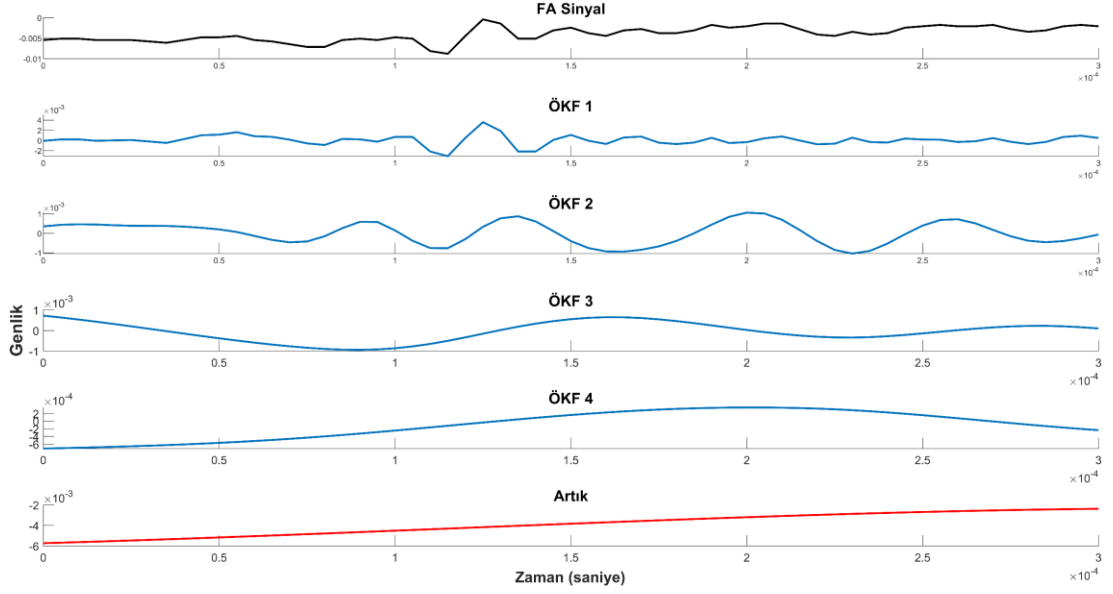
Bu koşullar aracılığıyla elde edilen $h(n)$ 'nin ÖKF olarak ($\varphi_k(n)$) saklanabilmesi için, $x(n)$ 'e ön tanımlı olarak belirlenen belirli bir EnRes enerji değerine sahip olması gerekmektedir. Benzer olarak, algoritmanın sonlanması için artık $r(n)$ 'nin kullanıcının ön tanımlı olarak belirlediği EnRat oranının altında düşmesi gerekmektedir. Enerji çözünürlük prensibine göre uygulanan GKA algoritması süreçlerini temsil eden blok diyagram aşağıdaki şekil 3.10'da verilmiştir.



Şekil 3.10: Enerji çözünürlüğüne dayalı GKA akış şeması.

Yukarıda anlatılan yöntemlere dayalı olarak, örnek malzemelerden elde edilen FA sinyal verisine GKA algoritmasının uygulanması sonucunda elde edilen ÖKF ve artık grafiği aşağıda şekil 3.11’de verilmiştir.

300 mikro saniyelik FA sinyali için GKA algoritması sonucunda elde edilen 4 adet ÖKF ve artık bileşenlerinin salınımları gözükmemektedir. Burada ilk bileşenlerin frekanslarının daha yüksek olduğu ve artan ÖKF sayısı ile frekansın düştüğü görülmektedir.



Şekil 3.11: FA sinyali ve EMD algoritması sonucu elde edilen ÖKF ve artık bileşenleri.

3.4 Hilbert-Huang Dönüşümü

Hilbert-Huang dönüşümü (HHD), zaman serilerinin analizinde kullanılan bir yöntemdir. Bu yöntem, görgül kip ayrışımı yöntemi ile zaman serilerini özgül kip fonksiyonlarına ayırdıktan sonra, ÖKF'lere Hilbert Dönüşümü (HD) [32] uygulanması sonucu ÖKF'lerden anlık frekans ve genlik bilgilerinin elde edilmesi şeklinde tanımlanabilir. Bu sayede özgül kip fonksiyonları üzerinde zaman-frekans düzleminde analiz gerçekleştirilir.

Bu dönüşümde ilk olarak GKA ile elde edilen ÖKF'lerine HD uygulanarak ÖKF'lerin analitik formları elde edilir. Bir $x(t)$ sinyali için elde edilen ÖKF'ler $\varphi_i(t)$ olsun, bu durumda ÖKF'ler için analitik form aşağıdaki gibi yazılabilir;

$$\varphi_{A_i}(t) = \varphi_i(t) + jH\{\varphi_i(t)\}, i = 1, 2, 3, \dots, N. \quad (3.8)$$

burada verilen $\varphi_{A_i}(t)$, özgül kip fonksiyonlarının analitik versiyonlarını ve $H\{\varphi_i(t)\}$ ise ÖKF'nin (19) numaralı bağıntıda verilen Cauchy integrali ile elde edile HD dönüşümlerini ifade etmektedir.

$$H\{\varphi_i(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{\varphi_i(\tau)}{t - \tau} d\tau \quad (3.9)$$

Dönüşüm sonucu yukarıda (3.8) numaralı bağıntıdaki analitik form kutupsal olarak aşağıdaki gibi yazılabilir.

$$\varphi_{A_i}(t) = a_i(t)e^{j\Phi_i(t)} \quad (3.10)$$

Burada $a_i(t)$ anlık genliği, $\Phi_i(t)$ ise anlık fazı ifade etmektedir. Anlık faz ve anlık genlik aşağıda verilen (3.11) ve (3.12)'deki bağıntılar kullanılarak elde edilir.

$$a_i(t) = \sqrt{\varphi_i(t)^2 + H\{\varphi_i(t)\}^2} \quad (3.11)$$

$$\Phi_i(t) = \arctan \left\{ \frac{H\{\varphi_i(t)\}}{\varphi_i(t)} \right\} \quad (3.12)$$

Anlık frekans $f_i(t)$ ise, anlık faz $\Phi_i(t)$ 'nin türevi alınarak elde edilir ve bağıntısı aşağıda verilmiştir.

$$f_i(t) = \frac{d\Phi_i(t)}{dt} \quad (3.13)$$

Böylece sinyalin barındırdığı $f_i(t)$ ve $a_i(t)$ bileşenleri ile zaman-frekans düzleminde analiz gerçekleştirilir. GKA ve anlık frekans kombinasyonu bu yöntemi, zaman-frekans analizi için güçlü bir sinyal işleme çerçevesi kılmaktadır.


FA sinyal kullanılarak elde edilen ÖKF'lere HHD uygulanması sonucunda elde edilen $f_i(t)$ ve $a_i(t)$ bileşenleri aşağıdaki şekillerde verilmiştir.

3.5 Özellik Çıkarımı


Özellik çıkarımı, verimliliği veya veri depolama ve işlemeyi iyileştirmek için en kompakt ve bilgilendirici özellik kümesini bulmayı amaçlamaktadır. Özellik vektörlerinin tanımlanması, sınıflandırma problemleri için en yaygın ve uygun veri temsil aracı olmaya devam etmektedir. Bir niteliği temsil eden veya değişken olan özellikler, sınıflandırıcılar için bir kaynaktır. Özellik çıkarımı tıp, petrol, endüstriyel denetim ve teşhis sistemleri, konuşma tanıma, biyoteknoloji, internet, hedefli pazarlama ve diğer birçok gelişmekte olan uygulamadaki uygulamalarla bu ilerlemelerin merkezinde yer almaktadır [38].

Bu tez çalışmasında her bir malzeme için zaman ve zaman-frekans düzleminde 14 adet özellik çıkarılmıştır. Bu özelliklerin hangi uzayda değerlendirildiği bulgular

bölümünde verilecektir. Burada sadece özelliklerin çıkarımı için kullanılan bağıntılar verilmiştir.



Şekil 3.12: FA sinyalin Hilbert-Huang anlık genlik izgesi.



Şekil 3.13: FA sinyalin Hilbert-Huang anlık frekans izgesi.

- Tepe genlik (TG), bir dalga formunun sıfır referans seviyesinden maksimum pozitif sapması olarak tanımlanır ve bağıntısı (3.14) numaralı bağıntıda verilmiştir. Tüm tepe genlik değerleri bu bağıntı kullanarak hesaplanmıştır.

$$TG = maks(x) \quad (3.14)$$

- Tepeden tepeye genlik (TTG), sinyal genliğinin pozitif tepe ve negatif tepe değerleri arasındaki fark olarak tanımlanır ve (3.15) numaralı bağıntı kullanılarak hesaplanmıştır.

$$TTG = maks(x) - min(x) \quad (3.15)$$

- Form Faktör (FF), sinyalin birinci derece türevinin değişkenliğinin, sinyalin değişkenliğine oranını ifade etmektedir ve bağıntısı (3.16) numaralı bağıntıda verilmiştir.

$$FF = \frac{\sigma^2\left(\frac{x''}{x'}\right)}{\sigma^2\left(\frac{x'}{x}\right)} \quad (3.16)$$

- Hjorth parametreleri (Activity, Mobility, Complexity), bu parametreler zaman düzleminde gerçekleştirilen sinyal işlemede kullanılmaktadır ve sinyalin istatistiksel özelliklerinin göstergesinin ifade edilmesini kapsamaktadır [39].

- Hjort Activity (HA), sinyal varyansını ifade etmektedir ve bağıntısı aşağıda (3.17) numaralı bağıntıda verilmiştir.

$$HA = \sigma^2(x) \quad (3.17)$$

- Hjort Mobility (HM), parametresi sinyalin birinci türevinin varyansının, sinyalin varyansına oranının kareköküdür ve bu parametre sinyalin ortalama frekansını ifade etmektedir. HM parametresinin bağıntısı aşağıda verilen (3.18) numaralı bağıntı kullanılarak elde edilmiştir.

$$HM = \sqrt{\frac{\sigma^2(x')}{\sigma^2(x)}} \quad (3.18)$$

- Hjort Complexity (HC), parametresi sinyal frekansındaki değişimi ifade eder. Ayrıca bu parametre sinyal ile sinüs dalgası arası benzerlik karşılaştırması olarak ifade edilmektedir. HC parametresinin elde edildiği bağıntı aşağıdaki (3.19) numaralı bağıntıda verilmiştir.

$$HC = \frac{HM(x')}{HM(x)} \quad (3.19)$$

- Entropi (E), ölçülebilir fiziksel bir nicelik olan entropi, sistemin düzensizliği ve belirsizliği ile bağlantılıdır. Sinyalin entropisinin hesabı için kullanılan bağıntı aşağıdaki (3.20) numaralı bağıntıda verilmiştir.

$$E = -\sum x_i \log x_i \quad (3.20)$$

- Standart Sapma (SS), veriler kümesindeki değerlerin dağılım miktarını gösteren ölçü olarak ifade edilebilir. SS değerinin düşük olması veri kümesindeki değerlerin ortalamaya yakın eğilim gösterdiğini, yüksek SS ise veri kümesindeki değerlerin geniş bir aralıkta yayılım gösterdiğini ifade etmektedir. SS hesabı için kullanılan bağıntı aşağıda (3.21) numaralı bağıntıda verilmiştir.

$$SS = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.21)$$

Burada n örnek sayısını, \bar{x} ise örneklerin ortalamasını ifade etmektedir.

- Ortalama Genlik (OG), sinyalin bir çevrim süresi boyunca ani değerlerinin ortalaması olarak ifade edilmektedir. Ortalama değerlerin hesabı için bağıntı aşağıda (3.22) numaralı bağıntıda verilmiştir. Ortalama frekans ve ortalama genlik ifadeleri (3.22) numaralı bağıntı kullanılarak elde edilmiştir.

$$OG = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.22)$$

- Eğim (M), sinyalin herhangi iki noktası arasındaki dikey değişimin, yatay değişmeye oranı olarak ifade edilmektedir. Bu çalışmada sinyalin dikey bileşenleri, sinyalin tepe değeri x_2 ve tepe değerin % 20'sine denk gelen diğer bileşen olan x_1 olarak belirlenmiştir. Yatay bileşenler ise x_2 ve x_1 değerlerinin yatay düzlemdeki iz düşümleridir ve sırasıyla y_2 ve y_1 olarak ifade edilmiştir. Eğim değerleri (3.23) numaralı bağıntı ile elde edilmiştir.

$$M = \frac{x_2 - x_1}{y_2 - y_1} \quad (3.23)$$

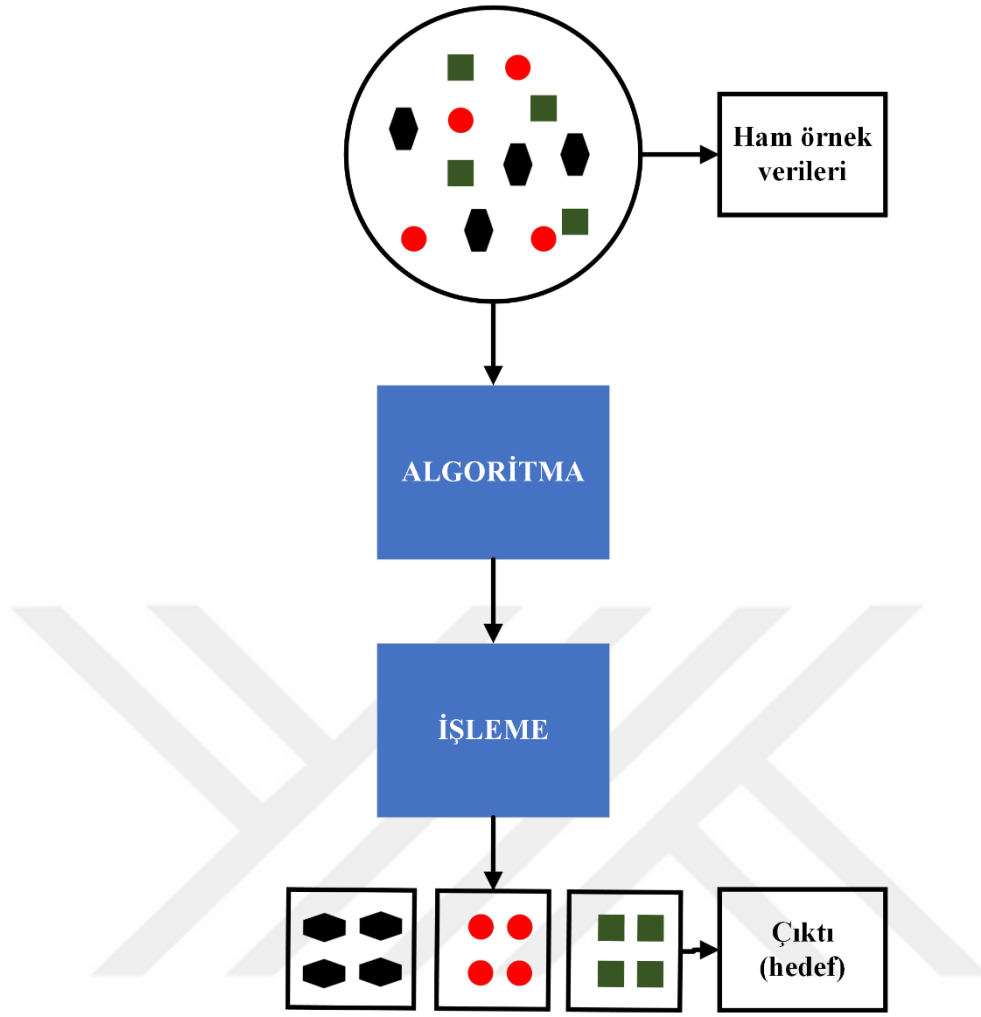
- Aktif Sinyal Süresi (ASS), sinyalin tepe genliğinin %20'sine ulaştığı andaki zaman olan t_1 ile tekrar tepe genliğin %20'sine düştüğü zaman olan t_2 arasındaki geçen süreyi ifade etmektedir. Bu süre aşağıda (3.24) numaralı bağıntı kullanarak hesaplanmıştır.

$$ASS = |t_1 - t_2| \quad (3.24)$$

3.6 Yapay Öğrenme

İnternet servislerinin yaygınlaşması ve teknolojiadaki gelişmeler, büyük veri setlerinin ortaya çıkmasına neden olmuştur. Bu veri kümeleri, bilim insanları ve araştırmacılar tarafından analiz edilmek ve işlenmek için birçok yöntem geliştirmesi ihtiyacı meydana getirmiştir. Yapay öğrenme (YÖ), oluşan büyük veri setlerine uygunluğu ve tahmin kabiliyetleri sayesinde hızla gelişerek yaygınlaştı. Ve bunun neticesinde birçok alanda bilim insanları ve çeşitli alanlardan araştırmacılar tarafından uygulanmaya başlanmıştır [40].

Yapay öğrenme, bilgi ve sayısal işlem yeteneğine sahip sistemlerin, mevcut veya veri toplama araçlarıyla elde edilen veri kümeleri kullanılarak verinin barındırdığı özellikler yardımıyla doğru ve akılcı kararlar verebilme yetisi olarak tanımlanabilir. YÖ, bir problemin çözümü için veya sonuç çıktısını elde etmek için önceden veri ile eğitilmiş, insan gibi öğrenme ve veriler doğrultusunda karar verebilme mekanizmasını taklit eden sistemler şeklinde de tanımlanabilir [41]. Aşağıda şekil 3.14'te basitleştirilmiş blok şeması verilen YÖ yapısı, temelde girdi olarak örnek ham verilerinin olduğu, bu verilerin işlenerek öğrenildiği ve ardından çıktı (hedef) değişkeninin üretilerek verileri ayırıştırılan bir süreçtir.



Şekil 3.14 : Yapay öğrenme süreci.

Bu çalışmada yapay öğrenme yöntemlerinden karar ağaçları (ing. Decision Tree) (KA), k-en yakın komşu (ing. k -Nearest Neighborhood) (k -NN) ve destek vektör makineleri (ing. Support Vector Machines) (DVM) sınıflandırıcı olarak belirlenmiştir. Tüm sınıflandırıcılar için çapraz doğrulama yöntemi olarak, birini dışarıda bırak (ing. leave-one-out LOO) çapraz doğrulama yöntemi seçilmiştir. Ayrıca özellik ağırlıklarının analizi için Relieff algoritması benimsenmiştir. Yukarıda bahsedilen yöntemlerin teorilerinden ve YÖ ile ilgi teorilerinden aşağıdaki takip eden bölümlerde bahsedilecektir.

3.6.1 Veri ve veri seti

Veri, işlenmemiş sayısal ya da sözel değerlerin temel tanımını oluşturur. Bu değerler, ölçüm, gözlem veya deney gibi çeşitli araştırma yöntemleriyle elde edilebilir. İşlem geçiren veya analiz edilen veri, anlamlı bilgilerin elde edilmesini sağlayan temel

yapıdır. Veri seti ise aynı konuyu veya yapıyı ilgilendiren verilerin toplanması ile oluşturulan yapıyı temsil etmektedir. Veri setleri, bilimsel arařtırmalarda temel argümanlardan biri olduklarından büyük öneme sahiptirler ve genellikle tablolar halinde saklanmaktadır.

Çizelge 3.3 : Örnek veri seti.

Tanımlayıcı	Boy (m)	Kilo (kg)	Cinsiyet
Kiři 1	1.50	50	kadın
Kiři 2	1.60	60	kadın
Kiři 3	1.80	90	erkek
Kiři 4	1.65	65	kadın
Kiři 5	1.75	85	erkek

Yukarıdaki çizelgede örnek bir veri seti verilmiştir. Verilen bu veri seti, 5 farklı kişinin oluşturduğu gruptaki, boy kilo ve cinsiyet bilgilerini içermektedir. Tablodaki değerlerin elde edilmesi ve bu değerlerin aynı nitelikte olanlarının gruplanarak bir araya getirilmesi veri setini oluşturmaktadır.

Elde edilen bu verilerin işlenmesi veya analiz edilmesi sonucu bu veriler bilgiye dönüşmektedir. Örnek olarak, yukarıdaki çizelge kullanılarak kadınların kilo ortalaması 58.33 kg bilgisi, erkeklerinde boylarının ortalamasının 1.78 metre bilgisi elde edilmektedir.

Anlatılacak veri seti için, her bir satırın bir örnek ve her bir sütunun bir özellik olarak kabul edildiği bir veri seti incelenmiştir. Sınıflandırma problemlerinde kullanılan veri setlerinde, özellik sütunlarından biri örneklerin ait oldukları sınıfları göstermektedir. Çizelge 3.3'te verilen örnek veri setine göre, örneklerin cinsiyeti sınıfları temsil edebilir özelliğindedir ve bu sütun sınıflandırma için sınıf sütunu olarak kabul edilmiştir. Bu durumda, tabloda verilen örnek veri seti boy ve kilo olmak üzere 2 özellik ve 5 örnekten ve iki sınıftan oluşmaktadır. Tablo incelendiğinde, verilen her bir özelliğin farklı aralık değerlerinde olduğu görülmektedir. Farklı aralıklardaki bu özellikler, veri analizi ve sınıflandırma açısından farklı özelliklerin farklı etki katsayılarına sahip olabileceği anlamına gelmektedir ve bu da hatalı sonuçlara neden olabilmektedir. Bu sorunu aşmak için özelliklere veri normalizasyonu uygulanmaktadır.

$$\text{özellik}_i^{\text{norm}} = \frac{\text{özellik}_i}{\text{maksimum}(\text{özellik}_i)} \quad (3.25)$$

Veri normalizasyonu, özelliklerin değerinin ait olduğu özellik sınıfındaki maksimum değere bölünmesi ile gerçekleştirilmektedir ve bu işlemi ifade eden bağıntı yukarıdaki (34) numaralı denklemlerle ifade edilmektedir. Çizelge 3.4, örnek veri setinin normalize edilmiş versiyonunu içermektedir. Yukarıda çizelge 3.3'te verilen özelliklerin normalize edilmiş hali aşağıda çizelge 3.4'te verilmiştir.

Çizelge 3.4: Normalize edilen örnekler.

Örnek	Özellik 1	Özellik 2	Sınıf
Tanımlayıcı	Boy (m)	Kilo (kg)	Cinsiyet
Kişi 1	0.83	0.56	kadın
Kişi 2	0.89	0.67	kadın
Kişi 3	1.00	1.00	erkek
Kişi 4	0.92	0.72	kadın
Kişi 5	0.97	0.94	erkek

Örnek verilerin normalize edilmesi için boy değerleri 1.80'e, ağırlık değerleri ise 90'a bölünmüştür. Bu sayede farklı özellikler normalize edilmiştir.

3.6.2 Yapay öğrenme türleri

Yapay öğrenme algoritmaları şekil 3.15'te yapısal olarak özet haliyle gösterilmiştir. Bu algoritmalar eğitilecek verinin özelliklerine göre 3 temel kategoride incelenmektedir. Bunlar denetimsiz öğrenme (ing. unsupervised learning), denetimli öğrenme (ing. supervised learning) ve pekiştirmeli öğrenme (ing. reinforcement learning) olarak gruplandırılmaktadır.

3.6.2.1 Denetimsiz öğrenme

Denetimsiz (eğitici) öğrenme, genellikle örneklerin benzer özelliklere göre gruplandırılması veya örnekler arasındaki gizli ilişkilerin keşfiyle ilgilenen bir alanı kapsamaktadır. Denetimsiz öğrenme uygulamalarında, örnek verileri genellikle bir sınıfa etiketlenmemiştir, bu durumda modellerden beklenen, veri çıktıları karşılığında denk gelecek kümeler veya veriler arasındaki gizli ilişki kurallarını keşfetmektir.



Şekil 3.15 : Yapay öğrenme türleri.

Denetimsiz öğrenme yönteminin en yaygın yöntemlerinden biri kümeleme analizidir. Bu bağlamda, kullanılan verinin etiketsiz olması nedeniyle kaç tane küme olacağını tahmin etme süreçleri bu yöntemde önemli bir konudur. Aynı şekilde veriler arası benzerliğinde tanımlanabilmesinde bu yöntemde kritik bir yer teşkil etmektedir.

3.6.2.2 Denetimli öğrenme

Denetimli (eğiticili) öğrenme, etiketli bir veri setinde bulunan verilerin etiketini tahmin etmek için kullanılan bir stratejidir. Denetimli öğrenme yönteminin temel hedefi, kullanılan modelin örnek verilerine karşılık ürettiği tahmin değerinin doğruluğunu optimize etmektir. Veri setindeki örneklerin giriş verileri ile modelin ürettiği etiketler arasındaki bilinen ve bilinmeyen ilişkileri ve örüntüleri algılamak için algoritma eğitilir. Bu süreç sonunda bir model elde edilir. Girdi verilerinin sınıf etiketleri bilindiği için, eğitilmiş modellerin öğrenme performansları değerlendirilebilir. Bu amaçla, denetimli öğrenme yaklaşımında veri seti genellikle eğitim seti, test seti ve doğrulama seti olmak üzere üç parçaya ayrılmaktadır [42].

3.6.2.3 Pekiştirmeli öğrenme

Denetimli öğrenmeden farklı olarak, bu yöntemde doğru giriş-çıkış kombinasyonları önceden algoritmaya sağlanmaz. Pekiştirmeli öğrenme, makinelerin, modellerin veya yazılımların performansını maksimize etmek için belirli bir durumdaki en uygun davranışı otomatik olarak belirlemelerine olanak tanıyan bir öğrenme yöntemidir. Bu yaklaşım, bir eğiticiden bağımsız olarak, en yüksek ödülü elde etmeye odaklanarak deneme-yanılma metoduyla öğrenme sürecini geliştirir. Bu metot genellikle oyunlar, programlama gibi dinamik çevresel koşulların olduğu durumlar için kullanılmaktadır.

3.6.3 Destek vektör makineleri

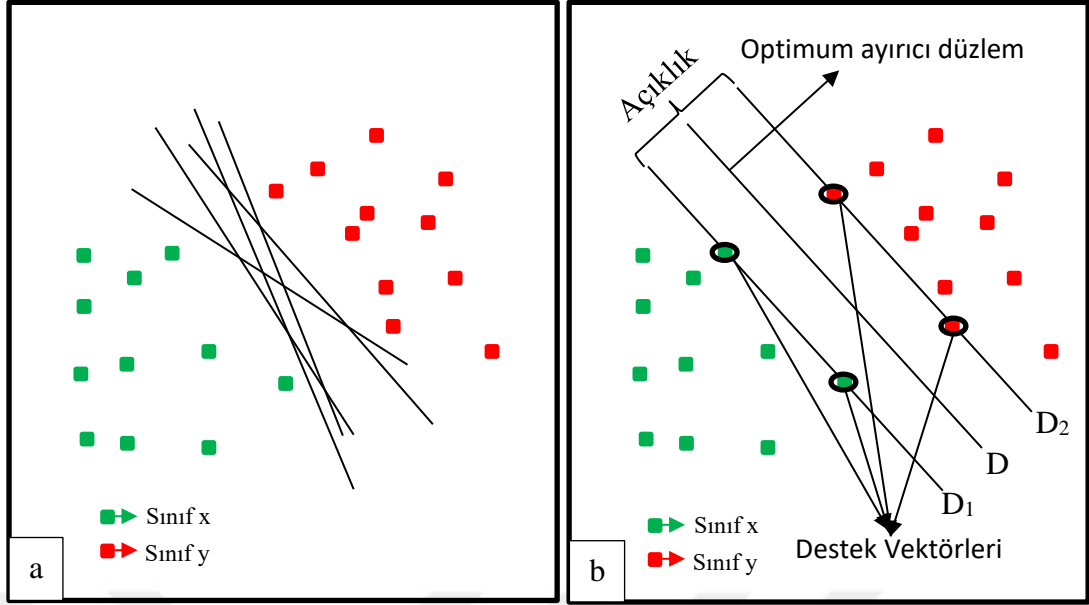
V. Vapnik [43] tarafından 1960'larda teori olarak ileri sürülen DVM temelde istatistiksel öğrenme teorilerine dayanmaktadır ve data gruplarını kullanarak örnekleri ait oldukları sınıflara sınıflandıracak eğriyi bulmayı amaçlayan MÖ disiplinlerindedir. Basit yapısı ve yüksek performansı nedeniyle destek vektör makineleri süreç içerisinde birçok sınıflandırma ve regresyon problem çözümü için uygulanan yöntem olmuştur.

Bu yöntemde, üzerinde çalışılan örnek veriler DVM'ye gösterilir daha sonra bu yöntemden örnek verilerin öz niteliklerindeki karakteristikler yardımıyla örnekleri sınıflandırabilme işlemini gerçekleştirebilecek bir fonksiyon üretmesi istenir. Örnek veri sınıfları, veri gruplarını kapsayan bir düzlemde bir nokta olarak düşünülürse, destek vektör makinesinin amacının bu veri düzlemindeki noktalar arasında ayırım düzlemini oluşturarak, örnek verilerini ait oldukları sınıflara ayırmak olduğu söylenebilir. Bu yöntem ses ve yüz tanımda, finans uygulamalarında, arıza ve anormali tespiti, tıbbi teşhis gibi birçok araştırma alanında uygulanmıştır [44, 45].

Bu yapay öğrenme yöntemi problemleri kareli optimizasyon problemleri şekline dönüştürülmesi sonucunda çözüm uyguladığından dolayı, hızlı eğitim ve çözüm süreci sağlamaktadır. Bunun sonucu olarak, sınıflandırma performansı açısından, öğrenme yetisi ve genelleme yeteneğinin veri uzayındaki özellik sayısı ile kısıtlı olmaması ve düşük veri setlerinde uygulanabilir olması gibi avantajlar sunmaktadır [46, 46].

DVM örnek verileri sınıflandırmak için veri uzayında en iyi ayırıcı düzlemi bulmaya çalışır. DVM'nin benzetim yapısı temel haliyle şekil 3.16'da verilmiştir. Şekil 3.16(a)'da farklı iki sınıf için ayırıcı doğrunun sonsuz şekilde çizilebileceği gösterilmiştir. Ancak DVM'nin temel amacı verilen örnekleri mümkün olan en yüksek doğrulukla ayırabilecek ayırıcı doğruyu bulmaktır. Bu amacı temsil eden doğru şekil 3.16(b)'de gösterilmiştir.

DVM ilk haliyle doğrusal sınıflandırma metodu olarak önerilmiştir ancak zamanla geliştirilerek doğrusal olmayan sınıflandırma problemlerine uygulanabilir hale gelmiştir. Bundan dolayı bu çalışmada destek vektör makinaları yöntemi doğrusal ile doğrusal olmayan durumlar için anlatılacaktır.




Şekil 3.16: Örnekleri sınıflandırabilecek olası doğrular (a) ve örnekleri en iyi sınıflandırabilecek doğru (b) için temel DVM yapısı.

3.6.3.1 Doğrusal destek vektör makineleri

Sınıflandırma problem örneklerinin doğrusal bir şekilde ayrılabilir olduğu durumlar için doğrusal DVM yöntemi kullanılmaktadır. Doğrusal bir şekilde ayrılabilen ve iki sınıfa olan bir sınıflandırma problemimiz olsun. Bu sınıflandırma problemine ait n adet özellik değeri barındıran x_i eğitim veri setimiz ve her bir örneğin ait olduğu sınıfa belirten $y_i = (-1, +1)$ sınıf etiketimiz olsun. Bu parametreler kullanılarak doğrusal olarak ayrılabilir problem verilerine ait DVM sınıflandırıcısının matematiksel ifadesi aşağıdaki bağıntıdaki gibi olacaktır.

$$f(x) = \text{sgn}(wx_i + b) \quad (3.26)$$

Yukarıda (3.26) numaralı bağıntıda w ağırlık vektörünü, $\text{sgn}(\omega x_i + b)$ etiketini, x ise örneklere ait özellik vektörünü ve b 'de sabit değer alan eşik temsil etmektedir. Destek vektör makinalarına x_i öznitelik vektörünün verilmesi sonucunda $f(x_i)$ fonksiyonunun üreteceği değer pozitif olduğu durumda giriş olarak verilen örnek pozitif değerler için etiketlenen sınıfa, eğer fonksiyonun ürettiği değer negatif ise negatif olarak etiketlenen sınıfa atılır ve örnek verisine ait öznitelikler kullanılarak sınıflandırma işlemi gerçekleştirilir. Doğrusal DVM'nin sınıflandırma problemini uygulama temsili şekil 3.17'de verilmiştir.



Şekil 3.17: Doğrusal DVM'nin sınıflandırma uygulanmasının grafiksel temsili.

Yukarıdaki şekilde H, iki sınıfı en iyi şekilde ayıran düzlemi, m ise iki düzlem arasındaki maksimum açıklığı göstermektedir. H₁ ve H₂ ise en etkin ayırıcı düzleme en yakın iki sınıfa ait örneklerden geçen destek vektörlerini temsil etmektedir. Doğrusal DVM'de temel amaç, mümkün olan en geniş açıklığı (m) bulmak ve problem örneklerini ait oldukları sınıfa ayırmaktır. Doğrusal bir şekilde sınıflandırılabilen örnekler arasındaki açıklık (marjin), $2/\|w\|$ olarak ifade edilmiştir. Mümkün olan en geniş açıklığa ulaşmak için $\|w\|$ değerinin alabileceği en küçük değeri alması gerektiği görülmektedir. Bu değer aşağıda verilen (3.27) numaralı bağıntıdaki optimizasyon probleminin çözümü ile elde edilmektedir [47].

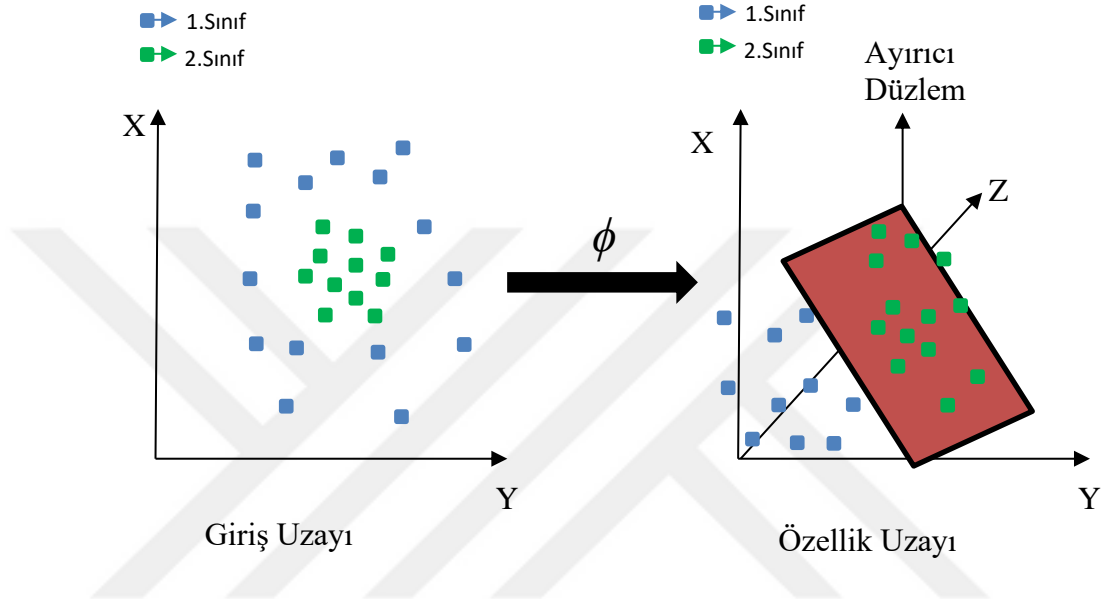
$$\min \frac{1}{2} \|w\|^2 \quad \rightarrow \quad y_i(wx_i + b) \geq 1 \quad (3.27)$$

3.6.3.2 Doğrusal olmayan destek vektör makineleri

Problem verilerinin doğrusal olarak dağılım göstermediği bazı durumlar olabilmektedir. Bu gibi durumlarda dairesel ve polinom eğriler yardımıyla ilgili problem örnekleri sınıflandırılabilir. Fakat kimi zaman sınıflandırmada uygun eğrileri bulmak güçleşebilmektedir. Bu problemin çözümü için V. Vapnik ve arkadaşları doğrusal bir şekilde sınıflandırmanın yetersiz kaldığı problemler için kernel (çekirdek) fonksiyonu kullanımını önermişlerdir. Bu sayede doğrusal olmayan

problem örneklerinin de çekirdek fonksiyonu yardımıyla sınıflandırılabileceğini belirtmişlerdir [47, 48].

Problem örneklerinin doğrusal şekilde ayrılamadığı durumda, doğrusal olmayan ve kernel adı verilen ϕ çekirdek fonksiyonu kullanılarak, örnek verileri özellik düzlemine dönüştürmektedir. Bu dönüşüm ile giriş örnek verileri daha yüksek boyuta taşınmaktadır. Bu dönüşümü ifade eden gösterim şekil 3.18’de verilmiştir.



Şekil 3.18: Çekirdek fonksiyonu yardımı ile örneklerin daha yüksek boyuta dönüştürülmesi.

Bu şekilde örnek verilerin bir üst uzaya dönüştürülmesi sonucunda en iyi ayrılcı düzlem ifademiz aşağıda (3.28) numaralı bağıntıdaki gibi ifade edilmektedir.

$$f(x) = \text{sgn}\left(\sum_{j=1}^n \alpha_j y_j K(x_j, x_k) + b\right) \quad (3.28)$$

Bu bağıntıda α_j Lagrange çarpanlarını ve $K(x_j, x_k)$ de örnek verilerinin bir üst uzaya dönüştürülmesi için kullanılan çekirdek (kernel) fonksiyonunu temsil etmektedir. DVM'nin sınıflandırmadaki performansı çekirdek fonksiyonlarının çeşidine ve aynı zamanda parametre seçimi gibi faktörlere göre değişiklik göstermektedir [47, 48].

Destek vektör makinelerinde kullanımının yaygın olduğu bazı çekirdek fonksiyonları aşağıda verilen çizelgede listelenmiştir. Burada verilen çekirdek fonksiyonlarının bağıntılarındaki b ve a çekirdek davranışlarını tanımlayan parametrelerdir.

Çizelge 3.5 : DVM çekirdek fonksiyonlarından bazıları.

Fonksiyon	Açıklama
$K(x_i, x_j) = (x_i x_j + a)^b$	Polinom Çekirdek Fonksiyonu.
$K(x_i, x_j) = \tanh(ax_i x_j - b)$	Sigmoid Çekirdek Fonksiyonu.
$K(x_i, x_j) = x_i^T x_j$	Doğrusal Çekirdek Fonksiyonu.

3.6.4 k -en yakın komşu

Yakın komşu (YK) yönteminin literatürde ilk olarak Cover ve Hart tarafından 1967’de önerilmiştir [49]. Önerilen bu çalışmada YK test verilerinin sınıflandırmasını gerçekleştiren bir örüntü sınıflandırma algoritması olarak kullanılmıştır. Bu yöntemin uygulamadaki kolaylığı ve başarılı sonuçlar sunması, YK algoritmasının birçok uygulamada tercih edilmesine neden olmuştur ve bu yöntem üzerinde zamanla birçok iyileştirme yapılmıştır. Yakın komşuluk yöntemi veri madenciliği, nesne ve örüntü tanıma gibi bir çok alanda uygulanmıştır [50].

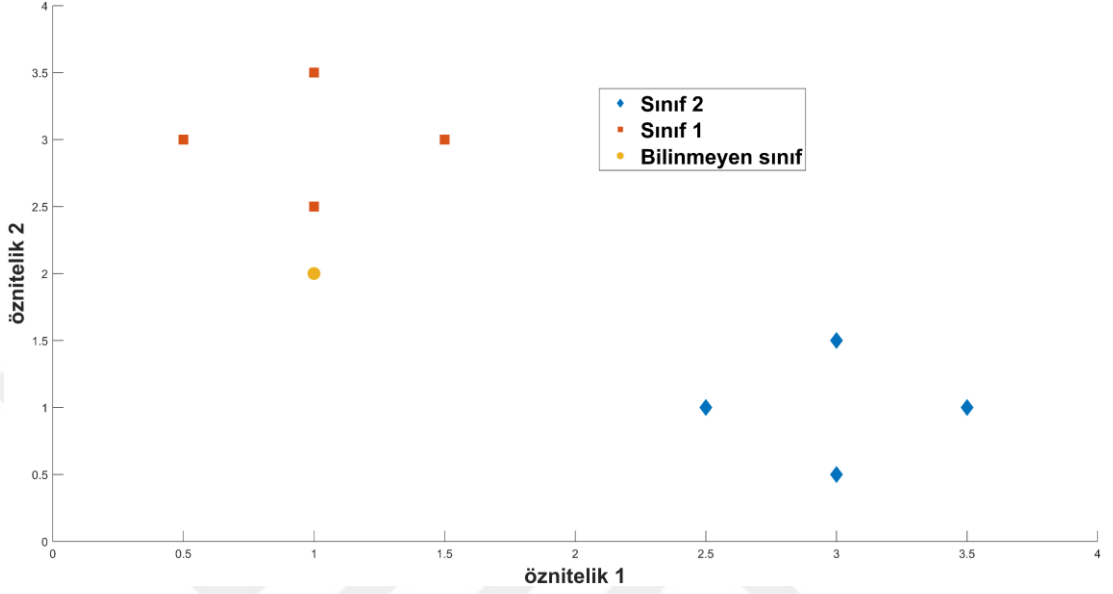
YK algoritmasındaki temel amaç, test verisindeki örneği eğitim setine göre en benzer örneğin ait olduğu sınıfa atmak olarak tanımlanabilir. Bu yöntemde kullanılan verilerin arasındaki benzerlik ölçüsü, belirlenen uzaklık ölçüsü fonksiyonu aracılığıyla belirlenmektedir. Örnekler arasındaki benzerlik ölçüsünü belirlemek için yaygın olarak kullanılan fonksiyon aşağıdaki (3.29) numaralı bağıntıda verilen Öklid uzaklık ölçüsü fonksiyonudur.

$$d(a, b) = \sqrt{\sum_{k=1}^m (a_k - b_k)^2} \quad (3.29)$$

Burada a_k a verisinin k ’inci özellik vektörünü, a ve b örnekleri, d ise Öklid uzaklığını ifade etmektedir.

Basit bir örnek uygulama ile YK algoritmasının anlatımı, kavram açısından daha açıklayıcı olacaktır. Örnek setinde 2 sınıf olsun ve her sınıf 4 adet örnekten oluştuğu kabul edilirse. Veri setindeki örneklerin üç boyutlu gösterimi her bir örnek için, $\mathbf{x}_1(1,2.5,1)$, $\mathbf{x}_2(0.5,3,1)$, $\mathbf{x}_3(1,3.5,1)$, $\mathbf{x}_4(1.5,3,1)$, $\mathbf{x}_5(2.5,1,2)$, $\mathbf{x}_6(3,0.5,2)$, $\mathbf{x}_7(3,1.5,2)$ ve

$x_8(3.5,1,2)$ şeklinde olacaktır. Burada x 'ler örnekleri, x örneklerinin ilk iki boyutu öznitelikleri üçüncü boyutu da örneklerin ait olduğu sınıfı temsil etmektedir. Verilen bu örneklerin iki boyutlu düzlemdeki dağılımını gösterir grafik aşağıdaki şekilde verilmiştir.



Şekil 3.19 : Örneklere ait öznitelik vektörlerinin dağılımı.

Şekil 3.19'da sarı daire ile verilen $b(1,2,?)$ örneğinin ise sınıfı bilinmeyen örnektir. YK yöntemi ile bu örnek ve diğer örnek arasındaki uzaklık, Öklid uzaklığı kullanılarak hesaplanmalıdır. Bu örnek ile eğitim setindeki tüm örnekler arasındaki Öklid uzaklığının hesaplanmasının ardından sınıfı bilinmeyen bu örnek, eğitim setindeki örneklerden Öklid uzaklığı en yakın olan örneğin sınıfına atılır. Yukarıda şekilde ve verilen örneklerin özellik vektörlerine bakıldığında, b örneğinin Öklid uzaklığının en yakın olduğu sınıf, 1 olarak etiketlenen sınıftır ve Öklid uzaklığı en yakın olduğu örnek ise x_1 olup bu uzaklığın hesabı ise aşağıdaki bağıntıda verilmiştir.

$$d(b, x_1) = \sqrt{(1 - 1)^2 + (2 - 2.5)^2} \cong 0.63 \quad (3.30)$$

Sonuç olarak b örneği YK yöntemi ile kendini temsil eden 1 ile etiketlenen sınıfa atanır.

k -En Yakın Komşu (k -NN) algoritması, sınıflandırma problemlerinde kullanılan bir algoritmadır. Yakın komşuluk algoritmasının bir özel durumudur. YK algoritmasında, sınıfı bilinmeyen bir verinin sınıfı, en yakın komşularının sınıflarına göre tahmin edilmektedir. Ancak k -NN algoritmasında ise, sınıfı bilinmeyen bir verinin sınıfı, en

yakın k komşularının sınıflarına göre tahmin edilir. Buradaki k değeri, en yakın komşuların sayısını temsil etmektedir. Temeli benzerlik kavramına dayanan k -NN algoritmasında, sınıfı bilinmeyen bir örneğin, en yakın komşuları ile benzerlik derecesi hesaplanır. Daha sonra komşuların çoğunluğunun dahil olduğu sınıfa, sınıfı bilinmeyen örneğin ataması gerçekleştirilir.

Farklı alanlara uygulanabilirliği ve algoritmasının uygulanmasındaki basitlikten dolayı k -NN algoritması, farklı birçok problemde uygulanmıştır ve k -NN üzerinde birçok iyileştirmeler yapılmıştır.

K -NN algoritması, kullanıcı tarafından seçilen k komşu sayısı, uzaklık ölçüsü ve eğitim veri seti gibi parametrelere bağlıdır. Bu parametrelerin optimizasyonu ve etkisi için yapılan çalışmalardan bazıları aşağıda verilmiştir.

- Farklı k değerlerinin, eğitim seti boyutlarının ve uzaklık ölçülerinin sınıflandırma doğruluğu üzerindeki etkisi test edilmiştir [51].
- Veri setinin az sayıda sınıfa ve her sınıfın farklı sayıda örneğe sahip olduğu durumlarda k -NN algoritmasının bazı eksiklikleri olduğunu belirtilmiştir [52].
- Bulanık k -en yakın komşu algoritması önerilmiştir [53].
- Test setindeki örnekler için her sınıftan en yakın k komşusu seçilmiş ve ağırlıklı k -NN yöntemi önerilmiştir [54].

k -NN algoritmasında uzaklık ölçüsü bu yöntemin önemli bir parametresi olmuştur ve bu uzaklık ölçüsü içinde çeşitli çalışmalar yapılmıştır. Todeschini literatürdeki yaygın kullanımı olan Öklid uzaklığı fonksiyonunun alternatifi için farklı uzaklık fonksiyonlarının kullanımı sonucunda, sınıflandırma performansına etkilerini analiz etmiştir [55]. Yaptığı çalışma sonucunda farklı uzaklık fonksiyonlarının sınıflandırma doğruluğu üzerinde doğrudan etkisini belirtmiştir. k -NN'de uzaklık hesabı işlemlerinin bu yöntemde en çok zaman alan süreçler olduğu belirtilmiştir. Belkasim ve arkadaşları bu süreyi azaltmak için bir yöntem önermişlerdir. Ayrıca doğruluk değerini artırmak için uzaklık ölçüm fonksiyonu olarak, Weinberger ve diğerleri Mahalanobis uzaklık fonksiyonunu önermişlerdir [56]. Basit uyarlanabilir uzaklık ölçüsü öneren Wang ve diğerleri çalışmalarında sınıflandırma performansının artırılmasını amaçlamışlardır. Wang ve diğerleri sınıflandırma performansını artırmak için basit bir uyarlanabilir uzaklık ölçütü önermişlerdir [57].

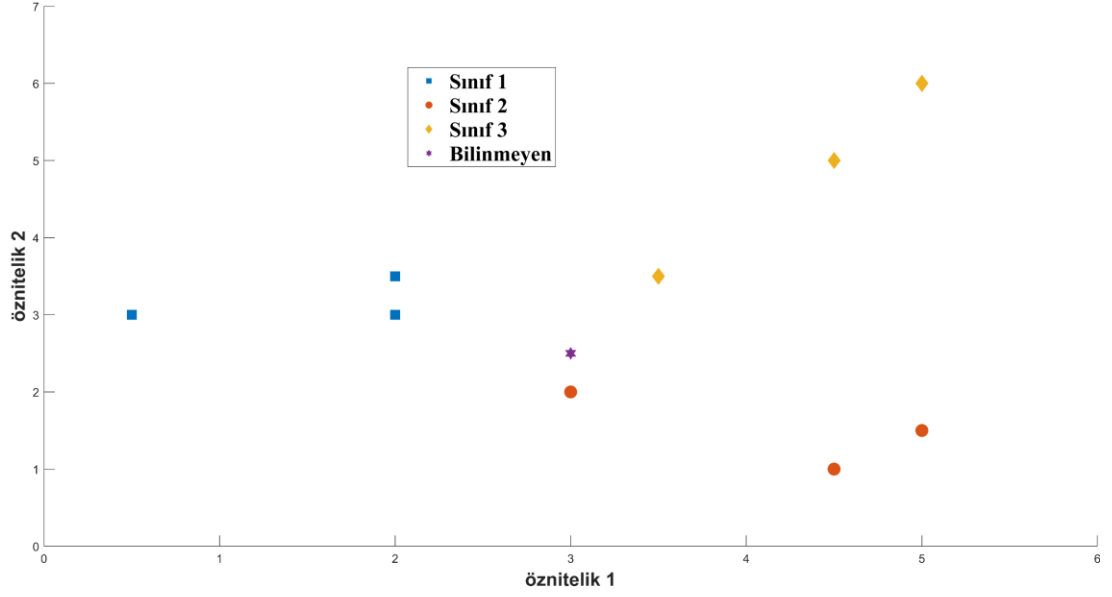
k -NN sınıflandırma algoritmasında k komşuluk değeri bu yöntemin doğruluğunu etkileyen önemli bir parametredir. Yapılan çalışmalarda k komşuluk sayısının seçimi için birçok yöntem önerilmiştir, fakat en doğru k komşuluk sayısı farklı k komşuluk sayılarının test edilmesi ile belirlenebilmektedir [58].

Yukarıda YK algoritmasında olduğu gibi k -NN algoritmasında bir örnekle somutlaştırmak, kavrama açısından daha etkili olacaktır. Verilecek örnek ile farklı komşuluk sayısı için sınıflandırmanın değişimi görülmüş olunacaktır. Örnekte kullanılacak sentetik veri seti aşağıda çizelge 3.6'da verilmiştir. Bu örnek veri setinde her biri iki özneliğe sahip 9 örnekten ve 3 sınıftan oluşmaktadır.

Çizelge 3.6 : k -NN için sentetik veri kümesi ve sınıfları.

Örnekler	Öznitelik 1	Öznitelik 2	Sınıf
x ₁	0.5	3	1
x ₂	2	3	1
x ₃	2	3.5	1
x ₄	3	2	2
x ₅	4.5	1	2
x ₆	5	1.5	2
x ₇	3.5	3.5	3
x ₈	4.5	5	3
x ₉	5	6	3

Yukarıda verilen sentetik örnek verilerine ait iki boyutlu uzayda dağılımları aşağıda şekil 3.20'de verilmiştir. Ayrıca öznelik 1 değeri 3, öznelik 2 değeri 2.5 olan ve sınıfı bilinmeyen Y örneği şekilde verilmiştir. Bu örnek yukarıda çizelge 3.6'da verilen eğitim seti aracılığıyla sınıflandırılmaya çalışılmıştır.



Şekil 3.20: k -NN örneği için verilen öz niteliklerin dağılım grafiği.

Sınıflandırmanın ilk adımında bilinmeyen örnek Y ile eğitim setindeki tüm örnek verileri arasındaki uzaklıklar, Öklid uzaklığı fonksiyonu aracılığıyla hesaplanmıştır. Hesaplanan bu değerler çizelge 3.7’de verilmiştir.

Çizelge 3.7 : Y bilinmeyen örnek ile eğitim seti arasındaki Öklid uzaklıkları.

Örnekler	Öklid uzaklığı	Yakınlık sırası
x_1	2.55	6
x_2	1.12	2
x_3	1.41	3
x_4	0.5	1
x_5	2.12	4
x_6	2.24	5
x_7	1.12	2
x_8	2.92	7
x_9	4.03	8

Öklid uzaklıklarının hesaplanmasının ardından bilinmeyen örnek Y için belirlenen k komşuluk değerlerine göre sınıfı belirlenir. Burada en önemli hususlardan biri farklı komşuluk değerleri için Y ’nin atanacağı sınıflardır. Bu örnek için k komşuluk değerleri 1, 4 ve 6 olarak belirlenmiştir ve bu k komşuluk değerlerine göre Y bilinmeyen örnek için atanan sınıfları gösteren çizelge aşağıda verilmiştir.

Çizelge 3.8: k komşuluk değerine göre Y 'nin en yakın komşuları.

k komşuluk değeri	En yakın komşular
$k = 1$	x_4
$k = 4$	x_2, x_3, x_4, x_7
$k = 6$	$x_2, x_3, x_4, x_5, x_6, x_7$

En yakın komşu değeri $k = 1$ olduğu durumda, Y 'nin en yakın komşusu x_4 olmuştur ve x_4 sınıf 2'de olduğundan Y 'nin sınıfı, sınıf 2 olarak atanır. k komşuluk değerinin 4 olduğu durumda en yakın komşular x_4, x_2, x_7, x_3 olmuştur ve çoğunluk komşuluk (x_2 ve x_3 aynı sınıfta olduğundan) sınıf 1'de olduğundan Y bilinmeyen örneği bu sınıfa atanır. Son olarak k komşuluk değeri 6 olduğu durumda en yakın komşular $x_2, x_3, x_4, x_5, x_6, x_7$ olmuştur ve Y bu durumda, x_4, x_5, x_6 ün dahil olduğu ve çoğunluk komşuluğa sahip sınıf olan sınıf 2'ye atanmıştır.

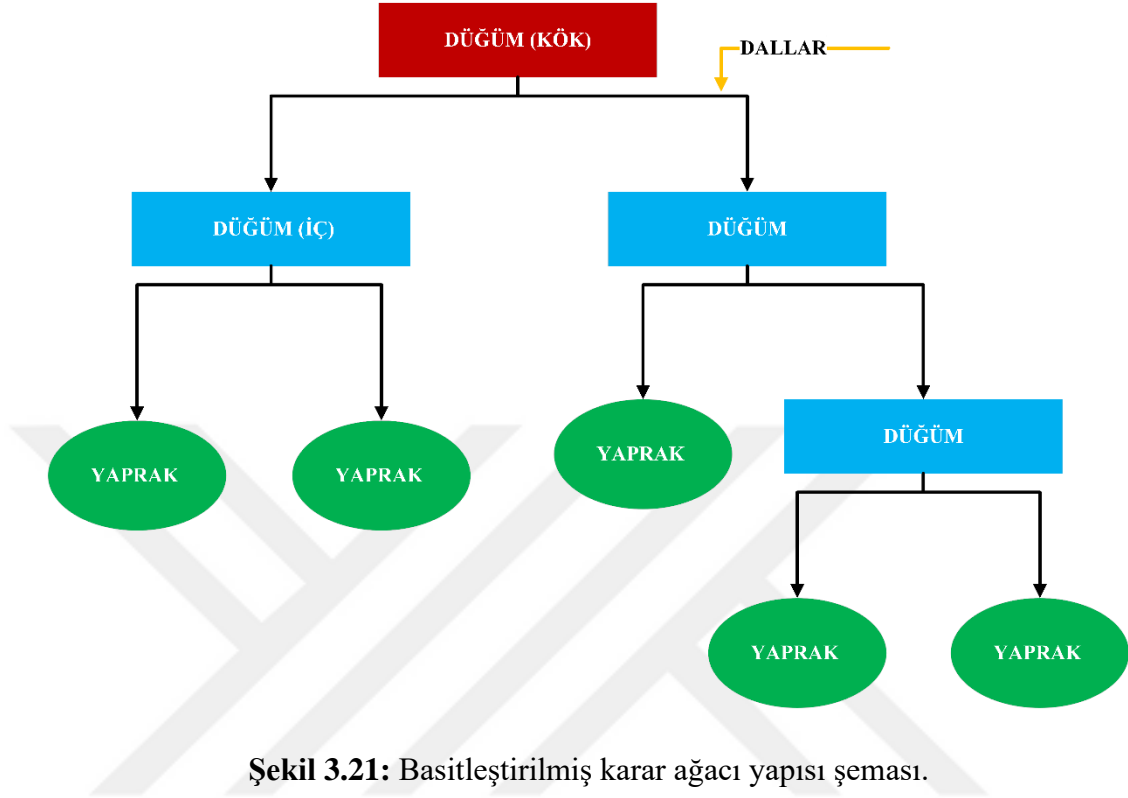
Yukarıda verilen örnek uygulama ışığında doğru k komşuluk değeri seçiminin, k -NN algoritmasında sınıflandırma açısından hayati bir konumda olduğu görülmüştür. Farklı komşuluk değeri seçimi bilinmeyen örneğin farklı sınıflara sınıflandırılabileceği yukarıda açıkça gösterilmiştir.

3.6.5 Karar ağacı

Karar ağacı (KA), ağaç yapısında model oluşturarak problem örneklerini sınıflandırmada yaygın olarak kullanılan bir sınıflandırma metodudur. Bu yöntem "koşul sonuç" mantığına dayalı olarak uygulanabilen bir sınıflandırıcıdır [59]. KA kolay şekillendirilebilir, anlaşılır ve kolay yorumlanabilir özelliklerinden dolayı diğer yöntemlere göre bazı avantajlar sunmaktadır. Bu yöntemde örneklerden elde edilen veri seti kullanılarak bir ağaç yapısı oluşturulur. Daha sonra bilinmeyen örnekler bu oluşturulan yapıya göre belli kurallar dizisine uygun sınıflandırılır. Diğer bir ifadeyle, eğitim için kullanılan veri setinin kullanımıyla eğitilen karar ağacının, sınıfı bilinmeyen bir veriyle karşılaştığında, eğitimde üretilen kural setine göre bu örneğin sınıfının tahmin edilmesi şeklinde ifade edilebilir. Ayrım özellikleri yüksek kaliteli veriler üzerinde eğitilirse, karar ağaçları çok doğru sınıflandırma yapabilen bir yöntemdir [60].

Karar ağacı algoritmasının oluşturduğu model biçim bakımından bir ağacı çağrıştırdığından dolayı, karar ağacı olarak adlandırılmaktadır. KA ana yapısı, kök

düğümü, dallar, iç düğümler, terminal düğümleri ve çıktı etiketinin barındıran yaprakтан oluşmaktadır. Bir karar ağacının basitleştirilmiş görseli aşağıda şekil 3.21’de verilmiştir.



Şekil 3.21: Basitleştirilmiş karar ağacı yapısı şeması.

Karar ağacında örnek verilerinin işlendiği yer kök düğümüdür. KA örneklerin sınıflandırması kök düğümünden başlar ve ağacın uç noktası olan yaprak düğümünde son bulur [61]. Problem verileri birbirine çok yakın olduğu bir durumda hepsi aynı sınıfa sınıflandırılacağından, kök düğüm dallanma yaparak dallara ayrılmadan tüm örnek verilerin aynı sınıfa atanması ile süreç sonlanacaktır. Böylece kök düğüm, direkt yaprak düğümüne ulaşır. Fakat problem verilerinin farklı özellikler barındırdığı durumda, oluşacak karar ağacının kök düğümü sınıflandırma için iki veya daha çok dala ayrılacaktır. Düğüm ayırma yaparken en ayırıcı değişkene göre dallara ayrılır ve bu nedenle ilgili değişken adıyla etiketlenir. Karar verici bu değişkene göre, sınıf içinde türdeş dağılan veriler ve sınıflar arasında çok türlü veriler barındıran yeni iç düğümler oluşturur. Yeni oluşan bu iç düğümler kapsadığı örnek verileri en doğru şekilde sınıflayabilecek başka bir ayırıcı değişkene göre yeniden dallanmalara ayrılır. Bu süreçler dallanma için ayırıcı bir değer bulunmayana kadar devam eder [62]. Karar ağacının dallanmamış son düğümü terminal düğümü olarak adlandırılmaktadır. Yaprak düğümündeki değer ise problem verisinin sınıflandırıldığı etiketi

göstermektedir. Karar ağacının farklı yaprak düğümündeki aynı sınıfa sınıflandırılan örnekler olabilir, fakat bu örnekler her bir yaprak için farklı bir sınıflandırma kuralını göstermektedir.

Karar ağaçları, bir çıktı sınıfı ve bu sınıfı temsil eden girdi değişkenlerinden oluşmaktadır. Bu ağaçlar, sonuç kararlarını ve kararların açıklamalarını içeren akış şemaları sunarlar. Karar ağaçları, pek çok karşılaştırmalı test kullanarak, giriş verisinin sınıfını tahmin etmek için en iyi ayırıcı değişken sırasını bulmaya çalışmaktadır. Bu sıralama, giriş verisini etiketlenecek sınıflarına ayırırken etkili olan değişkenlerin önem sırasını temsil eder. Başlangıç düğümü olan kök düğümünden hedef yaprağa giden her yol, gözlemleri "eğer-sonra" (if-then) koşullu yapısını kullanarak sınıflandırır [63]. Bu yapı, bir koşulun doğru olması durumunda hangi sınıfın atanacağını belirler. Karar ağaçları, yapay öğrenme içerisinde sınıflandırma algoritmaları açısından en kolay ve anlaşılır olanlardandır.

Karar ağaçlarının oluşturulmasındaki en önemli adım, veri setindeki değişkenlerin sınıflandırılmasını sağlayacak dallanmanın hangi kriter ya da hangi değişken için yapılacağını belirlemesidir. Bu aşamada belirsizliği en yüksek olan değişken belirlenir ve ağacın kök düğümünde test için kullanılır. Bunu belirlemek için geliştirilen literatürde farklı yaklaşımlar bulunmaktadır. En önemli yaklaşımlar; entropi, bilgi kazancı ve bilgi kazancı oranına dayalı [64, 65], Twoing kuralı[66], Gini kriteri [66], Chi-kare olasılığıdır [67,68].

Karar ağacı yöntemleri, temel olarak cevap değişkenini açıklayıcı değişkenlere göre sınıflandırma mantığına dayanır. Bu yöntemler, farklı amaçlara hizmet eden farklı algoritmalar içerir. İlk ağaç tabanlı uygulamalar, AID (ing. automatic interaction detector) algoritması ile başlamıştır [69]. Daha sonra, bu temel algoritmanın üzerine ek algoritmalar geliştirilmiştir. Geliştirilen bu algoritmalar aşağıda verilen Çizelge 3.9'daki gibi sıralanabilir.

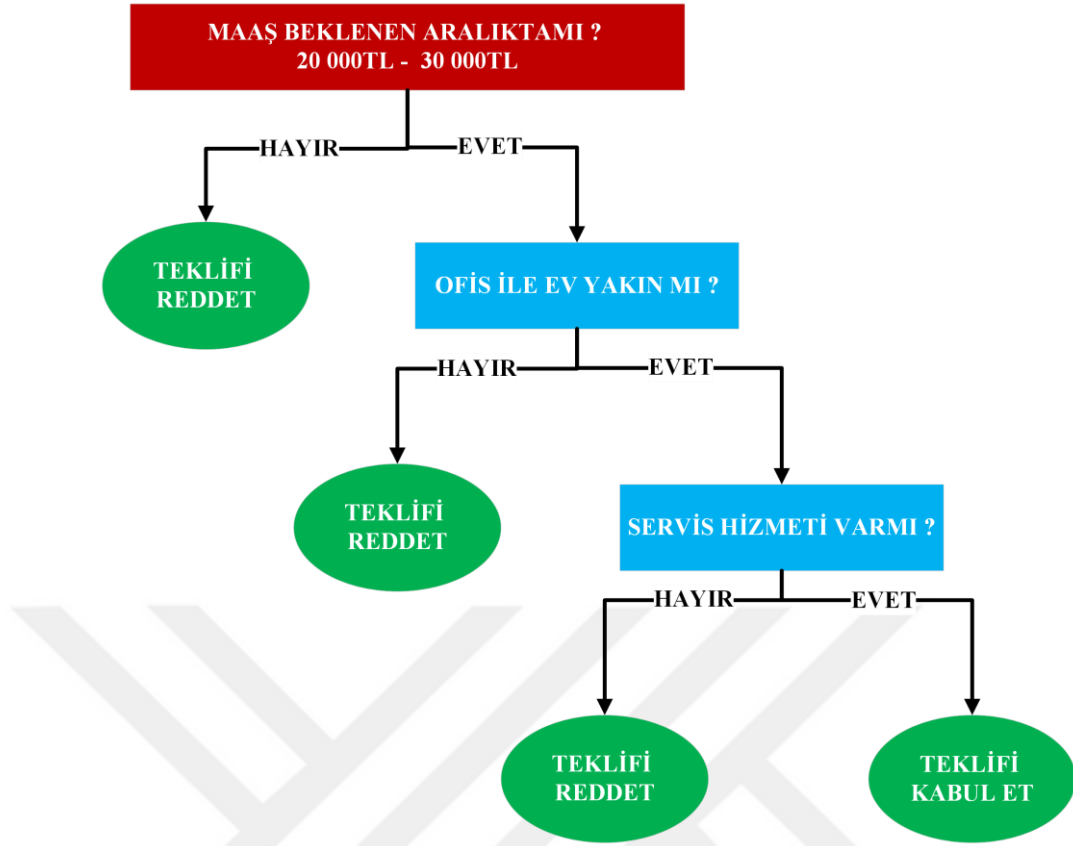
Karar ağacı yönteminin sınıflandırma açısından işleyişini somutlaştırmak için bir örnek verilmesi kavramsal açıdan daha faydalı olacaktır. Bir iş teklifini değerlendirmek için, bireyin teklifi karar ağacı mantığıyla değerlendirmesini içeren yapı aşağıdaki şekilde verilmiştir.

Şekil 3.22’de verilen karar ağacı modelinde maaş beklenti aralığı değişkeni teklifi kabul etme açısından en etkili değişken olarak belirlenmiştir. Bu değişken şekilde de görüldüğü gibi kök değişken olarak belirlenmiştir.

Çizelge 3.9 : KA için geliştirilen algoritmalar.

Algoritma	Kaynak
CART	[66]
CHAID	[67]
Exhaustive CHAID	[70]
QUEST	[71]
Random Forest	[42]
C4.5	[64,72]
C5	[64,72]
ID3 tree	[73]
J48 tree	[74]
CAL5	[75]
Rotation Tree	[76]
MARS	[77]
Increased trees	[78]
SLIQ	[79]
SPRINT	[79]

Bu durumda teklifin kabul edilip edilmeyeceğini belirlemede en etkili değişkenin maaş miktarı olduğunu göstermektedir. Bu örnekteki algoritma, karar ağacında teklifin maaş aralığında olmadığı durumda sola (HAYIR) dallandırmıştır ve giriş verisini teklifi reddet olarak etiketleyerek dallanmayı sonlandırmıştır. Ağacın kök düğümünden sonraki ilk sağ dallanmada ise ofis ile ev arası mesafenin sınıflandırmada ayırıcı faktörünün devreye girdiği görülmektedir. Daha sonra son yanıt değişkeni olan servis hizmetinin karar verme açısından bir başka etkin faktör olduğu görülmektedir. Bu şekilde basit bir KA yapısının ise-yap (if-then) mantığına dayalı, gelen teklifleri sınıflandıran yapısı basit olarak örneklendirilmiştir.



Şekil 3.22: İş teklifi için oluşturulan basit bir KA yapısı örneği.

3.6.6 Çapraz doğrulama

İstatistik veya yapay öğrenmede temel amaç, mevcut örnek verilerinden sınıflandırma modeli oluşturmaktır. Böyle bir model bir regresyon modeli veya bir sınıflandırıcı olabilir. Bu tür sınıflandırma modelin performans değerlendirilmesi, eğitim verilerinde yeterli tahmin yeteneğini gösterebilir, ancak eğitim haricinde görünmeyen gelecek örnek verileri tahmin etmekte başarısız sonuçlar verebilir. Bu açıdan çapraz doğrulama (ÇD), sınıflandırıcı modelinin sınıflandırmadaki genelleme performansı hakkında tahmin açısından bilgi verici bir yöntemdir [80].

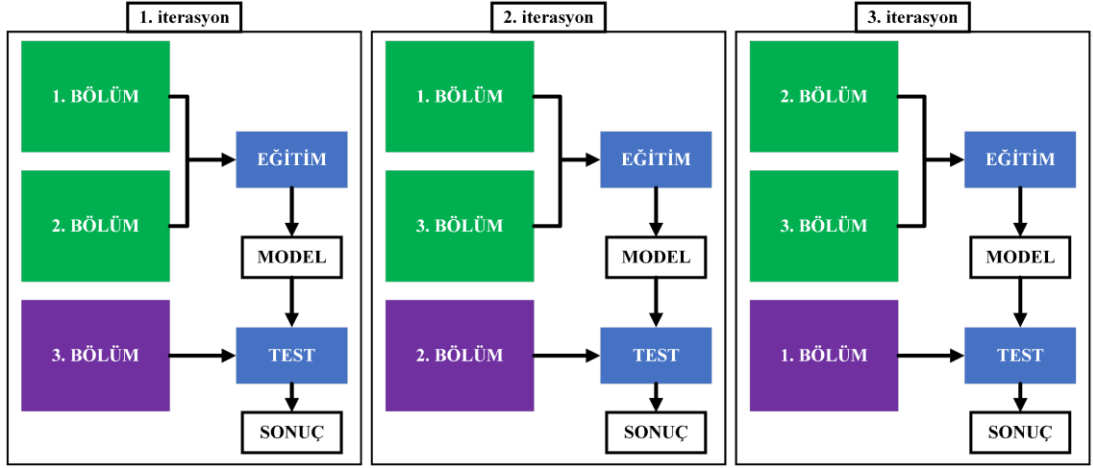
Çapraz doğrulama, öğrenme algoritmalarını değerlendirmek ve karşılaştırmak için, bir modeli öğrenmek veya eğitmek için kullanılırken, diğeri modeli doğrulamak için kullanılmak üzere örnek verilerini iki segmente ayıran istatistiksel bir yöntemdir. Temel olarak çapraz doğrulamada, eğitim ve doğrulama süreçleri birbirini takip eden değişimlerde adımlardır. Bu sayede her bir veri örneği doğrulama aşamasında modelin performansının değerlendirilmesi sürecine dahil olmaktadır. En temel çapraz doğrulama yöntemi k-Katmanlı Çapraz Doğrulama (k-KÇD) yöntemidir. k-KÇD

yönteminin haricindeki diğer ÇD yöntemleri, k-KÇD yönteminin farklı özel durumlarıdır veya k-KÇD'nin tekrarlanan süreçlerini içermektedirler [81].


K-katlı çapraz doğrulamada, veri önce k sayıda eşit (eşite yakın) büyüklükteki parçalara veya kata bölünmektedir. Daha sonra, her bir farklı iterasyonda örnek verinin farklı bir parçası (bölümü) doğrulama için ayrılmaktadır. Geriye kalan $k - 1$ parça ise eğitim için kullanılmaktadır [81]. Aşağıda şekil 3.23'te k değeri 3 olan k-KÇD yönteminin bir örneğini temsil etmektedir. Şekilde örnek verinin yeşil blokları eğitimde kullanılırken, mor renkle gösterilen bloklar doğrulama için kullanılmaktadır. Çapraz doğrulama yönteminde, eğitim algoritmalarını veya bunları karşılaştırmak için şöyle bir süreç gerçekleştirilir: her bir iterasyonda bir veya daha çok öğrenme algoritması $k-1$ kat bölümdeki örnek verilerini kullanarak modeli eğitir ve ardından eğitilen model doğrulama bölümündeki örnek veriler kullanılarak modelin tahminde bulunulması istenir. Tercih edilen eğitim algoritmasının her iterasyondaki performansı, doğruluk ölçütü gibi ön belirlemeli performans ölçütü ile takip edilir. Modelin tüm eğitim ve doğrulama süreçleri tüm iterasyonlar için tamamlandığında, her bir algoritma için k adet performans ölçütü sonucu elde edilir. Bu ölçütlerden birleşik bir performans ölçütü elde etmek için her iterasyon için elde edilen performans ölçütünün ortalaması gibi farklı yöntemler kullanılmaktadır. Bu değer sonucunda kullanılan algoritmaların diğerlerine göre üstünlüğünün analizi gerçekleştirilmektedir [81].

3.6.6.1 Birini dışarıda bırak çapraz doğrulama

Birini dışarıda bırak çapraz doğrulama (BDBÇD) yöntemi, k katlı çapraz doğrulama yönteminin özel bir halidir, bu yöntemde k kat (bölüm) değeri örnek sayısına eşittir. Bir başka söylemlle ifade edilirse, her bir iterasyonda bir örnek haricinde kalan tüm veri eğitim için kullanılır ve oluşturulan model hariç tutulan o örnek kullanılarak test edilmektedir. Veri setinin az veya kısıtlı olduğu durumlarda etkili olan bu yöntem, bir çok çalışmada sınıflandırıcıların performans değerlendirmesinde uygulanmıştır [82]. Birini dışarıda bırak ÇD kullanılarak eğitilen modelin doğruluk tahmini neredeyse önyargısız bilinmektedir, ancak yüksek varyansa sahip olduğundan dolayı güvenilmez tahminlere sebep olabileceği belirtilmiştir [83]. Dört örnekten oluşan bir modele birini dışarıda bırak ÇD yönteminin uygulanışını temsil eden şematik gösterim şekil 3.24'te verilmiştir.



Şekil 3.23: k -KÇD yönteminin adımlarının blok gösterimi.



Şekil 3.24: Dört örnekten oluşan bir modelin birini dışarda bırak çapraz doğrulama blok şeması.

Yukarıdaki şekilde görüldüğü gibi, bu çapraz doğrulama yöntemi her bir iterasyonda veri setinin bir örneğini test için ayırır ve kalan örneklerle modeli eğitir. Ardından ayırdığı örneği kullanarak modelin performansını değerlendirmektedir. Bu tür bir doğrulama yönteminin, K sayıda iterasyonunun her biri için bir doğruluk hesaplaması yapılmaktadır. Nihai doğruluk değeri için aşağıda verilen denklem kullanılarak, elde edilen K tane doğruluk değerinin aritmetik ortalamasından elde edildiği belirtilmektedir.

$$\text{doğruluk} = \frac{1}{K} \sum_{k=1}^K d_k \quad (3.31)$$

Buradaki d_k her bir iterasyondaki doğruluk değerini ifade etmektedir.

3.6.7 ReliefF özellik seçim algoritması

Neredeyse her sınıflandırma veya yapay öğrenme süreçlerinin temel zorluğu, problem verilerindeki bir veya birden fazla öznitelik arasındaki ilişkileri karakterize etmek ve özellikler arasındaki ilişkileri belirlemek olmaktadır. Örnek verilerini barındıran çoğu veri setinde, ilgili özellikler mevcut özelliklerin bir alt kümesidir. Bunlar sınıf değerini belirleyen bilgileri içermektedir. Bu özelliklerin haricinde geriye kalan problemi temsil etme yönünden ilgisiz özellikler, bilgilendirici olmayan ve aynı zamanda model yapısının genel boyutunu artıran özelliklerdir. Bu durum, sınıflandırma modellerinin zorluğunu ve hesaplama yükünü arttıran bir etmendir. Belirtilen bu sonuçların azaltılması ve ilgisiz özelliklerin modelden arındırılması işlemi özellik seçimi olarak adlandırılmaktadır. Genel tanımla, özellik seçimi ilgili özellikleri belirleme ve ilgisiz olanları eleme süreci olarak tanımlanabilir [84].

Özellik seçimi algoritmalarından biri olan Relief algoritması, Kira ve Rendell [85] tarafından örneklere dayalı öğrenmeden esinlenerek [86], orijinal Relief algoritmasını önermişlerdir. ReliefF algoritması ise Relief algoritmasının bir uzantısı olarak geliştirilmiştir ve ilk olarak Kononenko tarafından önerilmiştir [87]. ReliefF algoritması daha sonra bir çok araştırmacı tarafından uygulanmış, çeşitli uzantılar ve iyileştirmeler önerilmiştir [85, 88–90].

Bu tez çalışmasında da kullanılan ReliefF özellik seçimi algoritmasının temel fikri, örnek özniteliklerinin kalitesini, yerel bir komşulukta problem örneklerini bir sınıftan diğerine sınıflandırabilme yeteneklerine göre değerlendirmek olarak söylenebilir. Yani problem için ayırt edilebilirlik açısından en iyi özellikler, farklı sınıfa dahil örnekleri arasındaki uzaklığı arttırmada daha fazla katkıda bulunurken aynı sınıfa dahil örnekler arasındaki uzaklığı arttırmada etkisi daha az olan özelliklerdir. Bu algoritma yukarıda belirttiği gibi, Relief algoritmasının çoklu sınıfın bulunduğu, eksik örnek veri ve gürültülü örneklerin olduğu veri setlerine uygulanan bir uzantısıdır.

ReliefF (Relief-F) özellik seçim algoritmasının sözde kodu şekil 3.25'te verilmiştir. ReliefF algoritması iki sınıflı uygulamalarla sınırlı olmadığı gibi, eksik ve gürültü içeren verilere karşıda dirençli bir yöntemdir [87].

Girdi: Öznitelik ve sınıf değerleri vektörü

Çıktı: Özniteliklerin tahmin değerlerini içeren W vektörü.

1. Tüm ağırlıkların başlangıç değerlerini ata $W[A] := 0.0$;
2. **for** $i := 1$ **to** m **do begin**
3. Rastgele R_i değeri seç;
4. k adet en yakın isabetleri H_j ;
5. **for** her sınıf $C \neq \text{sınıf}(R_i)$ **do**
6. her sınıf için k adet hata değerini bul $M_j(C)$;
7. **for** $A := 1$ **to** a **do**
8. $W[A] := W[A] - \sum_{j=1}^k \frac{\text{diff}(A, R_i, H_j)}{m \cdot k} +$
9. $\frac{\frac{P(C)}{1-P(\text{sınıf}(R_i))} \sum_{j=1}^k \text{diff}(A, R_i, H_j)}{m \cdot k}$;
10. **end**

Şekil 3.25: ReliefF algoritmasının sözde kodu.


Bu yöntem Relief'e benzer şekilde, ReliefF, verisetinden herhangi bir R_i örneği seçer (satır 3), ardından aynı sınıfa dahil en yakın isabet H_j olarak isimlendirilen k tane yakın komşusunu bulmaya çalışır (satır 4). Ayrıca en yakın hatalar $M_j(C)$ olarak isimlendirilen ve farklı sınıflara ait örneklerden k tane en yakın komşusunu tarar (satır 5 ve 6). R_i rastgele seçilen örneği, H_j ve $M_j(C)$ hesaplanan değerlerine bağlı olarak örneğe ait tüm A öznitelikleri için $W[A]$ öznitelik ağırlık değerlerini günceller (satır 7, 8 ve 9). ReliefF in güncelleme formülü, uzantısı olduğu Relief algoritmasına tüm isabetlerin ve tüm hataların katkısının ortalamasının alındığı bağıntının eklenmesi ile benzeşmektedir. Hataların sınıflar için katkısı, o sınıfın önceki olasılığı olan $P(C)$ olasılığı ile ağırlıklandırılmaktadır. Bu algoritmadaki her adım için isabetlerin (H_j) ve hataların $M_j(C)$ katkılarının 0 ile 1 aralığında ve simetrik olması istenmektedir. Bu nedenden dolayı hatalara ait olasılık ağırlıklarının toplamının 1 gerekliliği sağlanmalıdır. İsalet sınıfının azlığından dolayı her bir olasılık ağırlığı $1 - P(\text{sınıf}(R_i))$ değerine bölünmelidir. Bu işlemler m adet olarak tekrarlanarak gerçekleştirilir.

k tane isabet ve hata seçimi Relief için temel farktır ve bu da algoritmanın gürültüye karşı daha dirençli olmasını sağlamaktadır. Kullanıcı tarafından tanımlanan k parametresi tahminlerin yerelliğini kontrol etmektedir. Çoğu uygulamada bu değerin 10 olarak seçilmesi güvenilir sonuçlar vermektedir [87,91].



4. FA SİSTEM ÇALIŞMALARI VE SONUÇLARI

Bu çalışmada kullanılan düzeneğin nihai özellikleri yukarıda materyal bölümünde verilmişti. Verilen çalışma düzeneğindeki sistem, gerçekleştirilen çalışmaların ve araştırmaların sonucunda elde edilen son tasarımı temsil etmektedir. Bu bölümde çalışma düzeneği için donanımla ilgili araştırma ve uygulama sonucu elde edilen donanıma bağlı bulgular ve sonuçlar işlenecektir.




Şekil 4.1: EPC9126 kartı ile kurulan çalışma düzeneği.

4.1 EPC9126 Lazer Sürücü Kartı

Tez çalışmasında ilk olarak hazır temin edilen EPC9126 lazer sürücü kartı kullanılarak FA sinyal elde edilmeye çalışılmıştır. Çalışma düzeneğinin gerekli elektriksel bağlantılarının yapılarak kurulmuş hali şekil 4.1’de verilmiştir. Çalışma düzeneğinin bileşenleri arasındaki ilişkiyi gösterir bloklar ve birbiri ile olan sinyal bağlantı ilişkilerini gösterir hiyerarşik düzen ise şekil 4.2’de verilmiştir. Şekil 4.2 ve şekil 4.1’de aynı numara ile etiketlenen bloklar aynı bileşeni temsil etmektedir.


Şekil 4.2’de görselde (1) numarası ile etiketlenen bileşen lazere, sürücü için kontrol sinyalinin üretilmesi ve osiloskop amacıyla kullanılan AD2’yi, (2) numarası ile etiketlenen bileşen EPC9126 lazer sürücü kartını, (3) numarası ile etiketlenen bileşen lazer diyotu ve (4) ile etiketlenen bileşen akustik sinyallerin algılanması için kullanılacak akustik algılayıcı elemanı temsil etmektedir.



Şekil 4.2: Çalışma düzeneği bileşenlerinin birbiriyle olan bağlantı ilişkileri.

Çalışma düzeneği bileşenlerinden AD2 osiloskop ve sinyal jeneratörü olarak, lazer diyot ve akustik algılayıcı mikrofon yaygın kullanımı olan bileşenlerdir. Çalışma düzeneğinin sistem performansı ve sinyal kalitesi üzerinde baskın etkisi olduğundan, lazer sürücü EPC9126 kartının teknik ve tasarım yapısından aşağıda ayrıca bilgi verilmiştir.

Lazer sürücüler genelde bir enerji kaynağına lazer ve yarı iletken anahtarlama elemanının seri bağlanması ile oluşturulan yapı kullanılmaktadır. Bu tezde ilk denemeler, şekil 4.2’de verilen EPC firmasının EPC9126 ürün kodlu geliştirme kartı ile gerçekleştirilmiştir. EPC9126 lazer sürücü kartı, kapasitif deşarj tasarım topolojisi temelinde tasarlanmıştır. Kapasitif deşarj topolojisi temelinde dayalı lazer sürücü tasarımının basitleştirilmiş şematığı ve zaman genlik grafiği aşağıda şekil 4.3’te verilmiştir. Şekil 4.3’te verilen sürücü şematığında Q_1 mosfetinin ideal anahtarlayıcı, D_L diyotunun ideal ve V_{DLF} sabit voltaj düşümüne sahip olduğu varsayılmıştır.



Şekil 4.3: Basitleştirilmiş kapasitif deşarj lazer sürücü şematığı (sol) ve zaman genlik grafiği (sağ)[92].

Şekil 4.3'te verilen sürücünün temel çalışma mantığı takip eden metinde anlatılmıştır. Q_1 mosfeti kesimdeyken kapalı durum geçerlidir. Kapalı durumda lazer üzerinden akan akım $\dot{I}_{DL} = 0$ olur ve C_1 kapasitörü R_{IN} direnci üzerinden $V_1 = V_{IN}$ olacak şekilde şarj olur. $t = t_0$ da, $V_{command}$ sinyali mosfet gate sürücüsünü tetikler. $t = t_1$ anında Q_1 mosfeti tamamen iletme geçer ve C_1 kondansatörü L_1 bobini ve D_L lazer diyotu üzerinden deşarj olur. C_1 ve L_1 rezonant ağ oluşturduğundan \dot{I}_{DL} ve V_{C1} sinüzoidal olarak salınır. Lazer diyotun ileri kutuplamadaki gerilim düşümünden dolayı, kondansatörün başlangıçtaki gerilim değeri $V_{C1,0} = V_{IN} - V_{DLF}$ olur. $t = t_2$ anında \dot{I}_{DL} lazer akımı sıfır olur ve $V_{C1} = 2V_{DLF} - V_{IN}$ 'e eşit olur. $t = t_2$ anında D_L lazer diyotu ters polarlamadan ötürü akımın ters yöne değişmesini engeller ve C_1 kapasitesi R_{IN} direnci üzerinden şarj olur. $t = t_3$ anında Q_1 mosfeti kapalı duruma geçer. Bir çevrim böylece tamamlanmış olur. Bu devredeki L_1 bobini lazer akımının aktığı yolun kaçak endüktansını ifade etmek için kullanılmıştır [92].

Kapasitör şarj zaman sabiti τ_{chrg} , akım darbe genişliği t_{wb} , devrenin karakteristik empedansı R_0 ve yarı-doruk genişliği (full width half maximum) t_w bağıntıları aşağıdaki 4.1- 4.4 numaralı bağıntılarda verilmiştir.

$$\tau_{chrg} = R_{IN}C_1 \quad (4.1)$$

$$t_{wb} = \pi\sqrt{(L_1C_1)} \quad (4.2)$$

$$R_0 = \sqrt{\frac{L_1}{C_1}} \quad (4.3)$$

$$t_w = \frac{2}{3}t_{wb} \quad (4.4)$$

EPC9126 [92] lazer sürücüsünün şematik tasarımı EK-A'da verilmiştir. EPC9126 lazer sürücü kartının tasarımı kapasitif deşarj topolojisine dayanmaktadır. EK-A'da verilen şematik incelenirse kondansatör şarj yolu, VBUS, R2 – R6 dirençleri, C10- C14 kapasiteleri R14 - R18 şönt dirençleri üzerinden oluştuğu görülmektedir. Deşarj yolu ise, R14- R18 şönt dirençleri, C10 - C14 kapasiteleri, lazer diyot (U2) ve Q1 mosfeti üzerinden oluşmaktadır.

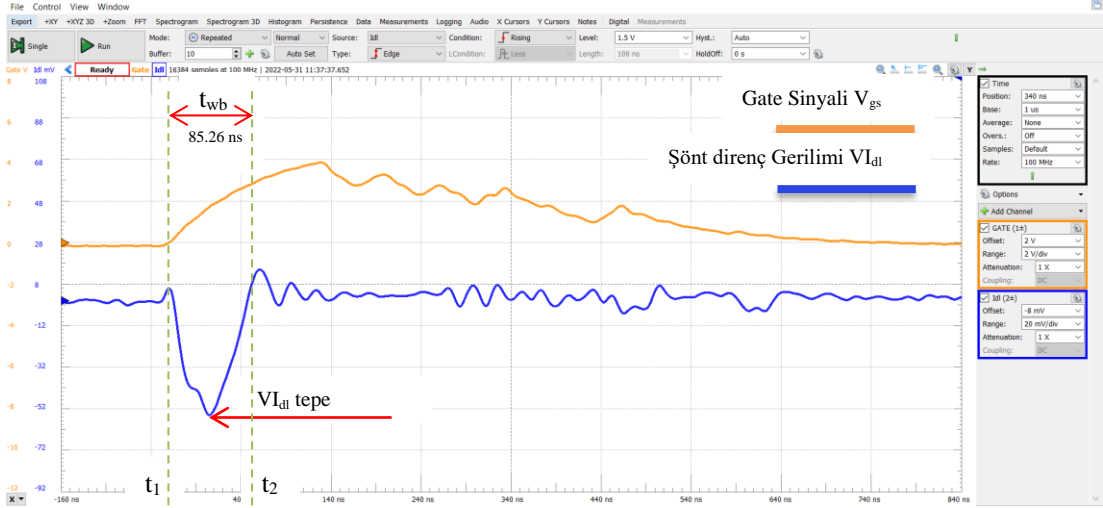
EPC9126 sürücüsünün kullanım kılavuzunda akımın darbe genişliğinin zamanlaması için sunulan S1 anahtar kombinasyonları çizelge 4.1'de verilmiştir.

Çizelge 4.1: Lazer sürücüsü darbe genişlik kombinasyonları.

Anahtar Konumları						Darbe Genişliği(ns)
6	5	4	3	2	1	
0	0	0	0	0	0	60.4
0	1	0	0	0	0	38.1
0	0	1	0	0	0	18.5
0	1	1	0	0	0	11.5
0	0	0	1	0	0	9.3
0	1	0	1	0	0	6.6
0	0	1	1	0	0	5.5
0	1	1	1	0	0	5.1
0	0	0	0	1	0	4.9
0	1	0	0	1	0	3.4
0	0	1	0	1	0	2.9
0	1	1	0	1	0	2.4
0	0	0	1	1	0	2.1
0	1	0	1	1	0	1.9
0	0	1	1	1	0	1.7
0	1	1	1	1	0	1.2

EK-A'da verilen sürücünün deşarj kapasitörleri üzerinden sağlanan akımın darbe genişliği Q1 mosfetinin açık kalma süresiyle ayarlanmaktadır. PULSE_IN1 girişine uygulanan darbe sinyali U3 tampon bellek (buffer) üzerinden çoklanmıştır. Çoklanan bu darbe sinyali R24 – R32 dirençleri S1 anahtar aracılığıyla seçilerek C26 kapasitesi üzerinden RC devresi oluşturulmuştur. EK-A'da verilen şematikte U4 mosfet gate sürücüsünün basitleştirilmiş iç modelinde, gate sürücüsünün içerisinde biri değil olan iki girişli bir ve kapısı (AND GATE) olduğu görülmektedir. Ve kapısının bir girişine darbe sinyali, diğer girişine RC devresi çıkışı gelmektedir. Darbe sinyali pozitif olduğunda mosfet iletme geçmekte, aynı zamanda çoklanan darbe sinyali, seçilen RC devresi üzerinden geciktirilerek mosfetin kesime geçmesi için geçecek süre ayarlanmaktadır.

Lazer sürücüsünün çizelge 4.1'de verilen anahtar kombinasyonlarından 60.4ns darbe genişliğine sahip olan kombinasyon seçilerek mosfet gate tetikleme ve akım grafikleri elde edilmiştir. Akım ölçümü EK-A'da verilen şematikte J3 konnektöründen, mosfet gate gerilimi ise J9 konnektöründen ölçülmüştür.



Şekil 4.4: EPC9125 lazer akımı ve mosfet gate gerilim eğrileri.

Mosfet gate gerilim grafiği ve lazer diyota kondansatörlerin sağladığı akımın hesaplanacağı şönt direnç gerilim grafiği şekil 4.4'te verilmiştir. Şekildeki grafik incelenirse, t_1 anında mosfetin tetiklenmesi ile kondansatör deşarj olmaya başlamıştır. t_2 anında ise kondansatörün deşarj süreci sonlanmıştır. Kondansatörlerin sağladığı bu lazer akımı I_{d1} 'nin darbe genişliği t_{wb} 85.26ns olarak ölçülmüştür. Çizelge 4.1'de tüm anahtarların 0 olduğu konumda darbe genişliği 60.4ns olarak belirtilmiştir, aynı kombinasyon kullanılmasına rağmen buradaki farklılık lazerin ve aradaki iletken bağlantının hat empedansından kaynaklanmaktadır.

Burada lazer akımının eğri formu şekil 4.4'te verilen grafikteki gibidir (mavi), fakat akım değerlerini elde etmek için şönt dirençlerin eşdeğerine bölünmesi gerekmektedir. EK-A'de verilen şematikte şönt dirençler R11-R16 dirençleri paralel bağlanmıştır. Paralel bağlı ve direnç değerleri eşit dirençlerin eşdeğeri aşağıdaki (4.5) numaralı bağıntı ile hesaplanır.

$$R_{eş} = \frac{\text{Direnç Değeri}}{\text{Direnç Adeti}} \quad (4.5)$$

Eş değer direnç $R_{eş}$ şematikteki değerler kullanılarak hesaplandığında $94m\Omega$ olarak elde edilir.

$$R_{eş} = \frac{0.47\Omega}{5} = 94m\Omega$$

Kondansatörlerin lazere sağladığı akımın tepe değerini bulmak için (4.6) numaralı bağıntıda verilen ohm yasası kullanılır.

$$I = \frac{v}{R} \quad (4.6)$$


Değerler yerine konulursa,

$$I_{dl} = \frac{54.71mV}{94m\Omega} = 614mA$$

kondansatörlerin lazere sağladığı akımın tepe değeri 614mA olarak hesaplanır. Yukarıda ölçülen değerler ve elde edilen grafikler lazer sürücü tetik girişine 5V genlikte, 5kHz frekans ve %8 doluluğa sahip PWM sinyali, kondansatörlerin şarj gerilimi bağlantısı VBUS terminaline 17V uygulanması koşullarında elde edilmiştir.

4.2 EPC9126 ile FA Sinyalin Elde Edilmesi

Bu bölümde EPC9126 lazer sürücü kartı kullanılarak denemeler gerçekleştirilmiştir. FA etkinin lazer ışınlarının doğrudan mikrofonu uygulandığında küçük güçlerde de gözükeceğinden [93], ilk denemeler MEMS mikrofon üzerinde gerçekleştirilmiştir. Mikrofon ve lazer diyotun yerleşim görseli şekil 4.5'te verilmiştir.




Şekil 4.5: Mikrofon ve lazer diyot yerleşim görseli.

Şekil 4.5'te de görüldüğü gibi lazer diyot doğrudan mikrofonun giriş portuna uygulanmıştır. EPC9126 Lazer sürücü kartı ve lazer diyotlar ile denemeler neticesinde mikrofondan alınan sinyalde herhangi bir faydalı veri elde edilemediği gözlemlenmiştir.

Bu durumun lazer sürücüsünün lazere sağladığı akımın darbe genişliğinden olabileceği ve yeterli optik gücün aktarılamadığından olabileceği düşünülmüştür. Kaynak [94]'de yapılan çalışmada FA etkinin lazer akımının darbe genişliğiyle olan bağlantısından bahsedilmiştir. Burada lazer 17kHz frekans ile sürülmüş ve çeşitli darbe

genişliklerinde sinyaller elde etmişlerdir. Elde edilen sinyallere ait görsel şekil 4.6’da verilmiştir.



Şekil 4.6: Kaynak [94]’ten alınan farklı lazer akımı darbe genişlikleri neticesinde elde edilen akustik görseller.

Şekil 4.6’da verilen görselde akım darbe genişliği 9.41us ile 25.88us arasında değişmektedir. Burada yapılan çalışma neticesinde lazer akımının darbe genişliğinin artırılmasıyla fotoakustik etkinin artacağı sonucu belirtilmiştir [94].

Şekil 4.3’te verilen kapasitif deşarj sürücü topolojisi analiz edilirse, lazer akımının tepe değeri I_{dlpk} aşağıdaki (4.7) numaralı bağıntıyla bulunabileceği gözükmektedir.


$$I_{dlpk} = \frac{v_{in} - v_{DLF}}{R_0} \quad (4.7)$$

R_0 daha önce (4.3) numaralı bağıntıyla belirtilmişti ve hattın kaçak endüktansının eş değer şarj kapasitesine bölümünün karekökü ile bulunmaktadır. (4.3) numaralı bağıntı incelendiğinde şarj kapasitörlerinin sığa değerlerinin artırılması devrenin karakteristik empedansı olan R_0 ’ı düşüreceği görülmektedir. R_0 düşmesi (4.7) numaralı bağıntıda paydanın azalması anlamına gelmekte ve lazer akımının artacağı sonucu çıkmaktadır.

Sonuç olarak şekil 4.4 incelenirse, EPC9126 lazer sürücü kartının sağladığı maksimum akım darbe genişliği t_{wb} 85.26ns olduğu gözükmektedir. Bu değer sürücü kartının deşarj kapasitörlerinin deşarj zamanı ile belirlendiğinden bu kapasitörlerin değiştirilerek sığasının artırılması gerekmektedir. EPC9126 fabrikasyon üretim olduğundan bu kart üzerinde değişiklik yapılamadığı için temel tasarım referans alınarak yeni sürücü kartı tasarımı gerçekleştirilmiştir.

4.3 Kapasitif Deşarj Topolojisine Dayalı Lazer Sürücü Kart Tasarım

Yukarıda lazer akımının darbe genişliğinin FA etki üzerinde olan etkisinden bahsedilmiştir. Lazer akımının artırılması, dolayısıyla fotoakustik etkinin de artırılması amacıyla kapasitif deşarj topolojisine dayalı lazer sürücü kartı tasarımına gidilmiştir. Bu amaçla gerekli komponent seçimleri yapılmış ve KiCAD ortamında EK-A'daki tasarım referans alınarak lazer sürücüsünün tasarım süreçleri gerçekleştirilmiştir. Tasarlanan sürücüye ait KiCAD şematik tasarım görseli EK-B'de verilmiştir. Şematikte C10 – C14 etiketleri ile belirtilen kapasitörler deşarj kapasitörleridir. Kart üzerinde kondansatör değerleri değiştirileceğinden, şematikte bu değerler gizlenmişlerdir.



Şekil 4.7: Tasarlanan sürücünün üretilmiş görseli.

Tasarlanan sürücü kartının üretilmiş görseli ve deneysel düzeneğin tekrar kurulmuş hali şekil 4.7'de verilmiştir.

Tasarlanan sürücü kartı ile, EPC9126 lazer sürücüsünde kullanılan 852nm 220mW lazer diyot sürülmüş. Daha sonra tasarlanan lazer sürücüsünün deşarj kapasitörlerinin sağladığı lazer akımının ölçülmesi ve analiz işlemine geçilmiştir. Deşarj akım ölçümü Ek-B'de verilen şematikte TP4, Q1 mosfet gate sinyali TP6 test noktasından ölçülmüştür.


Gate sinyali ve kondansatör deşarj akımının hesaplanacağı şönt dirençler üzerine düşen gerilimin grafiği şekil 4.8'de verilmiştir. Kondansatör deşarj akımının grafiğinin formu şekil 4.8'de verilen şönt dirençler üzerine düşen gerilimin formu ile aynıdır. Fakat deşarj akımının genlik değerleri farklı olacağından, (4.7) numaralı bağıntı kullanılarak ve daha önce hesaplanan $R_{\text{şönt}}$ eşdeğer dirence bölümüyle

hesaplanmıştır. Deşarj kondansatörleri tarafından sağlanan lazer akımının tepe değerini şekil 4.8'deki değer kullanılarak hesaplanırsa,

$$I_d = \frac{118.8mV}{94m\Omega} = 1.264A$$

I_d 1.264A olarak bulunur. EPC9126 lazer sürücüsünde deşarj kapasitörleri 17V gerilimle şarj edilmiştir. Tasarlanan lazer sürücü devresindeki kondansatörler 10V gerilimle şarj edilmiştir. EPC126 sürücüsünde lazer akımının tepe değeri 614mA olarak hesaplanmıştır. Tasarlanan sürücüde ise 1.264A olarak hesaplanmıştır, bu değer EPC9126 tarafından sağlanan akımın yaklaşık 2.058 katı olduğu görülmüştür.

Ayrıca şekil 4.8'deki grafik incelenecek olursa, deşarj kapasitörlerinin sağladığı akımın darbe genişliği, 709.3ns olarak ölçülmüştür. Deşarj kapasitörlerinin daha düşük şarj geriliminde hem daha yüksek akım hem de daha geniş darbe süresi tasarlanan sürücü ile sağlanmış ve bu sayede lazerin aktardığı ortalama enerji arttırılmıştır.




Şekil 4.8: Tasarlanan lazer sürücü gate ve akım sinyal grafikleri.

4.4 Tasarlanan Lazer Sürücü ile FA Sinyalin Elde Edilmesi


Tasarlanan sürücü ile kondansatörlerin sağladığı ve lazeri süren deşarj akımının darbe genişliğinin ve akım genliğinin arttırılmasının ardından akustik sinyalin elde edilmesi için denemelere geçilmiştir. Şekil 4.7'de verilen görseldeki gibi lazer diyot doğrudan mikrofona ses girişine doğru yönlendirilmiştir. Bu yönlendirmedeki amaç kaynak [93]'de belirtilen FA etkinin MEMS mikrofonda düşük güçlerde de gözlemlenebileceği bilgisine dayanmaktadır.

Darbe genişliğinin ve lazer akımının artırılması neticesinde şekil 4.9’da verilen grafikte, mikrofonda FA etki olduğu görülmektedir.



Şekil 4.9: Tasarlanan sürücü gate sinyali(mavi) ve MEMS mikrofon sinyali (turuncu) grafikleri.

Tasarlanan lazer sürücü kartı ile mikrofon üzerinde FA etkinin oluşmasının ardından şekil 4.10’da verilen malzemeler üzerinde akustik sinyal elde edilmesi için denemeler yapılmıştır. Lazer ve mikrofonun konumlandırılması şekil 4.2’de verilen görseldeki gibi ayarlanmıştır. Şekil 4.10’da verilen görseldeki malzemeler üzerinde çeşitli güç ve dalga boyundaki lazer diyotlar kullanılarak denemeler yapılmıştır. Sinyal genliği ve akustik etki bakımından MEMS mikrofondan elde edilen en anlamlı sinyal 783nm 200mW gücündeki lazer diyotla elde edilmiştir. Bu nedenle denemeler yoğunlukla bu lazer ile gerçekleştirilmiştir.



Şekil 4.10: Deneme için kullanılan malzemeler demir, izole bant, sünger ve bakır plakette (soldan sağa).

Malzeme üzerinde gerçekleştirilen çalışmalar neticesinde herhangi bir FA etkinin oluştuğuna dair bir sinyal ölçülemedi. FA etkinin oluşmamasının başlıca sebebi, temin edilen lazer diyotların güçleri düşük değerlerde olduğu (Çizelge 4.2’ye bakınız)

için, yeterli optik gücün malzemeye aktarılamaması ve malzemenin ısınıp genişmesi için yeterli enerjinin oluşmadığından dolayı akustik titreşimlerin, tasarlanan sistem tarafından ölçülememesidir. Malzemeye aktarılacak ortalama güç için, darbe genişliği ve akım genliği, sürücü tasarımı yapılarak arttırılmıştır fakat buna rağmen yeterli olmadığı görülmüştür.


Çizelge 4.2: Deneme çalışmalarında kullanılan lazerler.

Numara	Ürün / Özellikleri
1	520nm, 80mW Lazer Diyot
2	783nm, 200 mW, TO-56 Paket Lazer Diyot
3	450nm 80mW TO-56 Paket Lazer Diyot
4	515nm, 10 mW, TO-56 Paket Lazer Diyot
5	650nm ve 791nm, 380mW TO56 Paket Lazer Diyot
6	RLD78MZM7-00A 780nm 20mW Lazer Diyot
7	RLD82NZJ1-00A 820nm 220mW Lazer Diyot
8	RLD84NZJ2-00A 840nm 220mW Lazer Diyot
9	RLD85NZJ4-00A 850nm 220mW Lazer Diyot


4.5 Lazer Optik Gücü ile Fotoakustik Sinyal İlişkisi

Lazer gücünün FA etkiyle olan ilişkisinin gözlemlenmesi için 200mW olan lazer diyot normal güçte ve lazer diyotun veri sayfasında belirtilen akım değerinin (en fazla 350mA) üzerinde akım değerlerinde sürülmesi sonucunda mikrofon üzerinde elde edilen akustik sinyallerin genliği incelenmiştir.

Farklı akım değerleri ile sürülen lazerin ve ölçülen akustik sinyalin grafikleri şekil 4.11 ve şekil 4.12’de verilmiştir. Şönt dirençler üzerinden ölçülen gerilimler $R_{eş}$ eşdeğer dirence bölünürse, lazer akımının tepe değeri I_d , şekil 4.11’deki ölçüm için 437mA ve şekil 4.12’deki ölçüm için I_d 758mA olarak hesaplanır.



Şekil 4.11: Lazer diyotun 437mA akımla sürüldüğünde oluşan mikrofon sinyali.



Şekil 4.12: Lazer diyotun 758mA akımla sürüldüğünde oluşan mikrofon sinyali.

Şekil 4.11 ve şekil 4.12’de, lazer akımının 437mA olduğunda ölçülen mikrofon tepe gerilim değeri 140.71mV, 758mA olduğunda ölçülen mikrofon tepe gerilim değeri 222mV olarak ölçülmüştür. Bu değerler, lazer diyotun optik gücünün FA etki üzerindeki etkisini göstermektedir.

Yapılan tüm denemelere rağmen malzemeler üzerinde FA etki oluşmadığından akustik sinyal alınamamıştır. Bu durum satın alınan lazer diyotların gücünün düşük olmasından kaynaklandığı düşünülmüştür. Malzemeye aktarılan optik gücün artırılması için, lazere uygulanan akımın darbe genişliğinin ve genliğinin artırılması yolu denenmiştir, fakat yeterli güç aktarımı sağlanamamıştır. Bu yapılan işlemler lazerin ömrünü azaltacağından sınırlı kalmıştır [31].


Lazer güçlerinin paylaşıldığı literatür kaynaklarından, [31]'de 1W ile 3W arasında lazer diyotları maksimum akım sınırınının 45 katına kadar sürerek, [26]'da 20W gücünde lazer diyotla ve [95]'da 2W gücünde optik güçle FA etkiyi oluşturmuşlardır. Kaynak [26]'da tren raylarındaki çatlak için çalışma yapılmıştır. Bu çalışma, doktora tezi ile daha yakın olduğundan dolayı bu çalışma ile karşılaştırılacak olunursa, kullanılan lazer 20W ve bu çalışmada kullanılan lazerden yaklaşık 100 kat daha güçlü olduğu görülmüştür. Bu nedenle daha güçlü bir lazerin gerekli olduğu sonucuna varılmıştır.

4.6 Tasarlanan ve Tezde Kullanılan Çalışma Düzenegi

Yukarıdaki bölümlerde gerçekleştirilen araştırmalar sonucunda bu tezde kullanılan çalışma düzeneginin son hali aşağıda şekil 4.13'de verilmiştir. Yukarıda farklı lazerlerle ve lazer akımının artırılması sonucunda deneme malzemelerinden FA sinyali elde edilemediği belirtilmişti. Şekil 4.13'de verilen tasarımda, yukarıdaki bölümlerde verilen çalışma düzenegi kurulumlarına ek olarak bazı değişiklikler ve güncellemeler yapılmıştır. Bu değişiklikler, lazer kaynağı olarak 450nm 15W lazer kaynağı kullanılmıştır, malzemenin konumlandırması ve lazer kaynağının stabil kalabilmesi için platform tasarlanmıştır ve ses sinyali ile anahtarlama kaynağın parazit sinyali arasında faz farkı oluşturmak için, mikrofonun giriş portuna 125mm uzunluğunda, 7.67mm çapında içi boş silindirik bir parça eklenmiştir. Değişiklikleri içeren çalışma düzeneginin üç boyutlu tasarımı materyal bölümünde şekil 3.1'de, gerçek görseli ise şekil 4.13'de verilmiştir.

Şekil 4.13'de verilen çalışma düzenegindeki deşarj kapasitörlerinin, 60V gerilimle şarj edilmesi durumunda lazerden geçen akımın grafiği aşağıda şekil 4.14'te verilmiştir. Kondansatör deşarj akımının grafiğinin formu şönt dirençler üzerine düşen gerilimin şekli ile aynıdır, fakat genlik olarak daha önce hesaplanan $R_{\text{şönt}}$ dirence bölümüyle hesaplanmıştır. Deşarj kondansatörleri tarafından sağlanan lazer akımının, tepe değerini şekil 4.14'teki verilen değer kullanılarak hesaplanırsa,

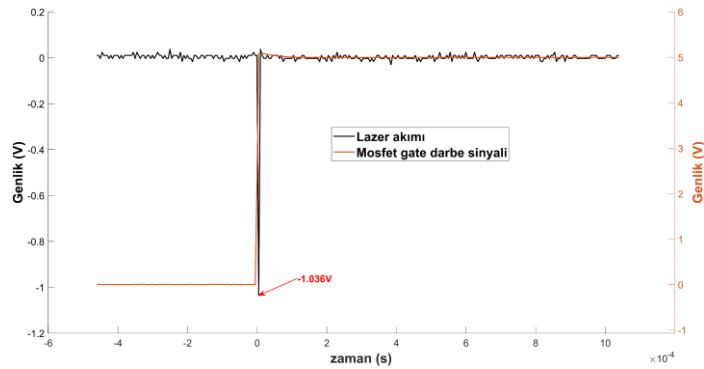
$$I_d = \frac{1.036V}{94m\Omega} = 11.022A$$



Şekil 4.13: Çalışma düzeneği (1- Osiloskop, 2- Lazer sürücü, 3- Lazer, 4- Lazer ve malzeme sabitleme tablası, 5- Gripper, 6- Mikrofon, 7- 125x7,67mm içi boş silindir).


I_d lazer akımı 11.022 amper olarak bulunur. Bu değer daha önceki en yüksek lazer akımının yaklaşık 8.8 katıdır. Lazer akımı ile lazer optik gücü doğru orantılı olduğundan, tasarlanan sürücü ve yapılan geliştirmeler neticesinde malzemelere aktarılacak optik güç artırılmıştır.

Çalışma düzeneğinin geliştirilerek şekil 4.13'te verilen son halini almasının ardından, tez malzemelerinden FA sinyallerin elde edilmesi için denemeler gerçekleştirilmiştir. Şekil 3.7'de görselleri verilen, alüminyum, demir, plastik ve tahta malzemelerinden elde edilen FA sinyal grafikleri ve lazer darbe sinyalini gösteren grafikler şekil 4.15'te verilmiştir.



Şekil 4.14: Çalışma düzeneğindeki lazerden geçen akım grafiği.

Verilen grafiklerin süreçleri, darbe sinyali ile lazer sürücünün tetiklenmesi ile başlar ve ardından deşarj kondansatörleri lazer diyot üzerinden boşalmaya başlamaktadır. Darbe sinyali ile FA sinyal mikrofon aracılığıyla toplanmasının ardından süreç tamamlanmaktadır. Şekil 4.15'te darbe sinyali ve mikrofon sinyali verilmiştir. FA sinyal tüm sinyalin bir bölümünde olduğundan dolayı şekillerde mavi kesikli çizgi ile işaretlenmiştir.




Şekil 4.15: Tez malzemelerinden elde edilen ham FA sinyal grafikleri.

4.6.1 FA Sinyal Üzerindeki Anahtarlama Etkisinin Azaltılması


Lazer sürücülerinin iyi bir parazit yalıtımına sahip olmasına rağmen, alınan FA sinyalde güçlü parazite neden olduğu belirtilmiştir [31]. Bu parazitin etkisini azaltmak için literatürde, anahtarlama belli bir süre sonra veri alma işlemi gerçekleştirilmiştir.

Bu tez çalışmasında şekil 4.13'te verilen çalışma düzeneğinde (7) numara ile belirtilen bileşen ile akustik sinyalin kaynağı ile mikrofonun girişi arasındaki mesafe artırılmıştır. Bu sayede anahtarlama kaynaklı parazit ile akustik sinyal arasında faz farkı oluşturularak, gürültünün FA sinyal üzerindeki etkisi azaltılmıştır.

Mikrofona ile doğrudan alınan FA sinyal ve lazer sürücüsünün darbe sinyalinin verildiği grafik şekil 4.16'da mikrofonun ses giriş portuna yukarıda belirtilen içi boş silindirin monte edilmesi sonucu elde edilen FA sinyal ve darbe sinyalinin verildiği grafik ise şekil 4.17'de verilmiştir.



Şekil 4.16: Mikrofon ile doğrudan alınan sinyal grafiği.




Şekil 4.17: Mikrofonu içi boş silindir monte edilerek alınan sinyal grafiği.

Yukarıda şekil 4.16'da verilen grafik incelendiğinde, mikrofonun doğrudan kullanılması durumunda lazer sürücünden kaynaklanan parazit, FA sinyale karışarak sinyalin formasyonunu bozduğu ve FA sinyalin tespit edilmesini zorlaştırdığı görülmüştür.

Mikrofona, yukarıda özellikleri verilen içi boş silindir monte edilmesi sonucu lazer sürücünden kaynaklanan parazit ile FA sinyali arasında faz farkının oluştuğu şekil 4.17'de görülmektedir. Bu sayede lazer sürücünden kaynaklanan gürültünün etkisi azaltılarak, gürültüden arındırılmış FA sinyali formasyonu elde edilmiştir.

5. MALZEME FA VERİLERİNİN GKA ANALİZİ VE SINIFLANDIRMA



Şekil 5.1: Önerilen yöntemin blok şeması.

Bu tez çalışmasında, FA sinyalin GKA ile işlenmesine dayanan, farklı katı malzemeler için ortak bir kusur tespiti çerçevesi önerilmiştir. Önerilen yöntemi özetleyen blok şema, şekil 5.1’de verilmiştir. Uygulanan yöntem sonuçları ve analizleri aşağıda verilen alt başlıklarda detaylı olarak sunulmuştur.

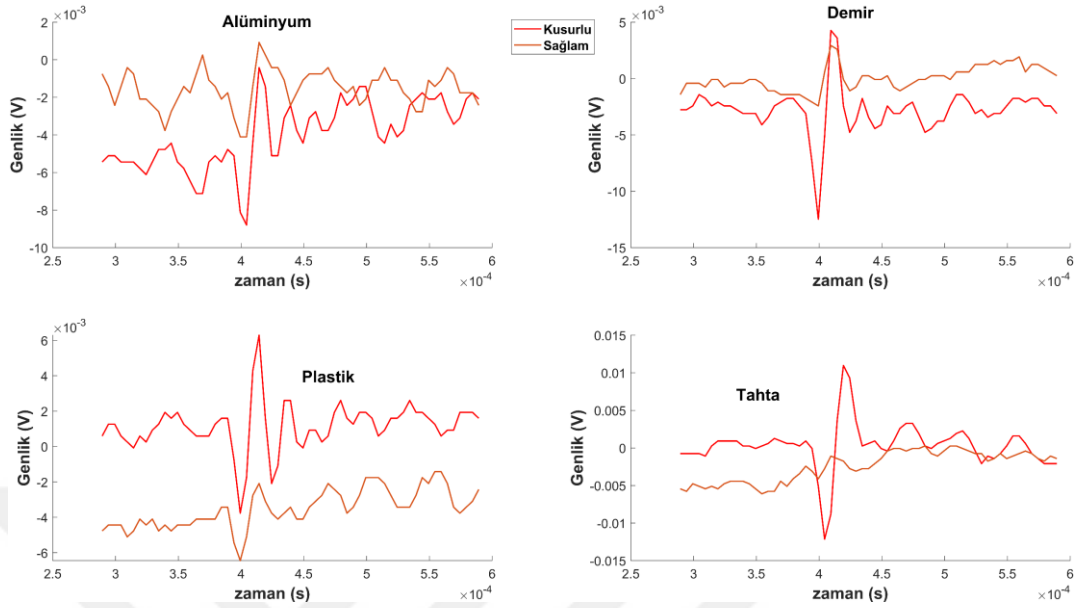
5.1 Malzemelerden Elde Edilen FA Veri Seti

Tezde kullanılacak FA verilerin elde edileceği malzemeler için demir, alüminyum, tahta ve plastik malzemeleri belirlenmiştir. Malzeme guruplarının içerisinde sağlam ve kusurlu örneklerini barındıran alt guruplar oluşturulmuştur. Bu malzeme guruplarından oluşturulan veriseti, her malzemedan 120 adet sağlam, 120 adet kusurlu olmak üzere 960 adet örnekten oluşmaktadır. Veri setinin elde edildiği örneklerin görselleri materyal bölümünde şekil 3.7’de verilmiştir.

Malzemelerden elde edilen akustik sinyallerin ham hali, dördüncü bölümde şekil 4.15’teki grafiklerde verilmiştir. Şekildeki grafiklerde FA sinyalin, sinyalin bir bölümünde oluştuğu görülmektedir. Bu tezdeki amaç FA sinyalin analizi ve işlenmesi olduğundan dolayı, sinyalde sadece FA verinin olduğu zaman aralığının elde edilmesi hem analiz açısından hem de maliyet ve performans açısından faydalı olacaktır.

FA sinyal bilgisinin, mikrofon akustik sinyalinde 289.37us ile 589.37us zaman aralığında olduğu, deneme yanılma yoluyla tespit edilerek sinyallerin bu zaman aralıkları ham sinyalden kesilerek elde edilmiştir. FA sinyal bilgisini içeren bu sinyallerin grafiği aşağıda şekil 5.2’de verilmiştir. Malzemelerden elde edilen akustik sinyal bu şekilde kırılarak FA sinyal verisi elde edilmiştir ve veri seti bu veriler

kullanılarak oluşturulmuştur. Aşağıdaki başlıklarda yapılan çalışmalar bu veriler kullanılarak gerçekleştirilmiştir.



Şekil 5.2: Malzemelerin kırılmış FA sinyal grafikleri.


5.2 GKA'nın FA Sinyal Üzerindeki Taban Kaymasına Etkisi

Bu çalışmada FA sinyallerin algılanması için MEMS mikrofon kullanılmıştır. Yüksek performansı ve düşük maliyetlerinden ötürü bu mikrofonlar birçok akustik uygulama için tercih edilmektedir. Fakat bu mikrofonların uygulama ortamlarında genellikle gürültü ve bozucu etkiler bulunmaktadır. Bununla birlikte, akustik ortamdaki gürültü karmaşık ve değişkendir. Doğal veya yapay çeşitli ses sinyalleri kaynağı, toplanan akustik sinyallere karışarak faydalı sinyalde gürültüye neden olmaktadır. Bunun sonucunda kaçınılmaz olarak taban çizgisinin kayması ve diğer bozulma olaylarına yol açmaktadır [96].

Sinyal algılama, tanıma, özellik çıkarımı ve sınıflandırma süreçlerinin kalitesi ölçülen ham sinyalin daha az gürültü ve bozulmaya sahip olmasını gerektirir. Bu nedenle, gürültülü sinyalden gürültüyü temizlemek için ve taban kaymasını düzeltmek, daha sonraki sinyal işleme, özellik çıkarımı ve sınıflandırma işlemleri için büyük önem arz etmektedir [96].

Şekil 5.3'te bir örnekten alınan ham FA sinyali ve GKA uygulanması sonucu elde edilen ÖKF grafikleri verilmiştir. Şekilde ham veriye ait grafikte sağlam ve kusurlu sinyaller arasında taban kayması olduğu görülmektedir. Bu taban kayması yukarıda

belirtilen çeşitli çevre gürültülerinin bir yansıması olarak malzemelerden elde edilen akustik sinyalde oluşmuştur. Ham verideki bu istenmeyen etkiyi azaltmak için bu çalışmada, GKA ham akustik sinyallere uygulanmıştır. GKA uygulandıktan sonra elde edilen ÖKF sinyallerinde taban kayması önemli ölçüde kusurlu ve sağlam sinyaller arasında azaldığı şekil 5.3'teki ÖKF grafiklerinde gözükmemektedir. Şekilde verilen grafikler ışığında, özellikle ilk ÖKF'lerin taban kaymasına etkisi daha baskın olduğu görülmüştür.



Şekil 5.3: GKA'nın FA sinyal üzerindeki taban kaymasına etkisi.

Şekil 5.3'te verilen sonuçlar doğrultusunda, bu tezde önerilen GKA yönteminin ölçülen sinyalin büyük çoğunluğunun gürültüsünü etkili bir şekilde minimize edeceği, kaynak FA sinyalin temel özelliklerini daha iyi geri kazanabileceği ve taban kaymasını iyi bir şekilde düzeltebileceği sonucuna varılabilir. Böylece önerilen yöntem sayesinde, daha ileri MEMS mikrofon ile sinyal algılama ve tanıma için iyi bir temel oluşturabilir.

5.3 Orijinal Sinyali Temsil Eden ÖKF'lerin Araştırılması

Her bir malzeme ve sinyal için farklı sayıda ÖKF üretilmektedir. Ham sinyal birçok bileşen barındırabileceğinden bu sinyali temsil eden ÖKF veya orijinal sinyale en yakın ÖKF'nin belirlenmesi amacıyla ham sinyal ile ÖKF'ler arasındaki korelasyon katsayıları [97] hesaplanmıştır. Hesaplanan korelasyon katsayıları Çizelge 5.1'de verilmiştir.


Çizelge 5.1: Ham sinyal ve ÖKF'ler arası korelasyon katsayısı değerleri.

	Korelasyon Katsayısı		
	ÖKF 1	ÖKF 2	ÖKF 3
Alüminyum	0.5949	0.5667	-
Demir	0.9617	0.1718	0.0815
PVC	0.8464	0.3389	0.1576
Tahta	0.9274	0.5079	0.2841


Çizelge 5.1'e bakılırsa, ham sinyal ile birinci ÖKF arasındaki korelasyon katsayısı tüm örneklerde bire yakın çıktığı görülmektedir. Korelasyon katsayısının bire yaklaşması, o bileşenin karşılaştırıldığı bileşene yakınsadığını göstermektedir. Çizelge 5.1'de verilen sonuçlar birinci ÖKF'nin, ham FA sinyale diğer ÖKF'lere göre benzerlik açısından daha yakınsadığından dolayı, ÖKF 1'in sinyal analizi için daha uygun olduğunu göstermiştir ve özellik çıkarımı için ÖKF 1 kullanılmıştır. Bu sayede birden fazla ÖKF kullanılarak yapılacak işlemlerden doğacak, işlem yükünü ve oluşacak hesap süresinin artmasından kaynaklanacak olumsuz etkiler azaltılmıştır.

5.4 FA Sinyalin Zaman-Frekans Bileşenleri

EMD ile elde edilen birinci ÖKF'lere HHD uygulanarak ÖKF'lere ait anlık frekans $\omega(t)$ ve anlık genlik $A(t)$ izgeleri elde edilmiştir. Alüminyum, demir, plastik ve tahta örneklerine ait anlık frekans grafikleri şekil 5.4'te ve anlık genlik grafikleri şekil 5.5'te verilmiştir.



Şekil 5.4: Malzemelerin anlık frekans grafikleri.




Şekil 5.5: Malzemelerin anlık genlik grafikleri.

Şekil 5.4 ve şekil 5.5'te verilen grafikler ışığında malzeme sınıflarının anlık genlik izgesinin, anlık frekans izgesine göre sağlam ve kusurlu örnekler üzerinde ayırt ediciliğinin daha yüksek olduğu görülmüştür. Bu veriler ışığında, elde edilen FA sinyaller için zaman-frekans düzleminde anlık genlik bileşeninin, anlık frekans bileşenine göre daha ayırt edici nitelikte olduğu söylenebilir.

5.5 Özelliklerin Çıkarımı ve Özelliklerin Ağırlık Analizi

Bu çalışmada özellik çıkarmak için öncelikle alüminyum, demir, plastik ve tahta örneklerine ait tüm veri setine GKA uygulanarak, ÖKF'ler her bir örnek için elde edilmiştir. Daha sonra malzemelere ait ÖKF'lere Hilbert dönüşümü uygulanmıştır. Zaman düzlemindeki özellikler malzeme sinyallerinden elde edilen birinci ÖKF'ler kullanılarak elde edilmiştir. Zaman-frekans düzleminde çıkarılan özellikler ise malzemelerden elde edilen birinci ÖKF'lere, HD uygulandıktan sonra elde edilen anlık frekans ve anlık genlik bileşenleri kullanılarak çıkarılmıştır. Malzemelerden çıkarılan zaman ve zaman-frekans düzlemindeki 14 adet özellik çizelge 5.2'de verilmiştir.

Çizelge 5.2'de verilen her bir özellik veri setindeki örnekler için çıkarılmıştır. Tüm örneklere ait özelliklerin kendi içerisinde dağılımlarını gösteren grafikler şekil 5.6-5.9'de verilmiştir.




Şekil 5.6: Alüminyum örneklerinden elde edilen özelliklerin dağılım grafiği.


Şekiller incelendiğinde farklı malzemelerde farklı özelliklerin daha baskın olduğu görülmektedir. Örneğin alüminyum için şekil 5.6'ya bakılırsa, entropi ayırt edicilik açısından önemli bir özellik olduğu gözükmektedir. Fakat şekil 5.7'ye bakıldığında demir için entropi özelliğinin seçicilik açısından düşük olduğu söylenebilir. Grafikler incelendiğinde malzeme özelinde çıkarılan özneliklerin malzeme türüne göre farklı seçicilikte olduğu söylenebilir.

Çizelge 5.2: Öznelikler.


ZAMAN DÜZLEMİ	ZAMAN-FREKANS DÜZLEMİ
ÖKF 1'den çıkarılan özellikler	Anlık gen $A(t)$ ve anlık frekans $\omega(t)$ 'den çıkarılan özellikler
Tepe genlik (TG)	Tepe genlik (TG_{zf})
Tepeden tepeye genlik (TTG)	Eğim (M)
Form faktör (FF)	Standart sapma (SS)
Hjorth parametreleri (activity (HA), mobility (HM), complexity (HC))	Ortalama genlik (OG)
Entropi (E)	Aktif sinyal süresi (ASS)
	Tepe frekans (TG_f)
	Ortalama frekans (OG_f)



Şekil 5.7: Demir örneklerinden elde edilen özelliklerin dağılım grafiği.




Şekil 5.8: Plastik örneklerinden elde edilen özelliklerin dağılım grafiği.



Şekil 5.9: Tahta örneklerinden elde edilen özelliklerin dağılım grafiği.

Yukarıda bahsedilen ve malzemelerden elde edilen özelliklerin seçicilik açısından farklılıklarını daha iyi analiz edebilmek için, özelliklerin malzeme özelinde ağırlıkları hesaplanmıştır. Tüm malzeme özellikleri, Relieff algoritması ile her bir malzeme için ayrı ayrı sınıf içerisindeki ayırt edebilirlik açısından ağırlıkları hesaplanmıştır. Malzemelerden elde edilen 14 adet özelliğin her bir malzeme için ağırlıkları Şekil 5.10'da verilmiştir.



Şekil 5.10: Malzemelere ait özellik ağırlıkları.

Şekilde farklı malzemelerde özelliklerin ağırlıklarının da farklılaştığı açıkça görülmüştür. Yukarıda verilen şekil 5.6-5.9 grafikleri üzerinden, alüminyum ve demir

örneğinin seçicilik farkından bahsedilmiştir. Sayısal olarak bu farkı desteklemek için şekil 5.10’da alüminyum ve demir malzemelerinin entropi değerleri karşılaştırılırsa, alüminyum E değeri 0.25 iken, demir için E değeri 0.07 olarak hesaplanmıştır. Bu durumda entropi değeri seçicilik açısından alüminyum için önemli bir özellikken, demir için daha az öneme sahip bir özellik olduğu söylenebilir. Bu durum yukarıda belirtildiği gibi, tüm malzemeler için farklı özelliklerin baskın olduğunu göstermiştir.

5.6 Sınıflandırma Sonuçları

Malzemelere ait özelliklerin çıkarılmasının ardından, sınıflandırıcıların eğitimlerine geçilmiştir. Bu çalışmada karar ağaçları, k-en yakın komşuluk ve destek vektör makinaları sınıflandırıcı olarak belirlenmiştir. Yukarıdaki bölümlerde detayları verilen ve malzemelerden elde edilen sinyaller kullanılarak zaman ve zaman-frekans düzleminde çıkarılan 14 adet özellikle bu sınıflandırıcılar eğitilmiştir. *k*-NN için 1 komşuluk, DVM içinse doğrusal çekirdek parametre olarak girilmiştir. Tüm sınıflandırıcılar için çapraz doğrulama yöntemi olarak, birini dışarıda bırak çapraz doğrulama yöntemi uygulanmıştır.

Çizelge 5.3: Sınıflandırıcıların doğruluk değerleri.

Malzeme	Doğruluk (%)		
	KA	<i>k</i> -NN	DVM Doğrusal
Alüminyum	100	100	100
Demir	100	100	100
Plastik	100	99.14	100
Tahta	98.75	100	100
Tüm malzemeler dahil	96.67	97.77	94.93

KA, *k*-NN ve DVM için eğitim sonucunda elde edilen doğruluk değerleri çizelge 5.3’te verilmiştir. Tablodaki değerler ışığında her bir malzeme grubu için sınıf içi eğitim sonucu doğruluk değerlerinde, DVM sınıflandırıcısının dört malzeme grubunda da KA ve *k*-NN sınıflandırıcısına göre başarılı sonuç verdiği görülmüştür. Bu çalışma özelinde her malzemenin ayrı ayrı sınıf içi başarımlarından DVM’nin diğer yöntemlerden daha başarılı sınıflandırma gerçekleştirdiği söylenebilir.

Ayrıca malzemelerin bireysel olarak sınıf için eğitim fazından hariç, tüm malzemelerin dahil olduğu, malzeme türünden bağımsız, malzeme örneğinin kusurlu veya sağlam

olduğunu etiketleyen sınıflandırıcı eğitimleri gerçekleştirilmiştir. Tüm malzemelerin dahil olduğu eğitim fazı sonucu doğruluk değerleri çizelge 5.3'te verilmiştir. Bu doğruluk değerleri KA, k -NN, DVM için sırasıyla %96.67, %97.77 ve %94.93 olarak hesaplanmıştır. Çizelge 5.3'te tüm malzemelerin dahil olduğu sınıf içi eğitim sonucu doğruluk değerlerinde k -NN sınıflandırıcısının, diğer sınıflandırıcılardan daha yüksek başarımda bir doğrulukla sınıflandırma yaptığı görülmüştür.

Şekil 5.10'da malzemelerden çıkarılan özelliklerin farklı malzeme grupları içerisinde farklı ağırlıkların baskın olduğu belirtilmiştir. Bunun etkisi sınıflandırıcıların, malzemelerin ayrı ayrı sınıf içi genel doğruluk değerlerinin, tüm malzemelerin sınıf içi doğruluk değerlerinden yüksek olarak çıkmasında görülmüştür.



6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, FA etki kullanarak malzemelerde kusur tespiti için bir yöntem önerilmiştir. Ayrıca, düşük maliyetli FA kusur tespit sistemi geliştirilmiştir. Malzemelerden elde edilen FA sinyallere görgül kip ayrışımı uygulanarak, GKA ile FA sinyaldeki gürültüler süzölmüş, taban kaymasının etkisi azaltılmış ve aynı zamanda özellik çıkarımı için faydalı sinyal elde edilmiştir. Bu şekilde önerilen metodoloji ile farklı iki görev tek bir işlemde gerçekleştirilmiştir. FA sinyallerin birinci özgül kip fonksiyonlarından 14 adet özellik çıkarılmıştır. Karar ağacı, k-en yakın komşu ve destek vektör makinesi sınıflandırıcı olarak seçilmiş ve bu 14 özellik ile eğitilmiştir. Tüm sınıflandırıcılar için çapraz doğrulama yöntemi olarak, birini dışarıda bırak çapraz doğrulama yöntemi uygulanmıştır. Alüminyum, demir, plastik ve tahta için önerilen yöntemle, malzeme özelinde bir sınıf içindeki tek bir malzeme için ve tüm malzemelerin dahil olduğu bir sınıf içindeki tüm malzemeler için yüksek doğruluk performansıyla sınıflandırılmıştır.

Bu tez çalışmasında önerilen yöntem ile, hem ham sinyal üzerindeki gürültü giderilerek faydalı sinyalin salınımı elde edilmiştir, hem de sinyalden özellik çıkarımı yapılmıştır. Literatürde bir malzeme özelinde yapılan çalışmaların aksine, uygulanan yöntem ile şekil 3.7’de verilen farklı kusurların bulunduğu ve farklı malzemeler için ortak bir sınıflandırma çerçevesi geliştirilmiştir. Çizelge 5.3’te verilen sınıflandırıcı doğruluk değerleri, uyguladığımız yöntemin başarımını desteklemektedir.

Bu çalışma, FA yönteminin farklı malzemelerdeki yüzey kusurları için etkinliğini artırmaya yönelik önemli bir katkı sağlamaktadır. GKA yönteminin FA sinyallerindeki taban kaymasını elimine ederek sinyal işleme sürecini iyileştirdiği gösterilmiştir. Bu sayede, FA sinyal ve GKA yöntemi ile farklı malzemelerdeki kusur tespitinin başarı oranı önemli ölçüde artırılabilir.

Çalışmanın sonuçları, önerilen yöntemin endüstriyel uygulamalarda daha yaygın olarak kullanılmasına katkı sağlayabilir. Örneğin, FA yöntemi ile metallerin yüzey kusurları, plastik parçalardaki çatlaklar ve tahtalardaki böcek tahribatı gibi kusurların tespiti daha güvenilir hale getirilebilir.

Bu tez çalışması yüzey kusurlarının tespitine yöneliktir. Yüzeyin derinindeki veya yüzey altı kusurların tespiti için daha ileri çalışmalara ihtiyaç vardır. Ayrıca bu çalışmada lazer darbeleri malzemenin kusurlu bölümüne uygulanarak elde edilmiştir. Kusurlu bölgeden kademeli uzaklıklarda sinyaller alınarak, kusur tespiti için birtakım sınırlar çizilebilir.



KAYNAKLAR

- [1] **Chen, S. L. & Tian, C.** (2021). Recent developments in photoacoustic imaging and sensing for nondestructive testing and evaluation, *Visual Computing for Industry, Biomedicine, and Art*, 4(1), 6.
- [2] **Bell, A. G.** (1880). On the production and reproduction of sound by light, *American Journal of Science*, 20(118), 305-324.
- [3] **Beard, P. C.** (2002). Photoacoustic imaging of blood vessel equivalent phantoms, *Biomedical Optoacoustics III*, 4618, 54-62.
- [4] **Xu, M. & Wang, L. V.** (2006). Photoacoustic imaging in biomedicine, *Review of Scientific Instruments*, 77(4), 041101.
- [5] **Sun, M., Lin, X., Wu, Z., Liu, Y., Shen, Y. & Feng, N.** (2014). Non-destructive photoacoustic detecting method for high-speed rail surface defects, *IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, Montevideo, May 12-15.
- [6] **V.R., N., Mohapatra, A. K., Nayak, R., V.K., U., Kartha, V. B. & Chidangil, S.** (2022). UV laser-based photoacoustic breath analysis for the diagnosis of respiratory diseases: Detection of Asthma, *Sensors and Actuators B: Chemical*, 370, 132367.
- [7] **Yang, L., Chen, C., Zhang, Z. & Wei, X.** (2022). Glucose Determination by a Single 1535 nm Pulsed Photoacoustic Technique: A Multiple Calibration for the External Factors, *Journal of Healthcare Engineering*, 2022, 9593843.
- [8] **Li, J., Chen, Y., Ye, W., Zhang, M., Zhu, J., Zhi, W. & Cheng, Q.** (2023). Molecular breast cancer subtype identification using photoacoustic spectral analysis and machine learning at the biomacromolecular level, *Photoacoustics*, 30, 100483.
- [9] **Wu, S., Liu, Y., Chen, Y., Xu, C., Chen, P., Zhang, M., ... Cheng, Q.** (2022). Quick identification of prostate cancer by wavelet transform-based photoacoustic power spectrum analysis, *Photoacoustics*, 25, 100327.
- [10] **Jin, Y., Yin, Y., Li, C., Liu, H. & Shi, J.** (2022). Non-Invasive Monitoring of Human Health by Photoacoustic Spectroscopy, *Sensors*, 22(3), 1155.
- [11] **Tasmara, F. A., Widyaningrum, R., Setiawan, A. & Mitraryana, M.** (2023). Photoacoustic imaging of hidden dental caries using visible-light diode laser, *Journal of Applied Clinical Medical Physics*, 24(5), e13935.
- [12] **Zhang, Z., Jin, H., Zhang, W., Lu, W., Zheng, Z., Sharma, A., ... Zheng, Y.** (2023). Adaptive enhancement of acoustic resolution photoacoustic microscopy imaging via deep CNN prior, *Photoacoustics*, 30, 100484.

- [13] Nakazawa, H., Tokumine, J., Lefor, A. K., Yamamoto, K., Karasawa, H., Shimazu, K. & Yorozu, T. (2022). Use of a photoacoustic needle improves needle tip recognition in a video recording of simulated ultrasound-guided vascular access: A pilot study, *The Journal of Vascular Access*, 0, 11297298221122137.
- [14] Strahl, T., Steinebrunner, J., Weber, C., Wöllenstein, J. & Schmitt, K. (2023). Photoacoustic methane detection inside a MEMS microphone, *Photoacoustics*, 29, 100428.
- [15] Keeratirawee, K. & Hauser, P. C. (2021). Photoacoustic detection of ozone with a red laser diode, *Talanta*, 223, 121890.
- [16] Zhang, Y., Wang, M., Yu, P. & Liu, Z. (2022). Optical gas sensing of sub-ppm SO₂F₂ and SOF₂ from SF₆ decomposition based on photoacoustic spectroscopy, *IET Optoelectronics*, 16(6), 277-282.
- [17] Li, C., Qi, H., Zhao, X., Guo, M., An, R. & Chen, K. (2022). Multi-pass absorption enhanced photoacoustic spectrometer based on combined light sources for dissolved gas analysis in oil, *Optics and Lasers in Engineering*, 159, 107221.
- [18] Liao, Z., Zhang, J., Gan, Z., Wang, Y., Zhao, J., Chen, T. & Zhang, G. (2022). Thermal runaway warning of lithium-ion batteries based on photoacoustic spectroscopy gas sensing technology, *International Journal of Energy Research*, 46(15), 21694-21702.
- [19] Keeratirawee, K., Furter, J. S. & Hauser, P. C. (2022). Low-cost electronic circuitry for photoacoustic gas sensing, *HardwareX*, 11, e00280.
- [20] Kot, P., Muradov, M., Gkantou, M., Kamaris, G. S., Hashim, K. & Yeboah, D. (2021). Recent Advancements in Non-Destructive Testing Techniques for Structural Health Monitoring, *Applied Sciences*, 11(6), 2750.
- [21] Zakrzewski, J., Chigarev, N., Tournat, V. & Gusev, V. (2010). Combined Photoacoustic–Acoustic Technique for Crack Imaging, *International Journal of Thermophysics*, 31(1), 199-207.
- [22] Setiawan, A., Suparta, G. B., Mitrayana, M. & Nugroho, W. (2018). Surface Crack Detection with Low-cost Photoacoustic Imaging System, *International Journal of Technology*, 9(1), 159.
- [23] Jeon, S., Kim, J., Yun, J. P. & Kim, C. (2016). Non-destructive photoacoustic imaging of metal surface defects, *Journal of Optics*, 18(11), 114001.
- [24] Shiraishi, D., Kato, R., Endoh, H. & Hoshimiya, T. (2010). Destructive Inspection of Weld Defect and its Nondestructive Evaluation by Photoacoustic Microscopy, *Japanese Journal of Applied Physics*, 49(7S), 07HB13.
- [25] Wang, S., Tran, T., Xiang, L. & Liu, Y. (2019). Non-Destructive Evaluation of Composite and Metallic Structures using Photo-Acoustic Method, AIAA Scitech 2019 Forum, California: San Diego, Jan 7-11.
- [26] Vangi, D., Banelli, L. & Gulino, M.-S. (2021). Interference-based amplification for CW laser-induced photoacoustic signals, *Ultrasonics*, 110, 106270.

- [27] **Yan, L., Gao, C., Zhao, B., Ma, X., Zhuang, N. & Duan, H.** (2012). Non-destructive Imaging of Standard Cracks of Railway by Photoacoustic Piezoelectric Technology, *International Journal of Thermophysics*, 33(10), 2001-2005.
- [28] **Manohar, S. & Razansky, D.** (2016). Photoacoustics: a historical review, *Advances in Optics and Photonics*, 8(4), 586-617.
- [29] **Wang, L. V.** (2008). Tutorial on Photoacoustic Microscopy and Computed Tomography, *IEEE Journal of Selected Topics in Quantum Electronics*, 14(1), 171-179.
- [30] **Xu, M. & Wang, L. V.** (2005). Universal back-projection algorithm for photoacoustic computed tomography, *Physical Review E*, 71(1), 016706.
- [31] **Stylogiannis, A., Prade, L., Buehler, A., Aguirre, J., Sergiadis, G. & Ntziachristos, V.** (2018). Continuous wave laser diodes enable fast optoacoustic imaging, *Photoacoustics*, 9, 31-38.
- [32] **Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H.** (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, *Proceedings of the Royal Society of London Series A*, 454, 903-998.
- [33] **Yang, Y., Miao, C. & Deng, J.** (2013). An Analytical Expression for Empirical Mode Decomposition Based on B-Spline Interpolation, *Circuits, Systems, and Signal Processing*, 32(6), 2899-2914.
- [34] **Hu, X., Peng, S. & Hwang, W.-L.** (2012). EMD Revisited: A New Understanding of the Envelope and Resolving the Mode-Mixing Problem in AM-FM Signals, *IEEE Transactions on Signal Processing*, 60(3), 1075-1086.
- [35] **Rilling, G. & Flandrin, P.** (2006). On the influence of sampling on the empirical mode decomposition, *IEEE International Conference on Acoustics Speech and Signal Processing Proceedings*, (pp. III-III), France, May 14-19.
- [36] **Wang, G., Chen, X. Y., Qiao, F. L., Wu, Z. & Huang, N. E.** (2010). On intrinsic mode function, *Advances in Adaptive Data Analysis*, 02(03), 277-293.
- [37] **Rato, R. T., Ortigueira, M. D. & Batista, A. G.** (2008). On the HHT, its problems, and some solutions, *Mechanical Systems and Signal Processing*, 22(6), 1374-1394.
- [38] **Guyon, I. & Elisseff, A.** (2006). An Introduction to Feature Extraction. Retrieved from https://doi.org/10.1007/978-3-540-35488-8_1
- [39] **Hjorth, B.** (1970). EEG analysis based on time domain properties, *Electroencephalography and Clinical Neurophysiology*, 29(3), 306-310.
- [40] **Chicco, D.** (2017). Ten quick tips for machine learning in computational biology, *BioData Mining*, 10(1), 35.

- [41] **Alkan, A. & Seveli, O.** (2023). Türkiye’de Yapay Zekâ Alanında Yazılmış Yüksek Lisans Tezlerinin İncelenmesi, *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(1), 931-947.
- [42] **Breiman, L.** (2001). Random Forests, *Machine Learning*, 45(1), 5-32.
- [43] **Vapnik, V.** (1999). The Nature of Statistical Learning Theory. Retrived from <https://doi.org/10.1007/978-1-4757-3264-1>.
- [44] **Yahyaoui, A.** (2017). *Göğüs hastalıklarının teşhis edilmesinde makine öğrenmesi algoritmalarının kullanılması* (Doktora tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- [45] **Tuncer, E.** (2015). *Uyku evrelemesinde çeşitli dalgacık ve sınıflandırıcıların performans analizi* (Yüksek lisans tezi). Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi, Kocaeli.
- [46] **Başer, F. & Apaydin, A.** (2015). Comparison Between Logistic Regression and Support Vector Machines For Classification Purposes, *Anadolu University Journal of Science and Technology B - Theoretical Sciences*, 3(2), 53-65.
- [47] **Bagherzadi, N.** (2014). *Post operative prognostic prediction of esophageal cancer cases using bayesian networks and support vector machines* (Yüksek lisans tezi). Orta Doğu Teknik Üniversitesi, Enformatik Enstitüsü, Ankara.
- [48] **Balcı, Z.** (2018). *Ses sinyallerini kullanarak yumurta kabuğundaki çatlakların tespiti* (Yüksek lisans tezi). Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyon.
- [49] **Cover, T. & Hart, P.** (1967). Nearest neighbor pattern classification, *IEEE Transactions on Information Theory*, 13(1), 21-27.
- [50] **Bhatia, N. & Vandana.** (2010). Survey of Nearest Neighbor Techniques. *arXiv*. Retrieved December 10, 2024, from <https://doi.org/10.48550/arXiv.1007.0085>
- [51] **Paliwal, K. K. & Rao, P. V. S.** (1983). Application of k-Nearest-Neighbor Decision Rule in Vowel Recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5(2), 229-231.
- [52] **Goin, J. E.** (1984). Classification Bias of the k-Nearest Neighbor Algorithm, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(3), 379-381.
- [53] **Keller, J. M., Gray, M. R. & Givens, J. A.** (1985). A fuzzy K-nearest neighbor algorithm, *IEEE Transactions on Systems, Man, and Cybernetics*, 15(4), 580-585.
- [54] **Hattori, K. & Takahashi, M.** (1999). A new nearest-neighbor rule in the pattern classification problem, *Pattern Recognition*, 32(3), 425-432.
- [55] **Todeschini, R.** (1989). k-nearest neighbour method: The influence of data transformations and metrics, *Chemometrics and Intelligent Laboratory Systems*, 6(3), 213-220.

- [56] **Weinberger, K., Blitzer, J. & Saul, L.** (2006). Distance Metric Learning for Large Margin Nearest Neighbor Classification, *Journal of Machine Learning Research*, 10, 204-244.
- [57] **Wang, J., Neskovic, P. & Cooper, L. N.** (2007). Improving nearest neighbor rule with a simple adaptive distance measure, *Pattern Recognition Letters*, 28(2), 207-213.
- [58] **Hmeidi, I., Hawashin, B. & El-Qawasmeh, E.** (2008). Performance of KNN and SVM classifiers on full word Arabic articles, *Advanced Engineering Informatics*, 22(1), 106-111.
- [59] **Gerritsen, R.** (1999). Assessing loan risks: a data mining case study, *IT Professional*, 1(6), 16-21.
- [60] **Caruana, R. & Niculescu-Mizil, A.** (2006). An empirical comparison of supervised learning algorithms, *Proceedings of the 23rd international conference on Machine learning* (pp.161-168). USA: Association for Computing Machinery, June.
- [61] **Utgoff, P. E.** (1989). Incremental induction of decision trees, *Machine learning*, 4, 161-186.
- [62] **Öz, E.** (2020). *Makine Öğrenmesinde Sınıflandırma Yöntemleri ve Uygulamaları*. Ankara: Nobel Akademik Yayıncılık.
- [63] **Albayrak, A. S. & Yılmaz, S. K.** (2009). VERİ MADENCİLİĞİ: KARAR AĞACI ALGORİTMALARI VE İMKB VERİLERİ ÜZERİNE BİR UYGULAMA, *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 14(1).
- [64] **Quinlan, J. R.** (2014). C4.5: Programs for Machine Learning. Retrieved from <https://www.sciencedirect.com/book/9780080500584/c4-5> (Original work published 1993).
- [65] **Quinlan, J. R.** (1990). Decision trees and decision-making. *IEEE Transactions on Systems, Man, and Cybernetics*, 20(2), 339-346.
- [66] **Breiman, L.** (2017). Classification and Regression Trees. Retrieved from <https://doi.org/10.1201/9781315139470>.
- [67] **Kass, G. V.** (1980). An Exploratory Technique for Investigating Large Quantities of Categorical Data, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 29(2), 119-127.
- [68] **Lancaster, H. O. & Seneta, E.** (2005). Chi-Square Distribution. Retrieved from <https://doi.org/10.1002/0470011815.b2a15018>.
- [69] **Morgan, J. N. & Sonquist, J. A.** (1963). Problems in the Analysis of Survey Data, and a Proposal, *Journal of the American Statistical Association*, 58(302), 415-434.
- [70] **Biggs, D., De Ville, B. & Suen, E.** (1991). A method of choosing multiway partitions for classification and decision trees, *Journal of Applied Statistics*, 18(1), 49-62.
- [71] **Loh, W. Y. & Shih, Y. S.** (1997). Split Selection Methods for Classification Trees, *Statistica Sinica*, 7(4), 815-840.

- [72] **Salzberg, S. L.** (1994). C4.5: Programs for Machine Learning by J. Ross Quinlan. Morgan Kaufmann Publishers, Inc., 1993. *Machine Learning*, 16(3), 235-240.
- [73] **Quinlan, J. R.** (1986). Induction of decision trees. *Machine Learning*, 1(1), 81-106.
- [74] **Witten, I. H. & Frank, E.** (1999). Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations, *Acm Sigmod Record*, 31(1), 76-77.
- [75] **Michie, D., Spiegelhalter, D. & Taylor, C.** (1999). Machine Learning, Neural and Statistical Classification. *Technometrics*, 37.
- [76] **Rodriguez, J. J., Kuncheva, L. I. & Alonso, C. J.** (2006). Rotation Forest: A New Classifier Ensemble Method. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(10), 1619-1630.
- [77] **Friedman, J. H.** (1991). Multivariate Adaptive Regression Splines, *The Annals of Statistics*, 19(1), 1-67.
- [78] **Friedman, J. H.** (2002). Stochastic gradient boosting, *Computational Statistics & Data Analysis*, 38(4), 367-378.
- [79] **Shafer, J., Agrawal, R. & Mehta, M.** (1996). SPRINT: A scalable parallel classifier for data mining, *Vldb*, 96, 544-555.
- [80] **Larson, S. C.** (1931). The shrinkage of the coefficient of multiple correlation, *Journal of Educational Psychology*, 22(1), 45-55.
- [81] **Chamorro-Atalaya, O., Arévalo-Tuesta, J., Balarezo-Mares, D., González-Pacheco, A., Mendoza-León, O., Quipuscoa-Silvestre, M., ... Suarez-Bazalar, R.** (2023). K-Fold Cross-Validation through Identification of the Opinion Classification Algorithm for the Satisfaction of University Students, *International Journal of Online and Biomedical Engineering (iJOE)*, 19(11), 140-158.
- [82] **Wong, T. T.** (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation, *Pattern Recognition*, 48(9), 2839-2846.
- [83] **Efron, B.** (1983). Estimating the Error Rate of a Prediction Rule: Improvement on Cross-Validation, *Journal of the American Statistical Association*, 78(382), 316-331.
- [84] **Urbanowicz, R. J., Meeker, M., La Cava, W., Olson, R. S. & Moore, J. H.** (2018). Relief-based feature selection: Introduction and review, *Journal of Biomedical Informatics*, 85, 189-203.
- [85] **Kira, K. & Rendell, L. A.** (1992). A Practical Approach to Feature Selection. In D. Sleeman & P. Edwards (Ed.), *Machine Learning Proceedings* (pp.249-256). CA: Morgan Kaufmann.
- [86] **Aha, D. W., Kibler, D. & Albert, M. K.** (1991). Instance-Based Learning Algorithms, *Machine Learning*, 6(1), 37-66.
- [87] **Kononenko, I.** (1994). Estimating attributes: Analysis and extensions of RELIEF. In F. Bergadano & L. De Raedt (Ed.), *Machine Learning: ECML-94* (pp.171-182). Berlin: Springer.

- [88] **Greene, C. S., Penrod, N. M., Kiralis, J. & Moore, J. H.** (2009). Spatially Uniform ReliefF (SURF) for computationally-efficient filtering of gene-gene interactions, *BioData Mining*, 2(1), 5.
- [89] **Reyes, O., Morell, C. & Ventura, S.** (2015). Scalable extensions of the ReliefF algorithm for weighting and selecting features on the multi-label learning context, *Neurocomputing*, 161, 168-182.
- [90] **Zafra, A., Pechenizkiy, M. & Ventura, S.** (2012). ReliefF-MI: An extension of ReliefF to multiple instance learning, *Neurocomputing*, 75(1), 210-218.
- [91] **Robnik-Šikonja, M. & Kononenko, I.** (2003). Theoretical and Empirical Analysis of ReliefF and RReliefF, *Machine Learning*, 53(1), 23-69.
- [92] **Url-1** < <https://epc-co.com/epc/products/evaluation-boards/epc9126>>, date retrieved 04.12.2023.
- [93] **Cyr, B., Sugawara, T. & Fu, K.** (2021). Why Lasers Inject Perceived Sound Into MEMS Microphones: Indications and Contraindications of Photoacoustic and Photoelectric Effects. *In 2021 IEEE Sensors*, (pp.1-4). Australia: IEEE, October 31- November 03.
- [94] **Hanif, L. N., Satriawan, M. & Mitrayana, M.** (2022). The characterization of a photoacoustic tomography imaging system and its application to distinguish healthy liver and worm-infected liver. *In AIP Conference Proceedings*, 2391(1).
- [95] **Liu, L., Huan, H., Zhang, M., Shao, X., Zhao, B., Cui, X. & Zhu, L.** (2019). Photoacoustic Spectrometric Evaluation of Soil Heavy Metal Contaminants, *IEEE Photonics Journal*, 11(2), 1-7.
- [96] **Hu, H., Zhang, L., Yan, H., Bai, Y. & Wang, P.** (2019). Denoising and Baseline Drift Removal Method of MEMS Hydrophone Signal Based on VMD and Wavelet Threshold Processing, *IEEE Access*, 7, 59913-59922.
- [97] **Fisher, R. A.** (1915). Frequency Distribution of the Values of the Correlation Coefficient in Samples from an Indefinitely Large Population, *Biometrika*, 10(4), 507-521.


EKLER

EK A: EPC9126xx Lazer sürücü kartı şematığı

EK B: Tez için tasarlanan lazer sürücü kartı şematığı




EK A



Şekil A.1 : EPC9126xx Lazer sürücü kartı şematığı.

EK B



Şekil B.1 : Tez için tasarlanan lazer sürücü kartı şematiği.

ÖZGEÇMİŞ

Ad-Soyad : Zekeriya BALCI

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2016, Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2018, Afyon Kocatepe Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektrik Elektronik Mühendisliği Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Öğretim Görevlisi- Yüzüncü Yıl Üniversitesi (2019 - ...)

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Farklı Katı Malzemelerde Görgül Kip Analizi Tabanlı Foto Akustik Sinyal İşleme ile Kusur Tespiti- Journal of Materials and Mechatronics: A (Kabul tarihi: 3 Mart 2024)
- Enhanced Photoacoustic Signal Processing Using Empirical Mode Decomposition and Machine Learning for Cross-Material Defect Detection (Hakem değerlendirmesinde)

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- **BALCI, Z., YUMURTACI, M., YABANOVA, İ., ERGİN, S.** (2021). Yumurta Kabuğundan Alınan Akustik Sinyalin Dalgacık Paket Dönüşümü ve Entropiye Dayalı Olarak İşlenmesi ve Yapay Sinir Ağlarıyla Çatlağın Belirlenmesi. Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi, 8(1), 125-135. <https://doi.org/10.35193/bseufbd.847763>
- **BALCI, Z., & YABANOVA, İ.** (2022). Artificial Intelligence Based Determination of Cracks in Eggshell Using Sound Signals. Sakarya University Journal of Science, 26(3), 579-589. <https://doi.org/10.16984/saufenbilder.848213>
- **ÇINAR, S. M., BALCI, Z., & YABANOVA, İ.** (2019). Performing Speed Control of a DC Motor with Auto-Tuning PID. Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 19(3), 690-696. <https://doi.org/10.35414/akufemubid.593609>

- **YUMURTACI, M., BALCI, Z., ERGİN, S., & YABANOVA, İ.** (2022). The Detection of Eggshell Cracks Using Different Classifiers. *Eskişehir Technical University Journal of Science and Technology A-Applied Sciences and Engineering*, 23(2), 161-172.

