

**Diferansiyel Hiperspektral Görüntüleme Tekniđi ile Kimyasal
Madde Tespit Yöntemlerinin İncelenmesi**

**Investigation of Chemical Substance Detection Algorithms
Using Differential Hyperspectral Imaging**

FIRAT GÜRBÜZ

Dr. SENİHA ESEN YÜKSEL
Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliđinin
Elektrik ve Elektronik Mühendisliđi Anabilim Dalı için Öngördüđü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır
2019

FIRAT GÜRBÜZ 'ün hazırladığı “Diferansiyel Hiperspektral Görüntüleme Tekniği ile Kimyasal Madde Tespit Yöntemlerinin İncelenmesi” adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Özgül SALOR DURNA

Başkan



Dr. Öğr. Üyesi Seniha Esen YÜKSEL

Danışman



Doç. Dr. Berkan DÜLEK

Üye



Dr. Öğr. Üyesi Yakup ÖZKAZANÇ

Üye



Doç. Dr. Cenk TOKER

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak/...../..... tarihinde onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

ETİK

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

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

beyan ederim.

13.10.2019

 İmza

FIRAT GÜRBÜZ

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesi'ne verdiğimi bildiririm. Bu izinle üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istendiğinde suretlerini üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan "**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**" kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılmasına mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- Enstitü / Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihinden itibaren ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

13.02.2019

 İmza

FIRAT GÜRBÜZ

ÖZET

Diferansiyel Hiperspektral Görüntüleme Tekniđi ile Kimyasal Madde Tespit Yöntemlerinin İncelenmesi

Fırat GÜRBÜZ

Yüksek Lisans, Elektrik ve Elektronik Mühendisliđi Bölümü

Tez Danışmanı: Dr. Seniha Esen YÜKSEL

Ocak 2019, 170 sayfa

Sunulan tez kapsamında, çeşitli kimyasal maddelerin farklı arka plan materyalleri üzerindeki diferansiyel spektral yansımaları için bazı sınıflandırma algoritmalarının hedef tespit performansları incelenmiştir. Çalışmada öncelikle, aktif bir kamera sistemi ile taşıyıcı kayış ile hareket eden farklı madde ve materyallerin farklı dalga boylarında toplanan yansımaları için normalize edilmiş diferansiyel spektral yansımaları bulunmuştur. Gürültülü olan bu yansımalar üzerinde Savitzky-Golay Filtresi, Hareketli Ortalama Filtresi, Gaussian Filtre ve Medyan Filtresi algoritmaları ile farklı parametrelerde filtreleme çalışmaları yapılmış ve sonuçlar incelenmiştir. Bu inceleme sonucunda seçilen filtre tipi ve parametre ile filtrelenmiş verilerin sınıflandırılması için 2 farklı kategoride sınıflandırma algoritması kullanılmıştır. Öznitelik tabanlı sınıflandırma kategorisindeki Destek Vektör Makineleri algoritması için öncelikle bir öznitelik çıkarma yöntemi olan Temel Bileşenler Analizi uygulanmıştır. Temel Bileşenler Analizi yöntemi ile seçilen öznitelikler için farklı parametreler ile Destek Vektör Makineleri uygulanmış ve en iyi performansı gösteren parametrelerle uygulanan Destek Vektör Makineleri sonuçları incelenmiştir. İmza tabanlı sınıflandırma kategorisinde ise Uyumlu Filtre ve Spektral Açık Eşleyici algoritmaları kullanılmıştır. Kullanılan bütün sınıflandırma algoritmalarının performansları karşılaştırılmış birbirine göre iyi ve kötü yanları incelenmiştir. Daha sonra, sınıflandırma algoritmalarının yanlış pozitif sayısını azaltarak performansını arttırmak amacıyla bu tez

kapsamında geliştirilen son işleme algoritmaları kullanılmıştır. İlk olarak, her maddenin kendi kimyasal özelliklerine göre arka plan materyalinden bağımsız olarak belirli bir dalga boyu aralığında diferansiyel yansımada bir yükseliş ya da düşüş olduğu görülmüş ve bu bilginin kullanıldığı Eğim Eşikleme algoritması geliştirilmiştir. Sınıflandırma işleminden sonra, seçilen dalga boyu aralığındaki bu yükseliş veya düşüşün eğiminin belirli bir eşik değerinden yüksek olmasını sağlayan Eğim Eşikleme algoritması veri üzerinde uygulanmış ve beklendiği gibi doğru pozitif sayısında ciddi bir düşüş olmadan yanlış pozitif sayısının azaldığı gözlemlenmiştir. Bir diğer son işleme algoritması olan ve arka plan verileri üzerindeki az sayıdaki hatanın giderilmesini sağlayan Piksel Kaldırma algoritması da bu tez kapsamında geliştirilmiştir. Sonuç olarak, bu tezde diferansiyel hiperspektral görüntüleme tekniği ile kimyasal madde tespitinin yapılabileceği görülmüş ve bunu sağlayan farklı algoritmalar karşılaştırılmıştır.

Anahtar Kelimeler: Hiperspektral, Diferansiyel Yansımada, Kimyasal Madde Tespiti, Sınıflandırma, Temel Bileşenler Analizi (TBA), Destek Vektör Makineleri (DVM), Uyumlu Filtre (UF), Spektral Açık Eşleyici (SAE)

ABSTRACT

Investigation of Chemical Substance Detection Algorithms Using Differential Hyperspectral Imaging

Fırat GÜRBÜZ

Master of Science, Department of Electrical and Electronics Engineering

Supervisor: Dr. Seniha Esen YÜKSEL

January 2019, 170 pages

The aim of this thesis is to investigate the performance of some classification algorithms for differential spectral reflections of different chemical materials on different background materials. In the study, firstly, differential spectral reflections have been calculated for the reflections, that have been collected in different wavelengths by the active camera system, of different substances and materials that move with conveyor belt. On these noisy reflections, different parameters of Savitzky-Golay Filter, Moving Average Filter, Gaussian Filter and Median Filter algorithms have been studied and the results were examined. As a result of filtering, the classification algorithm is used to classify the filtered data with the selected filter type and selected parameters. For the Support Vector Machines algorithm in the feature-based classification category, a feature extraction method, Principal Component Analysis, is applied. Then, Support Vector Machines are examined with different parameters for the selected features by Principle Component Analysis method and the results of Support Vector Machines with the best parameters according to performance are analyzed. In the signature-based classification category, Matched Filter and Spectral Angle Mapper algorithms are used. The performances of all classification algorithms were compared and analyzed the good and bad sides of each other. Then, in order to increase the performance of classification algorithms by decreasing the number of false positives, the final processing algorithms developed in this thesis have been used. First of all, it has been observed that each substances according to their chemical characteristics regardless of the background material had an increase or decrease in the

differential reflection in a certain wavelength range, and the Slope Thresholding algorithm which uses this information has been developed. After the classification process, the Slope Thresholding algorithm which provides the slope of this increase or decrease in the selected wavelength range to be higher than a certain threshold value, has been applied on data, and it is observed that the number of false positives decreased without a significant decrease in the number of true positive number as expected. The Pixel Removal algorithm, which is another final processing algorithm and which allows the removal of a few errors on the background data, has also been developed within the scope of this thesis. As a result, in this thesis, it has been demonstrated that chemical substances could be detected by using differential hyperspectral imaging technique and different algorithms that provide this detection have been compared.

Anahtar Kelimeler: Hyperspectral, Differential Reflection, Chemical Substance Detection, Classification, Principle Component Analysis (PCA), Support Vector Machines (SVM), Matched Filter (MF), Spectral Angle Mapper (SAM)

TEŐEKKÜR

Arařtırmalarım süresince desteklerini esirgemeyen, bilgi ve tecrübelerinden her alanda faydalandığım deęerli tez danıřmanım Sayın Dr. Seniha Esen YÜKSEL'e

Lisansüstü eęitimim boyunca her koşulda yanımda olan ve bundan sonraki hayatım boyunca da hep yanımda olmasını dilediğim sevgili eřim Merve KOÇYİĐİT GÜRBÜZ'e

Tüm öğretim hayatım boyunca beni destekleyen, önceliklerini her zaman benim önceliklerime göre deęiřtiren, bugünlere gelmemde en büyük katkıyı saęlayan aileme,

Sonsuz Teőekkürler...

Fırat GÜRBÜZ

Ocak 2019, Ankara

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
İÇİNDEKİLER.....	vi
ŞEKİLLER LİSTESİ.....	viii
TABLolar LİSTESİ.....	xiii
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	3
1.2. Tezin Akışı.....	3
2. KİMYASAL MADDE TESPİTİ İÇİN KULLANILAN YÖNTEMLER.....	4
3. KULLANILAN VERİLERİN İNCELENMESİ.....	7
4. KULLANILAN YÖNTEMLER.....	10
4.1. Ön İşleme.....	10
4.1.1. Diferansiyel Alma.....	10
4.1.2. Savitzky-Golay Filtresi.....	11
4.1.3. Hareketli-Ortalama Filtresi.....	14
4.1.4. Gaussian Filtre.....	15
4.1.5. Medyan Filtresi.....	15
4.2. Sınıflandırma.....	15
4.2.1. Öznitelik tabanlı sınıflandırma.....	16
4.2.1.1. Öznitelik Çıkartmak - TBA.....	16
4.2.1.2. Destek Vektör Makineleri - DVM.....	20
4.2.2. İmza Tabanlı Sınıflandırma.....	25
4.2.2.1. Uyumlu Filtre.....	25
4.2.2.2. Spektral Açık Eşleyici.....	26
4.3. Son İşleme.....	27
4.3.1. Eğim Eşikleme.....	27
4.3.2. Piksel Silme.....	29
5. DENEYSEL SONUÇLAR.....	30
5.1. Ön İşleme İçin Deneysel Sonuçlar.....	31
5.1.1. Diferansiyel Alma Sonuçları.....	34

5.1.2.	S.Golay Filtresi Sonuçları.....	38
5.1.3.	Hareketli-Ortalama Filtresi Sonuçları	51
5.1.4.	Gaussian Filtresi Sonuçları	55
5.1.5.	Medyan Filtre Sonuçları	60
5.2.	Ön İşleme Sonuçlarının İncelenmesi	64
5.3.	Sınıflandırma İçin Deneysel Sonuçlar.....	65
5.3.1.	Öznitelik Tabanlı Sınıflandırma Sonuçları	69
5.3.1.1.	Temel Bileşenler Analizi Sonuçları	69
5.3.1.2.	Destek Vektör Makineleri Sonuçları	71
5.3.2.	İmza Tabanlı Sınıflandırma Sonuçları	92
5.3.2.1.	Uyumlu Filtre Sonuçları	92
5.3.2.2.	Spektral Açık Eşleyici Sonuçları	111
5.4.	Sınıflandırma Sonuçlarının İncelenmesi	118
5.5.	Son İşleme İçin Deneysel Sonuçlar	122
5.5.1.	Eğim Eşikleme.....	122
5.5.2.	Piksel Kaldırma	153
5.6.	Son İşleme Sonuçlarının İncelenmesi	153
6.	SONUÇLAR VE ÖNERİLER	159
	KAYNAKLAR.....	163
	EK 1 - Tez Çalışması Orjinallik Raporu	169
	ÖZGEÇMİŞ	170

ŞEKİLLER LİSTESİ

Şekil 1. Hiperspektral Veri Küpü Örneği	2
Şekil 2. Veri Toplama Sistemi Şematik Gösterimi	7
Şekil 3. Materyal-2 Üzerine Üçgen Biçiminde Konan Madde-1	9
Şekil 4. S.Golay Filtresinde Polinom Uydurma	12
Şekil 5. Temel Bileşenler Analizi	17
Şekil 6. Destek Vektör Makineleri Örnek Veri İncelemesi	20
Şekil 7. İki İmza Arasındaki Açık ve Kosinüsü	27
Şekil 8. Materyal-1 Üzerindeki Ham Madde-1 Verisi (Dalga boyu: 320nm)	32
Şekil 9. Seçilen Hedef Ve Arka Plan Verilerinin Ham Veri Üzerindeki Konumları	33
Şekil 10. Bir Pikselin Dalga Boyuna Göre Yansıma Değerleri.....	34
Şekil 11. Materyal-1 Üzerindeki Diferansiyel Madde-1 Verisi (Dalga Boyu: 320nm)	35
Şekil 12. Diferansiyel İşlemi Sonrası Dalga Boyuna Göre Madde-1 ve Arka Plan Yansıma Grafiği	36
Şekil 13. S.Golay (Derece:2 Çerçeve:21) ile Filtrelenmiş Madde-1 ve Arka Plan Yansıma Grafiği	37
Şekil 14. Pozitif ve Negatif Yöndeki Madde-1 Verileri.....	38
Şekil 15a. S.Golay Filtresi (Derece:1, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi	39
Şekil 15b. S.Golay Filtresi (Derece:1, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi	39
Şekil 15c. S.Golay Filtresi (Derece:1, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi.....	40
Şekil 15ç. S.Golay Filtresi (Derece:1, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi	40
Şekil 15d. S.Golay Filtresi (Derece:2, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi	41
Şekil 15e. S.Golay Filtresi (Derece:2, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi	41
Şekil 15f. S.Golay Filtresi (Derece:2, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi.....	42
Şekil 15g. S.Golay Filtresi (Derece:2, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi	42
Şekil 15ğ. S.Golay Filtresi (Derece:4, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi	43
Şekil 15h. S.Golay Filtresi (Derece:4, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi	43
Şekil 15ı. S.Golay Filtresi (Derece:4, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi.....	44
Şekil 15i. S.Golay Filtresi (Derece:4, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi	44
Şekil 16a. S.Golay Filtresi (Derece:1, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi	45
Şekil 16b. S.Golay Filtresi (Derece:1, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi	45
Şekil 16c. S.Golay Filtresi (Derece:1, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi	46
Şekil 16ç. S.Golay Filtresi (Derece:1, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi.....	46
Şekil 16d. S.Golay Filtresi (Derece:2, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi	47
Şekil 16e. S.Golay Filtresi (Derece:2, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi	47
Şekil 16f. S.Golay Filtresi (Derece:2, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi	48
Şekil 16g. S.Golay Filtresi (Derece:2, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi.....	48
Şekil 16ğ. S.Golay Filtresi (Derece:4, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi	49
Şekil 16h. S.Golay Filtresi (Derece:4, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi	49
Şekil 16ı. S.Golay Filtresi (Derece:4, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi	50
Şekil 16i. S.Golay Filtresi (Derece:4, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi.....	50
Şekil 17a. Hareketli Ortalama Filtresi (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi.....	51
Şekil 17b. Hareketli Ortalama Filtresi (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi.....	52

Şekil 17c. Hareketli Ortalama Filtresi (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi	52
Şekil 17ç. Hareketli Ortalama Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi.....	53
Şekil 18a. Hareketli Ortalama Filtresi (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi	53
Şekil 18b. Hareketli Ortalama Filtresi (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi	54
Şekil 18c. Hareketli Ortalama Filtresi (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi	54
Şekil 18ç. Hareketli Ortalama Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi	55
Şekil 19a. Gaussian Filtresi (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi	56
Şekil 19b. Gaussian Filtresi (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi	56
Şekil 19c. Gaussian Filtresi (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi	57
Şekil 19ç. Gaussian Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi.....	57
Şekil 20a. Gaussian Filtresi (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi.....	58
Şekil 20b. Gaussian Filtresi (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi.....	58
Şekil 20c. Gaussian Filtresi (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi.....	59
Şekil 20ç. Gaussian Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi	59
Şekil 21a. Medyan Filtre (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi.....	60
Şekil 21b. Medyan Filtre (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi.....	61
Şekil 21c. Medyan Filtre (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi.....	61
Şekil 21ç. Medyan Filtre (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi	62
Şekil 22a. Medyan Filtre (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi	62
Şekil 22b. Medyan Filtre (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi	63
Şekil 22c. Medyan Filtre (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi	63
Şekil 22ç. Medyan Filtre (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi.....	64
Şekil 23a. Materyal-1 Üzerindeki Filtrelenmiş Madde-1 Verisi	66
Şekil 23b. Materyal-2 Üzerindeki Filtrelenmiş Madde-1 Verisi	67
Şekil 23c. Materyal-3 Üzerindeki Filtrelenmiş Madde-1 Verisi	67
Şekil 23ç. Materyal-4 Üzerindeki Filtrelenmiş Madde-1 Verisi	68
Şekil 23d. Materyal-5 Üzerindeki Filtrelenmiş Madde-1 Verisi	68
Şekil 24. Temel Bileşenler Analizi Özdeğerlerin Logaritmik Gösterimi	69
Şekil 25. Hedef Ve Arka Plan Verilerinin İki Boyutta İncelenmesi.....	70
Şekil 26a. Çekirdek Ölçeği:0.3 Ceza Sabiti:1 Olan Destek Vektör Makineleri.....	71
Şekil 26b. Çekirdek Ölçeği:0.3 Ceza Sabiti:10 Olan Destek Vektör Makineleri.....	72
Şekil 26c. Çekirdek Ölçeği:0.3 Ceza Sabiti:1000 Olan Destek Vektör Makineleri.....	72
Şekil 26ç. Çekirdek Ölçeği:1 Ceza Sabiti:1 Olan Destek Vektör Makineleri	73
Şekil 26d. Çekirdek Ölçeği:1 Ceza Sabiti:10 Olan Destek Vektör Makineleri	73
Şekil 26e. Çekirdek Ölçeği:1 Ceza Sabiti:1000 Olan Destek Vektör Makineleri.....	74
Şekil 26f. Çekirdek Ölçeği:10 Ceza Sabiti:1 Olan Destek Vektör Makineleri	74
Şekil 26g. Çekirdek Ölçeği:10 Ceza Sabiti:10 Olan Destek Vektör Makineleri.....	75
Şekil 26ğ. Çekirdek Ölçeği:10 Ceza Sabiti:1000 Olan Destek Vektör Makineleri	75
Şekil 27a. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları	77
Şekil 27b. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları	77
Şekil 27c. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları.....	78
Şekil 27ç. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları.....	78
Şekil 27d. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları	79
Şekil 28a. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları	79

Şekil 28b. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları	80
Şekil 28c. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları.....	80
Şekil 28ç. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları.....	81
Şekil 28d. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları	81
Şekil 29a. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları	82
Şekil 29b. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları	82
Şekil 29c. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları.....	83
Şekil 29ç. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları.....	83
Şekil 29d. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları	84
Şekil 30a. Arka Plan Verileri (Örnek-1) İçin DVM Sonuçları	84
Şekil 30b. Arka Plan Verileri (Örnek-2) İçin DVM Sonuçları	85
Şekil 30c. Arka Plan Verileri (Örnek-3) İçin DVM Sonuçları	85
Şekil 30ç. Arka Plan Verileri (Örnek-4) İçin DVM Sonuçları	86
Şekil 30d. Arka Plan Verileri (Örnek-5) İçin DVM Sonuçları	86
Şekil 31. Madde-1 Verisi İçin DVM ROC Eğrisi	89
Şekil 32. Madde-1 Verisi İçin DVM PR Eğrisi	89
Şekil 33. Materyal-4 Verisi Çıkartıldıktan Sonra Madde-1 Verisi İçin DVM ROC Eğrisi	91
Şekil 34. Materyal-4 Verisi Çıkartıldıktan Sonra Madde-1 Verisi İçin DVM PR Eğrisi.....	91
Şekil 35. Hedef Olarak Seçilen Madde-1 Verilerinin İmzaları.....	92
Şekil 36. Madde-1 İçin Uyumlu Filtre ROC Eğrisi.....	93
Şekil 37. Madde-1 İçin Uyumlu Filtre PR Eğrisi.....	94
Şekil 38a. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları	95
Şekil 38b. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları	95
Şekil 38c. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları	96
Şekil 38ç. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları	96
Şekil 38d. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları.....	97
Şekil 39a. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları	97
Şekil 39b. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları	98
Şekil 39c. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları	98
Şekil 39ç. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları	99
Şekil 39d. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları.....	99
Şekil 40a. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları	100
Şekil 40b. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları	100
Şekil 40c. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları	101
Şekil 40ç. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları	101
Şekil 40d. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları.....	102
Şekil 41a. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları	102
Şekil 41b. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları	103
Şekil 41c. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları	103
Şekil 41ç. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları	104
Şekil 41d. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları.....	104
Şekil 42a. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları	105
Şekil 42b. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları.....	105
Şekil 42c. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları	106

Şekil 42ç. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları	106
Şekil 42d. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları	107
Şekil 43a. Arka Plan Verileri (Örnek-1) İçin UF Sonuçları	107
Şekil 43b. Arka Plan Verileri (Örnek-2) İçin UF Sonuçları	108
Şekil 43c. Arka Plan Verileri (Örnek-3) İçin UF Sonuçları	108
Şekil 43ç. Arka Plan Verileri (Örnek-4) İçin UF Sonuçları	109
Şekil 43d. Arka Plan Verileri (Örnek-5) İçin UF Sonuçları	109
Şekil 44. Madde-1 için Spektral Açık Eşleyici PR Eğrisi	112
Şekil 45a. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-1) İçin SAE Sonuçları	113
Şekil 45b. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-2) İçin SAE Sonuçları	113
Şekil 45c. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-3) İçin SAE Sonuçları	114
Şekil 45ç. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-4) İçin SAE Sonuçları	115
Şekil 45d. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-5) İçin SAE Sonuçları	115
Şekil 46 Madde-1 için Spektral Açık Eşleyici ROC Eğrisi	116
Şekil 47. Tüm Verilerde DVM, UF ve SAE İçin ROC Eğrilerinin Karşılaştırılması	118
Şekil 48. Tüm Verilerde DVM, UF ve SAE İçin PR Eğrilerinin Karşılaştırılması	119
Şekil 49. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için ROC Eğrilerinin Karşılaştırılması	120
Şekil 50. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için PR Eğrilerinin Karşılaştırılması	120
Şekil 51. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için ROC Eğrilerinin Karşılaştırılması (Yakınlaştırılmış)	121
Şekil 52a. Materyal-1 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi	123
Şekil 52b. Materyal-2 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi	124
Şekil 52c. Materyal-3 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi	124
Şekil 52ç. Materyal-4 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi	125
Şekil 52d. Materyal-5 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi	125
Şekil 53a. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-1)	127
Şekil 53b. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-2)	127
Şekil 53c. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-3)	128
Şekil 53ç. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-4)	128
Şekil 53d. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-5)	129
Şekil 54a. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-1)	129
Şekil 54b. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-2)	130
Şekil 54c. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-3)	130
Şekil 54ç. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-4)	131
Şekil 54d. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-5)	131
Şekil 55a. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-1)	132
Şekil 55b. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-2)	132
Şekil 55c. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-3)	133
Şekil 55ç. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-4)	133
Şekil 55d. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-5)	134
Şekil 56a. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-1)	134
Şekil 56b. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-2)	135
Şekil 56c. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-3)	135

Şekil 56ç. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-4)	136
Şekil 56d. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-5)	136
Şekil 57a. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-1)	137
Şekil 57b. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-2)	137
Şekil 57c. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-3)	138
Şekil 57ç. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-4)	138
Şekil 57d. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-5)	139
Şekil 58a. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-1)	139
Şekil 58b. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-2)	140
Şekil 58c. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-3)	140
Şekil 58ç. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-4)	141
Şekil 58d. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-5)	141
Şekil 59a. Eğitim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-1)	142
Şekil 59b. Eğitim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-2)	142
Şekil 59c. Eğitim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-3)	143
Şekil 59ç. Eğitim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-4)	143
Şekil 59d. Eğitim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-5)	144
Şekil 60a. Eğitim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-1)	144
Şekil 60b. Eğitim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-2)	145
Şekil 60c. Eğitim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-3)	145
Şekil 60ç. Eğitim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-4)	146
Şekil 60d. Eğitim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-5)	146
Şekil 61a. Eğitim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-1)	147
Şekil 61b. Eğitim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-2)	147
Şekil 61c. Eğitim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-3)	148
Şekil 61ç. Eğitim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-4)	148
Şekil 61d. Eğitim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-5)	149
Şekil 62a. Eğitim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-1)	149
Şekil 62b. Eğitim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-2)	150
Şekil 62c. Eğitim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-3)	150
Şekil 62ç. Eğitim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-4)	151
Şekil 62d. Eğitim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-5)	151
Şekil 63. İki Farklı Tipteki Yanlış Pozitif Piksellerinin Materyal-5 (Örnek-5) Verisi Üzerindeki Konumları	155
Şekil 64. İki Farklı Tipteki Yanlış Pozitif Piksellerinin Filtrelenmiş Diferansiyel Yansımaları	156
Şekil 65. Seçilen Yanlış Negatif Pikselin Konumu	157
Şekil 66. Seçilen Yanlış Negatif Pikselinin Filtrelenmiş Diferansiyel Yansıması	158
Şekil 67. Algoritma Akış Diyagramı	160

TABLolar LİSTESİ

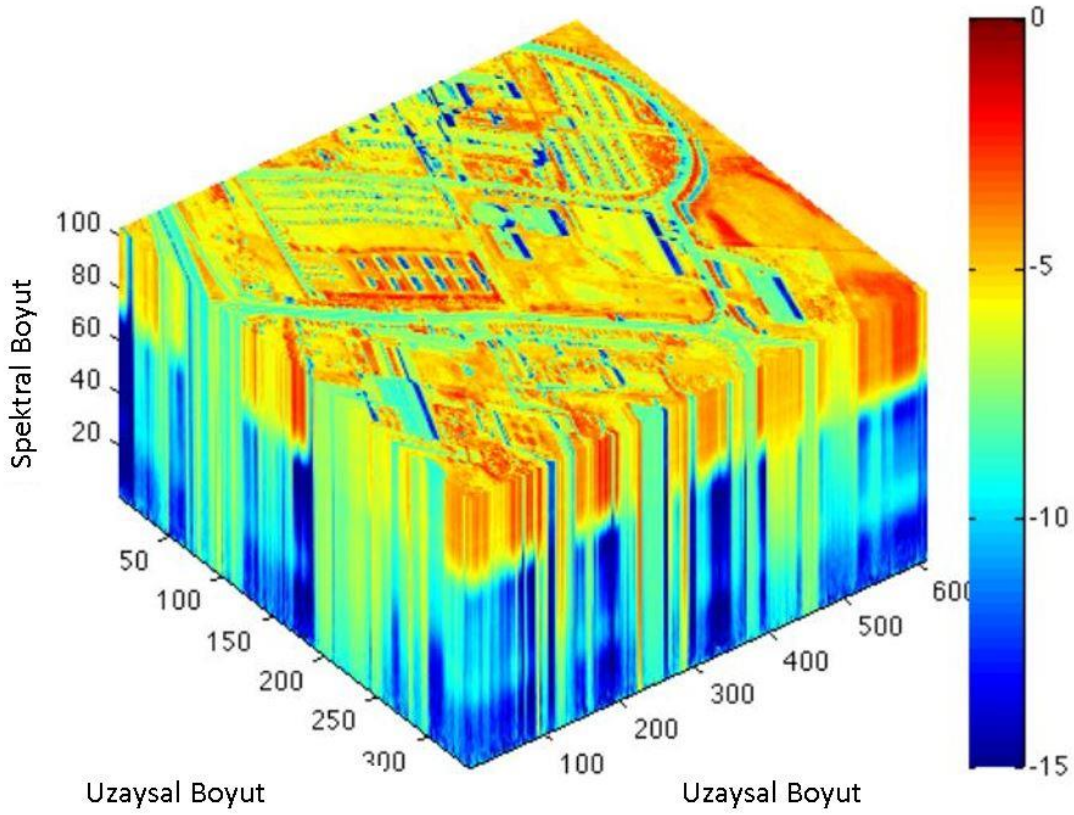
Tablo 1. S.Golay Filtresi Katsayı Tablosu	14
Tablo 2. Hedef Verilerinin Boyutları	30
Tablo 3. Arka Plan Verilerinin Boyutları	31
Tablo 4. Madde-1 Verisi İin DVM Sonuları	87
Tablo 5. Madde-1 Verisi İin DVM Performansı	87
Tablo 6. Materyal-4 verisi ıkarıldıktan sonra Madde-1 Verisi İin DVM Performansı.....	90
Tablo 7. Madde-1 Verisi İin UF Sonuları.....	110
Tablo 8. Madde-1 Verisi İin UF Performansı.....	110
Tablo 9. Madde-1 Verisi İin SAE Sonuları	117
Tablo 10. Madde-1 Verisi İin SAE Performansı	117
Tablo 11. Eėim Eėikleme Sonrası DVM ve UF Sonuları	152
Tablo 12. Eėim Eėikleme Sonrası DVM ve UF Performansları	152
Tablo 13. Son İėlemenin DVM ve UF Sonularına Etkisi	154

1. GİRİŞ

Son yıllarda artan terör olayları, bu terör olaylarını önceden tespit etmek amacıyla yapılan çalışmaları da hızlandırmıştır. Özellikle insanların toplu halde bulunduğu parklar, havaalanları, konserler, toplu taşıma araçları gibi alanlarda oluşabilecek tehditleri en aza indirmek için çalışmalar yapılmaktadır [1]. Yapılan çalışmaların çokluğuna rağmen, kullanılan tehlikeli maddelerin çeşitliliğinin her geçen gün artması, paketlenme/taşıma yöntemlerinin değişmesi, gelişen teknikler ile daha düşük miktarlarda madde ile daha fazla etki sağlanabilmesi, kimyasal madde tespitini zorlaştırmakta ve bu konuda daha fazla çalışma yapılmasını gerektirmektedir [2]. Tespit edilmeye çalışılan kimyasal maddeler, patlayıcı/parlayıcı özellikteki tehlikeli maddeler olabileceği gibi, kokain, eroin, vb. gibi kullanımı yasaklanmış uyuşturucu maddeler de olabilir.

Madde ile herhangi bir temas olmadan maddenin özelliği hakkında bilgi sahibi olmak anlamına gelen Uzaktan Algılama (Remote Sensing), farklı algılayıcı teknolojileri ile birlikte tarım, haritacılık, jeoloji, savunma gibi alanlarda olduğu gibi güvenlik için geliştirilen sistemlerde de kullanılan önemli bir fenomendir. Özellikle patlayıcı gibi yakından zarar verebilecek maddelerin hızlı ve doğru tespiti için uzaktan algılama teknikleri önemli bir yere sahiptir. Uzaktan Algılama için geliştirilen sistemler aktif ve pasif olmak üzere ikiye ayrılmaktadır. RADAR, Lidar, SAR gibi aktif uzaktan algılama sistemleri kendi yaydıkları enerjinin geriye dönüşünü kullanarak veri oluştururken, pasif sistemler uzaktan algılama için herhangi bir enerji üretmezler, güneşten gelen veya maddelerin iç enerjisini kullanarak veri oluştururlar [3].

Uzaktan Algılama için geliştirilen hiperspektral görüntüleme teknolojisi, yeryüzü ile ilgili bilgi toplamak amacıyla uydu üzerinde kullanılmaya başlanmış olup, gelişen teknoloji sonucunda algılayıcı maliyetlerinin azalması ile endüstride birçok alanda kullanılmaktadır[4]. Hiperspektral görüntüleme, bir görüntüdeki uzamsal olarak iki boyutta bulunan her piksel için farklı dalga boylarındaki (genellikle 100'den fazla) spektral yansımaların oluşturduğu veri setine denir [5]. Hiperspektral görüntüler aşağıda görüldüğü gibi 2 uzamsal boyut 1 spektral boyut olmak üzere 3 boyutlu bir veri küpü oluştururlar [6]. Örnek bir hiperspektral verisi Şekil 1'de gösterilmiştir. Farklı maddelerin içsel özelliklerine göre spektral yansımaları farklı olmaktadır.



Şekil 1. Hiperspektral Veri Küpü Örneği

Hiperspektral görüntüleme pasif olarak yapılabileceği gibi Diferansiyel Yansımaya Spektroskopi tekniğinde olduğu gibi aktif bir şekilde de yapılabilir. Diferansiyel Yansımaya terimini ilk defa R.E. Hummel 1970 yılında, maddelerin optik özelliklerini (yansımaya, soğurma, iletme) anlayabilmek için yaptığı çalışmada ortaya koymuştur [7]. Diferansiyel Yansımaya Spektroskopi tekniğinde, incelenmek istenen materyal spektrumunun genellikle UV-görünür-yakın kızıl ötesi bölgelerinde aydınlatılır ve materyalin enerji soğurması sağlanır [8]. Her maddenin kendisine özgü elektron yapısı olduğu için soğurulan bu enerji sonrası yapacağı spektral yansımaya da maddeye özgü olacaktır [8]. Diferansiyel spektrometre ile birbirine komşu iki pikselin enerji farkının, ortalama enerjiye bölünmesiyle materyalin “normalize edilmiş diferansiyel spektral yansımaya” bulunur.

Anna Marie Fuller [9] patlayıcı özelliği bulunan enerjik maddeler ile yaptığı çalışmasında, özellikle UV ve mavi görünür spektrum bölgelerinde aydınlatıldığında bu maddelerin karakteristik diferansiyel spektral yansıması olduğunu ortaya koymuştur. Literatürde, karakteristik olan bu spektral yansımaların birbirinden ayırt edilmesi için gerçekleştirilen çalışmalar bulunmaktadır [10][11].

1.1. Tezin Amacı

Bu tez kapsamında, farklı arka plan üzerindeki çeşitli kimyasal maddelerin diferansiyel spektral yansımaları kullanılarak bazı sınıflandırma algoritmalarının hedef tespit performansları incelenmiştir. Bu çalışma ile ayrıca, kimyasal maddenin cinsi, arka plandaki materyalin cinsi ve kimyasal maddenin miktarının, patlayıcı tespit performansına olan etkisi incelenmiştir. Bu tezdeki çalışmalar sayesinde düşük yanlış alarm ile birlikte yüksek doğruluk oranı olan bir patlayıcı tespit sisteminin geliştirilmesi amaçlanmıştır.

1.2. Tezin Akışı

Bölüm 2’de kimyasal madde tespiti için kullanılan yöntemler ve yapılan çalışmalar özetlenmiştir. Bölüm 3’te tez kapsamında kullanılan veri hakkında genel bilgi verilmiştir. Bölüm 4’te ise tez boyunca kullanılan algoritmalar ile ilgili teorik bilgiler verilmiştir. Bölüm 4’ün 1. kısmında verilerin verilerde sınıflandırma öncesi yapılan ön işleme yöntemleri hakkında bilgiler verilirken, 2. kısmında sınıflandırma algoritmaları anlatılmıştır ve son olarak da 3. kısımda sınıflandırmadan sonra gerçekleştirilen son işleme yöntemleri hakkında bilgiler verilmiştir. Bölüm 5’te algoritmaların veri üzerindeki sonuçları gösterilmiştir. İlk önce ön işleme sonuçları daha sonra sınıflandırma sonuçları ve son olarak da son işleme sonuçları sırasıyla 1. 2. ve 3. kısımlarda gösterilmiştir. Bu tezin son bölümü olan 6. Bölümde ise yapılan çalışmanın genel değerlendirmesi ve yapılabilecek çalışmalar için öneriler sunulmuştur.

2. KİMYASAL MADDE TESPİTİ İÇİN KULLANILAN YÖNTEMLER

Tezin bu bölümünde kimyasal madde tespiti için kullanılan bazı yöntemler incelenmiştir.

Kimyasal madde tespiti için kullanılan en eski yöntemlerden biri köpeklerdir. Geçmiş 2. Dünya Savaşı dönemlerine dayanan köpekler ile kimyasal madde tespiti [12], tutarlılık ve tekrarlanabilirlik yönünden zayıf olsa da [13] çok hızlı ve anlık birçok alanda tarama yapılabilmesinden dolayı günümüzde hala kullanılmaya devam edilmektedir [14]. Literatürde, köpeklerdeki tutarlılığın artırılması amacıyla yapılan çalışmaların [15] yanısıra fareler [16] ve domuzların [17] koku alma kabiliyetlerinin bu yönde geliştirilmesi için yapılan çalışmalar da mevcuttur.

Hayvanlardan ilham alınarak geliştirilen “elektronik burunlar” aynı hayvanlar gibi kimyasal maddelerin yaydıkları kokuları kullanarak sınıflandırma yapmaktadır [18]. Elektronik burunlar, biyolojik burunları gerçekçi bir şekilde taklit edebilmek için, her bir elemanı havadaki maddeler ile tepkimeye girerek farklı sinyaller oluşturabilen bir kimyasal algılayıcı dizisinden oluşmaktadır [19]. Daha sonra, bu algılayıcı dizisinin her birinden gelen sinyaller, yapay sinir ağları gibi örüntü tanıma yöntemleri kullanılarak sınıflandırılırlar.

Birden çok kimyasal algılayıcılardan oluşan kimyasal algılayıcı dizisi kullanmak yerine, aranan kimyasal madde ile tepkimeye girdiği bilinen bir diğer kimyasal maddenin kullanılması da oldukça kullanışlı bir yöntemdir [20]. Örneğin, güçlü bir patlayıcı olan TNT'nin bazı bazlar ile tepkimeye girerek güçlü bir renk değişimine sebep olduğu bilinmektedir [21]. Ticari ürün haline getirilen bu yöntem için şüphelenilen yüzeyler (giysi, paket, ayakkabı vb.) bir test kağıdı ile silinerek kimyasal maddenin bu kağıda yapışması sağlanır. Daha sonra, sırayla aranan maddelerin belirteci olan kimyasal maddeler püskürtülerek renk değişimi gözlenir. Bu sayede kimyasal madde tespiti yapılmış olur.

Aranan kimyasal maddenin tepkimeye girdiği bilinen diğer bir madde ile tepkime sonucunda ortaya çıkan renk değişiminin gözlemlendiği “kimyasal algılayıcı” yönteminin biraz daha da geliştirilmesi ile “elektrokimyasal algılayıcı” yöntemi ortaya çıkmıştır. Bu yöntemde diğerinden farklı olarak tepkime sonrası durumun incelenmesi yerine, kimyasal tepkime sırasında ortaya çıkan elektron veya iyonların ölçülmesi ile tespit yapılır [22]. Bu

algılayıcılar genellikle hızlı ve ucuz olduğu için tercih edilir ancak duyarlılıkları biraz düşüktür [23].

Şimdiye kadar çeşitli algılayıcılar ile yapılan kimyasal madde tespit yöntemleri incelendi, bundan sonra daha karmaşık ve duyarlılığı genellikle daha yüksek olan kimyasal maddenin spektroskopisini, yani madde ile elektromanyetik radyasyon arasındaki etkileşimi inceleyen yöntemler üzerinde durulacaktır. Bu yöntemlerden ilki iyon-hareketlilik spektrometresi (İHS) (ing. ion-mobility spectrometry (IMS)) ile yapılan kimyasal madde tespittir [24]. Bu yöntemde daha önce anlatılan kimyasal ve elektrokimyasal algılayıcı ile yapılan tespit yöntemlerinde olduğu gibi şüpheli görülen ürünler bir test kağıdı ile silinerek kimyasal maddenin bu kağıda yapışması sağlanır. Sonra, bu kağıttaki kimyasal maddenin daha önceki yöntemlerden farklı olarak kimyasal tepkimeye girmeden atmosferik basınç uygulanarak iyonlaştırılması sağlanır [24]. İyonlaşan atomların, atom numaralarına bağlı olarak sapma borusundaki (ing. drift tube) elektromanyetik alan içerisindeki sapma süreleri (ing. drift time) farklı olmaktadır [25]. Bu bilginin kullanılmasıyla, alınan örnekteki maddenin hangi kimyasal maddeye ait olduğu ve niceliği tespit edilebilir [26]. Bu yöntemde, yüksek duyarlılık (hedefin doğru bulunma oranı) ve yüksek özgüllüğün (hedef olmayan maddelerin doğru bulunma oranı) yanısıra algılama limiti (doğru tespit edilebilen en düşük madde miktarı) oldukça düşüktür. Bu sebeple, günümüzde iyon-hareketlilik spektrometre yönteminin kullanıldığı ticari ürünleri gümrük, havalimanları gibi yüksek güvenli bölgelede görmek mümkündür [27]. Ancak bu ürünlerin en önemli dezavantajları bir test kağıdı ile şüpheli nesneden örnek toplama ihtiyacının bulunmasıdır. Örnek toplama işlemi zaman aldığı için her nesne ve her insan üzerinde uygulanamamakta, sadece şüpheli görülenler seçilerek işlem yapılabilmektedir. Bu durum da güvenlik zafiyeti oluşturabilmektedir.


İyon-hareketlilik spektrometresinin bahsedilen dezavantajından dolayı kimyasal madde tespiti için, madde ile temas olmayan uzaktan algılama yöntemleri çalışılmaktadır. Bu yöntemlerden biri kızılötesi/morötesi spektroskopisi yöntemidir. Bu yöntemde genellikle güneşin enerjisi yetersiz kaldığı için ayrıca aydınlatıcı bir enerji kaynağı kullanılır [28]. Yapılan çalışmalarda algılama limiti iyon-hareketlilik spektrometresi kadar düşük olmasa da bu yöntem ile hedef tespitinin yapılabildiği gösterilmiştir [29][30]. Ancak bu

çalışmalarda kalibrasyonun önemli bir etken olduğu görülmüştür. Diferansiyel Yansıma Spektroskopi tekniğinde ise kalibrasyon ihtiyacı olmadan yapılan taramalardan kimyasal madde tespitinin yapılabileceği görülmüştür [31]. Bu tez kapsamında incelenen bu yöntemin sonucunda, iyon-hareketlilik spektrometresinin aksine sadece şüpheli görülen nesnelere değil bütün nesnelere taranması hedeflenmiştir. İlk etapta, tarama sonucunda kimyasal madde olduğu tespit edilen nesnelere yüksek duyarlılığa sahip iyon-hareketlilik spektrometresi ile incelenecektir. Kullanılan algoritmalar ile yüksek duyarlılık ile çalışan bir sistemin geliştirilmesinden sonra ise diferansiyel yansıma spektrometresinin iyon-hareketlilik spektrometresi yerine geçebileceği öngörülmektedir.

Bu yöntemlere ek olarak, lazer ışığının örneği plazma haline çevirerek karakterize ettiği lazerle-indüklenmiş bozunum spektroskopisi (LIBS) (ing. laser-induced breakdown spectroscopy (LIBS)) [32], birçok materyalin içerisine nüfuz edilebilen dalga boyu aralığında (0.1-10 Thz) görüntüleme sağlayan terahertz spektroskopisi [33] ve madde üzerine düşürülen lazerin moleküllerdeki titreşimini ölçerek kimyasal madde tespiti yapan Raman spektroskopisi [34] üzerine de önemli çalışmalar bulunmaktadır.

3. KULLANILAN VERİLERİN İNCELENMESİ

Veri toplama sisteminin ilk elemanı geniş bantta (200-550 nm aralığında) yayın yapan ışık kaynağıdır. Bu ışık kaynağından yayılan ışınların incelenmek istenen bölgeye düşürülmesi sağlanır. Tarama bölgesine düşen ışınlar bu bölgedeki materyalin içsel özelliğine göre geri yansıtılır. Geri yansıyan ışınlar dalga boylarına göre ayrıldıktan sonra bir CCD kamera tarafından toplanarak bilgisayara kaydedilir. Bu tez kapsamında yapılan çalışmalar bilgisayara kaydedilen bu veriler üzerinde gerçekleştirilmiştir. Kullanılan veri toplama sisteminin şematik gösterimi Şekil 2’de gösterilmiştir [35].



Şekil 2. Veri Toplama Sistemi Şematik Gösterimi

Tarama bölgesinin sürekli değiştirilmesi, ışık kaynağının hareket ettirilmesi yerine ışık kaynağının sabit tutulup bir taşıyıcı kayışın kaydırılması ile sağlanmıştır. Tarama bölgesinin sabit bir hızda sürekli kaydırılması, bir önceki tarama alanının bir sonrakinden çıkartılarak diferansiyel bir yansıma elde edilebilmesi için önemlidir. Tarayıcı kayışın bu hızı bilgisayar üzerinde çalışan algoritmalarla daha fazla olmamalıdır. Diğer bir deyişle, algoritmalar, taşıyıcı kayışın hızından daha hızlı çalışmalıdır. Bu tez için kullanılan kayışın hızı 20 cm/s ile 60 cm/s arasında ayarlanabilmektedir. Yani 1 mm aralıklarla tarama yapılmak istendiğinde, kullanılan algoritmanın 1.667 ms’den daha hızlı çalışması gerekmektedir.

Veri toplama sisteminde tek bir tarama bölgesi, düz bir hat üzerindeki piksellerden oluşur. Bu tez kapsamında incelenen verilerde her bir tarama bölgesi için 908 piksel

bulunmaktadır. Tarama bölgesi, 500 mm genişliğindeki taşıyıcı kayışın tamamının taranabilmesi için ayarlanmıştır. Bu yüzden her bir pikselin çözünürlüğü $500\text{mm}/908=0.55\text{mm}$ olmaktadır. Her bir piksel için 548 farklı dalga boyunda veri alınmıştır. Sonuç olarak, her bir tarama hattı için toplanan veri, uzaysal boyutta 908 ve spektral boyutta 548 olmak üzere 2 boyutludur.

Veri toplama işlemi, taşıyıcı kayışın çalıştırılması ile başlatılıp, yeterli bölgenin taranması sonrası durdurulmuştur. Bu işlem boyunca toplanan toplam veri bu tez boyunca tarama numunesi olarak anılacaktır. Tarama numunesindeki tarama hattının sayısı, taşıyıcı bandın çalışma süresi ile orantılı olduğu için değişiklik göstermektedir. Bu yüzden bir tarama numunesi için oluşturulan 3 boyutlu veri küpünün 3. boyutunun eleman sayısı sabit olmamaktadır. Sonuç olarak, bir tarama numunesi, eleman sayısı $908 \times 548 \times n$ (n = tarama hattı sayısı) olan 3 boyutlu bir veri küpüdür. Bu tez boyunca incelenen verilerde taşıyıcı kayışın hızı, her 10 mm'de bir tarama yapılacak şekilde ayarlanmıştır. Bu yüzden, taranan bölge boyutu, tarama hattı sayısı ile 10 mm olan tarama çözünürlüğü ile çarpılarak bulunabilir. Her bir tarama numunesi, boyutu tarama hattı sayısına göre farklılık gösteren ortalama 40-50 megabayt büyüklüğündeki ".csv" formatında kaydedilmiş dosyalardır.

Bu tezde, toplamda 8 farklı madde için alınan tarama numuneleri ile ilgili çalışmalar yapılmıştır. Bu maddeler 6 farklı materyalin (Materyal-1, Materyal-2,..., Materyal-6) üzerine konarak farklı tarama numuneleri oluşturulmuştur. Şekil 3'te görüldüğü üzere, hedef olan maddeler arka plan materyalinin üzerine üçgen biçiminde konulmuştur [36]. Bunun sebebi azalan madde miktarının sınıflandırma başarısına etkisini görebilmektir. Bir piksel içerisinde dahil olan madde miktarı azaldıkça, o pikselin tarama yaptığı sınırları içerisindeki arka plan alanı yani materyal miktarı artmaktadır. Bu yüzden de hedef pikseli üçgenin uç kısımlarında arka plan pikseline benzemeye başlamaktadır. Bu durumun etkisi Bölüm 5'te görülecektir.



Şekil 3. Materyal-2 Üzerine Üçgen Biçiminde Konan Madde-1

Hedef olmayan nesne olarak sınıflandırıcı eğitiminde kullanılmak üzere, arka plan olarak kabul edilen bu materyaller için de ayrıca tarama verileri toplanmıştır. Ayrıca, olası ölçüm hatalarının etkilerini en aza indirmek için, bahsedilen her hedef madde-arka plan kombinasyonu için 4 adet farklı tarama verisi alınmıştır.

Toplanan her veri için kesin referans (ground truth) oluşturabilmek amacıyla her piksel hedef piksel veya hedef olmayan piksel şeklinde etiketlenmiş ve yine csv formatında kaydedilmiştir. Veri toplama ve etiketleme işlemi bu tez için yapılan çalışmalar arasında yer almayıp, sadece bu teze girdi oluşturmaktadır.

4. KULLANILAN YÖNTEMLER

Tezin bu bölümünde tez boyunca kullanılan yöntemler incelenmiştir. Bu yöntemlerin veri üzerindeki sonuçları Bölüm 5'te incelenecektir.

4.1. Ön İşleme

Veri işleme yöntemlerinin yıllardır değişmesine ve gelişmesine rağmen, yıllardır değişmeyen, neredeyse doğanın bir kanunu olarak kabul edilen bir fenomen vardır: GIGO (Garbage In Garbage Out- Çöp Giren Çöp Çıkar). Ne yazık ki evrensel çöp bulucu bir sistem olmadığı için, ham veri içerisindeki problemleri çözmek için farklı ön işleme yöntemleri geliştirilmiştir. Bu yöntemler kullanılarak, veri işleme algoritmalarının daha iyi ve daha hızlı bir hale gelmesi sağlanır [37].

Bu tez kapsamında incelenen ön işleme yöntemleri bu bölümde anlatılmıştır. Ön işleme algoritmalarının sonuçları Bölüm 5'te incelenecektir.

4.1.1. Diferansiyel Alma

Bu tezin amacında geçen diferansiyel spektral yansıma verilerinin kullanılması, diferansiyel alma veri ön işleme yöntemi sayesinde gerçekleşmektedir. Bu yöntem, sadece ham spektral yansıma verileri üzerinde uygulanabilmektedir. Spektral yansıma verileri üzerinde diferansiyel almanın etkili bir yöntem olabileceği ilk olarak 1970 yılında Hummel tarafından ortaya atılmıştır [7].

Bu yöntem ile her pikselin yansıma değeri, bir sonraki tarama hattındaki pikselin yansıma değerinden çıkartılarak bu iki pikselin yansıma değerlerinin ortalamasının bölünmesiyle normalize edilmiş diferansiyel yansıma değeri bulunmaktadır. Bu işlem Denklem 1'de gösterilmiştir.

$$\|R_d\| = \frac{\Delta R}{\bar{R}} \quad (1)$$

Denklem 1'de gösterilen ΔR değeri birbirine komşu iki tarama hattındaki piksellerin yansıma değerleri farkını gösterirken, \bar{R} değeri bu komşu piksellerin yansıma değerlerinin ortalamasını göstermektedir. Bu denklem ile bulunan $\|R_d\|$ ise normalize edilmiş diferansiyel yansıma değerini gösterir.

i 'nci tarama hattındaki pikseller ele alındığında, yukarıdaki denklem, Denklem 2'deki gibi yazılabilir.

$$\|R_d\|_i = \frac{R_{i+1} - R_i}{\left(\frac{R_{i+1} + R_i}{2}\right)} \cong \frac{R_{i+1} - R_i}{R_{i+1} + R_i} \quad (2)$$

Bu işlem için 2 böleni sadece bir katsayı olacağı ve bütün piksellere aynı etkileyeceği için hesaba katılmayabilir.

Bir pikselin yansıma değeri tanımlanırken farklı spektral bantlardaki yansıma değerleriyle birlikte tanımlanır. Bu yüzden diferansiyel alma işlemi için bütün spektral bantlardaki yansıma değerlerinde ayrı ayrı diferansiyel alma uygulanır. Dolayısıyla yukarıdaki denkleme göre, toplam N dalga boyu olan i 'nci pikselin λ 'ncı dalga boyundaki normalize edilmiş diferansiyel yansıma değeri Denklem 3'teki gibi bulunabilir.


$$\|R_d\|_{i,\lambda} \cong \frac{R_{i+1,\lambda} - R_{i,\lambda}}{R_{i+1,\lambda} + R_{i,\lambda}} \quad (3)$$

Bu işlemin sonucunda elde edilen diferansiyel yansıma değerleri gürültülü olduğu için filtreleme işlemine ihtiyaç duyulmaktadır.

4.1.2. Savitzky-Golay Filtresi

İlk defa 1964 yılında A. Savitzky ve M.J.E. Golay tarafından ortaya konan bu teknik, eşit aralıklarla örneklenmiş her bir dijital verinin belirli bir komşuluktaki değerleri için belirli bir derecede polinom uydurarak veri üzerindeki gürültüyü azaltma tekniğidir [38][39].

Şekil 4'te, filtrelenecek $f(x)$ fonksiyonun x_i noktasının n komşuluğundaki değerleri ve bu noktalara göre uydurulan M dereceli $p_i(x)$ polinomu gösterilmiştir.



Şekil 4. S.Golay Filtresinde Polinom Uydurma

Şekil 4'teki $p_i(x)$ polinomunun $[x_{i-n}, x_{i+n}]$ aralığında $f(x)$ fonksiyonuna en uygun şekilde uydurulabilmesi için en küçük kareler kestirimi yöntemine göre Denklem 4'ün minimum olması gerekmektedir.

$$\min \left(\sum_{j=i-n}^{i+n} (p_i(x_j) - f(x_j))^2 \right) \quad (4)$$

$p_i(x_j)$ polinomu $p_i(x_j) = \sum_{k=0}^M b_k \left(\frac{x_j - x_i}{\Delta x} \right)^k$ olarak yazıldığında Denklem 4 en küçük değerini Denklem 5 sağlandığında alır.

$$\| \mathbf{A} \mathbf{b} - \mathbf{f} \|_2 = 0$$

$$\mathbf{A} = \begin{bmatrix} (-n)^M & \dots & (-n) & 1 \\ \vdots & \ddots & \vdots & \vdots \\ 0 & \dots & 0 & 1 \\ \vdots & \ddots & \vdots & \vdots \\ n^M & \dots & n & 1 \end{bmatrix} \in \mathbf{R}^{(2n+1) \times (M+1)} \quad (5)$$

$$\mathbf{b} = \begin{bmatrix} b_M \\ \vdots \\ b_1 \\ b_0 \end{bmatrix} \in \mathbf{R}^{M+1}$$

$$\mathbf{f} = \begin{bmatrix} f_{i-n} \\ \vdots \\ f_i \\ \vdots \\ f_{i+n} \end{bmatrix} \in \mathbf{R}^{2n+1}$$

Denklem 5'teki M değeri, uydurulacak $p_i(x)$ polinomunun derecesini gösterirken b_k ise polinomun ilgili derecedeki katsayısını ifade etmektedir.

Denklem 5'e göre $p_i(x_j)$ polinomunun b_k katsayılarını bulmak için Denklem 6'da görülen işlem yapılır.

$$\mathbf{b} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{f} = \mathbf{c}^T \mathbf{f}, \quad \mathbf{c} = \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{e}_{M+1}, \quad (6)$$

$$\mathbf{e}_{M+1} = (M + 1)'inci \text{ birim vektör}$$

Sonuç olarak, Denklem 7'de, giriş fonksiyonunun, f , seçilen M ve n değerlerine göre oluşturulan Savitzky-Golay Filtresi ile filtrelenmesi sonucunda ortaya çıkan g fonksiyonu aşağıdaki denklemle bulunabilir:

$$\mathbf{g} = \mathbf{c}^T \mathbf{f} \rightarrow g(x_i) = \sum_{j=i-n}^{i+n} c_{j-i} f(x_j) \quad (7)$$

Denklem 7'de görüldüğü gibi, giriş fonksiyonun sadece \mathbf{c} katsayı vektörü ile çarpılmasıyla filtrelenmiş fonksiyonumuz elde edilir. Bu \mathbf{c} vektörü ise giriş fonksiyonuna uydurulmak istenen polinomun derecesine (M) ve uydurulacak noktaların komşuluk miktarına (n) bağlı olarak değişmektedir. Komşuluk değeri n seçildiğinde toplam kullanılacak veri sayısı yani çerçeve boyutu ($2n + 1$) olmaktadır. Tablo 1'de bazı derece (M) ve çerçeve ($2n + 1$) için hesaplanmış \mathbf{c} vektörleri bulunmaktadır.

Bu \mathbf{c} vektörleri veriden bağımsız olduğu için, giriş fonksiyonunun seçilen çerçeve içerisindeki elemanlarını S. Golay Filtresi Katsayı Tablosu'ndaki katsayı vektörü ile çarpmak filtrelenmiş sonucu bulmak için yeterli olacaktır.

Tablo 1. S.Golay Filtresi Katsayı Tablosu

	Çerçeve=5	Çerçeve=7	Çerçeve =9
Derece=2	$c = \begin{bmatrix} -0.0857 \\ 0.3429 \\ 0.4857 \\ 0.3429 \\ -0.0857 \end{bmatrix}$	$c = \begin{bmatrix} -0.0952 \\ 0.1429 \\ 0.2857 \\ 0.3333 \\ 0.2857 \\ 0.1429 \\ -0.0952 \end{bmatrix}$	$c = \begin{bmatrix} -0.0909 \\ 0.0606 \\ 0.1688 \\ 0.2338 \\ 0.2554 \\ 0.2338 \\ 0.1688 \\ 0.0606 \\ -0.0909 \end{bmatrix}$
Derece=4	$c = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}$	$c = \begin{bmatrix} 0.0216 \\ -0.1299 \\ 0.3247 \\ 0.5671 \\ 0.3247 \\ -0.1299 \\ 0.0216 \end{bmatrix}$	$c = \begin{bmatrix} 0.0350 \\ -0.1282 \\ 0.0699 \\ 0.3147 \\ 0.4172 \\ 0.3147 \\ 0.0699 \\ -0.1282 \\ 0.0350 \end{bmatrix}$

Tablo 1’de görülen bu sayılar gelen veriden bağımsız sabit sayılardır.

4.1.3. Hareketli-Ortalama Filtresi

Hareketli ortalama filtresi (ing. Moving Average Filter), 1900’lü yılların başlarında “anlık ortalama filtresi” olarak kullanılan [40], belirli komşuluktaki verilerin ortalamasının alınmasıyla filtreleme sağlayan bir veri yumuşatma filtresidir. Aslında Savitzky-Golay Filtresindeki c sabit vektörü n komşuluk sayısı, e ise $2n + 1$ boyutlu kolon vektörü olmak üzere, $c = \frac{1}{2n+1} e$ olmak üzere değiştirilirse Hareketli-Ortalama Filtresi elde edilmiş olur. Sonuç olarak, f fonksiyonunun hareketli ortalama filtresi ile filtrelenmesi sonucunda ortaya çıkan g fonksiyonun denklemi aşağıdaki gibi olacaktır.

$$\begin{aligned}
 g = c^T f & \rightarrow g(x_i) = \sum_{j=i-n}^{i+n} c_{j-i} f(x_j) \\
 & = \frac{1}{2n+1} (f(x_{i-n}) + \dots + f(x_i) + \dots + f(x_{i+n}))
 \end{aligned} \tag{8}$$

4.1.4. Gaussian Filtre

Gaussian Filtresinin Hareketli-Ortalama ve Savitzky-Golay Filtresinden tek farkı, c sabit vektörü elemanlarının, seçilen varyans (σ^2) değerine göre oluşturulmuş sıfır ortalamalı bir Gaussian dağılımına sahip olmasıdır. Yine belirli bir komşuluk için oluşturulacak katsayıların normalize edilmiş olması (toplamının 1 olması) beklenmektedir. Seçilen varyans (σ^2) değerine göre filtrelenmiş fonksiyonu, Denklem 9'da gösterilmiştir.

$$\mathbf{g} = \mathbf{c}^T \mathbf{f} \rightarrow g(x_i) = \sum_{j=i-n}^{i+n} c_{j-i} f(x_j), \quad c_{j-i} = \frac{e^{-\frac{(j-i)^2}{2\sigma^2}}}{\left(\sum_{j=i-n}^{i+n} e^{-\frac{(j-i)^2}{2\sigma^2}} \right)} \quad (9)$$

Gaussian filtresinde, komşuluk sayısı, n için verilerin %95'ini kapsayan 2σ alanının seçilmesi makul olacaktır [41]. Bu durumda oluşan denklem, Denklem 10'da verilmiştir.

$$\mathbf{g} = \mathbf{c}^T \mathbf{f} \rightarrow g(x_i) = \sum_{j=i-2\sigma}^{i+2\sigma} c_{j-i} f(x_j), \quad c_{j-i} = \frac{e^{-\frac{(j-i)^2}{2\sigma^2}}}{\left(\sum_{j=i-2\sigma}^{i+2\sigma} e^{-\frac{(j-i)^2}{2\sigma^2}} \right)} \quad (10)$$

4.1.5. Medyan Filtresi

Medyan filtresi Savitzky-Golay Filtresi, Hareketli-Ortalama Filtresi ve Gaussian Filtresinden farklı olarak doğrusal olmayan bir filtredir. Özellikle anlık zirve ya da dip yapan gürültüyü yok etmek amacıyla kullanılır [42]. Medyan Filtre, belirli bir komşuluktaki verileri sıralayarak sıralamada ortada yer alan değeri filtrelenmiş değer olarak belirler. Bu şekilde anlık zirve yapan değeri belirli pencere içindeki orta değere çekilmiş olur. Bu filtrenin denklemi aşağıdaki gibi gösterilebilir.

$$g(x_i) = \text{med}\{f(x_{i-n}), f(x_{i-n+1}), \dots, f(x_i), \dots, f(x_{i+n-1}), f(x_{i+n})\} \quad (11)$$

4.2. Sınıflandırma

Sınıflandırma, ön işlemeden çıkan verilerin hangi sınıfa ait olduğuna karar verildiği kısımdır. Bu tez kapsamında sınıflandırma için farklı algoritmalar denenmiş, performansları incelenmiştir. Bu algoritmalar öznitelik tabanlı sınıflandırıcılar ve imza tabanlı sınıflandırıcılar olmak üzere ikiye ayrılmıştır.

Bu bölümde sınıflandırıcı algoritmalarının teorik bilgileri anlatılmış olup sınıflandırıcı sonuçları Bölüm 5'te incelenmiştir.

4.2.1. Öznitelik tabanlı sınıflandırma

Gelişen teknolojiyle toplanan verilerin boyutu sürekli artmaktadır. Bu veriler her ne kadar gürültüden ayrıştırılmış olsa da toplanan verilerdeki herhangi bir gereksiz bilgi sınıflandırıcıların yanlış karar vermesine sebep olabilir. Öznitelik tabanlı bu sınıflandırma çeşitlerinde, veriyi ham haliyle kullanmak yerine, bu veriden gerekli olan bilgilerin (özniteliklerin) çıkartarak bunların sınıflandırılması sağlanır. Gerekli özniteliklerin çıkartılması ile hem gürültüye sebep olan gereksiz bilgiler elenmiş olur hem de işlenecek verinin boyutu düşürülmüş olur. Böylelikle hem daha hızlı hem daha doğru bir sınıflandırma sonucu elde edilir [43]. İmza tabanlı sınıflandırıcılara göre bu avantajları olmasına rağmen, gereksiz olduğu düşünülen ve elenen veride sınıflandırma açısından herhangi bir önemli bilgi var ise sınıflandırıcılar tamamıyla başarısız olurlar. Bu yüzden doğru öznitelikleri çıkartmak ve çıkartılan bu özniteliklerin sınıflandırıcı için önemli olanlarını belirlemek çok önemlidir.

4.2.1.1. Öznitelik Çıkartmak - TBA

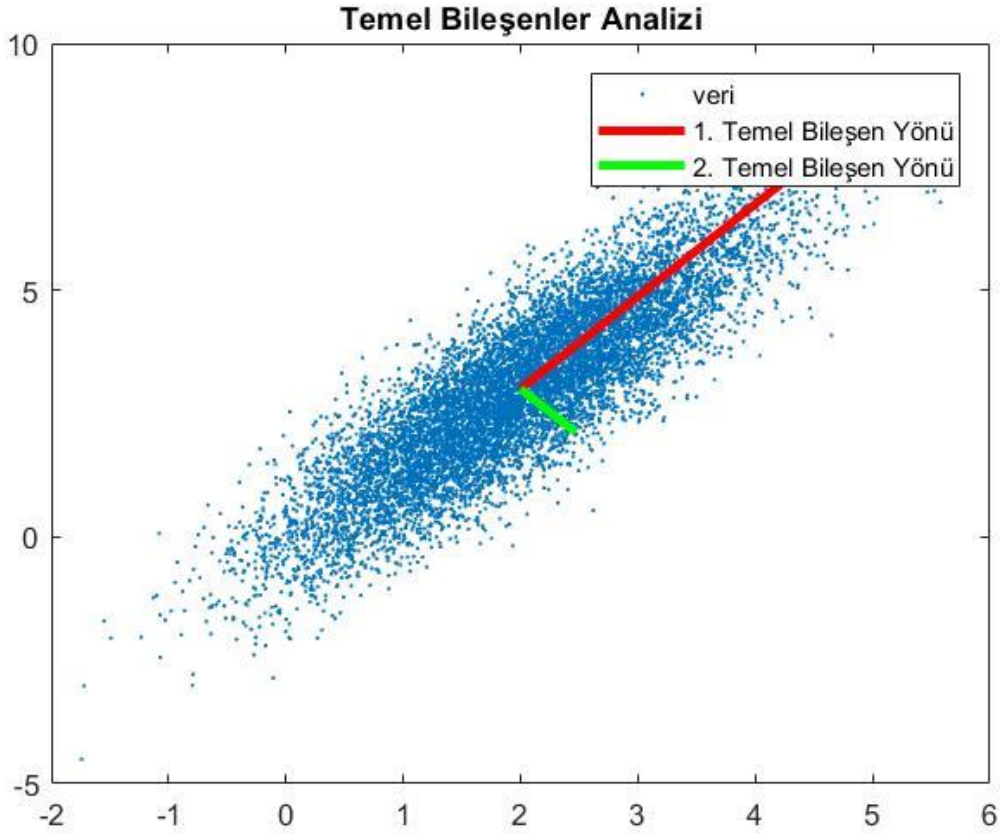
Literatürde farklı öznitelik çıkartma algoritmaları olmasına rağmen [44][45], bu tez kapsamında en eski ve en popüler olan Temel Bileşenler Analizi (TBA) öznitelik çıkartma algoritması kullanılmıştır [46].

TBA, 1901 yılında Karl Pearson tarafından ortaya atılan “ana eksen teoremi”nin 1933 yılında Hotelling tarafından geliştirilmesi sonucu kullanılmaya başlanan bir tekniktir [47]. Bu teknikte özetle, birbiri ile ilişkili değişkenlere sahip veri, dikgen bir dönüşüm kullanılarak temel bileşenler olarak adlandırılan doğrusal olarak ilişiksiz değişkenlere sahip değerler kümesine dönüştürülmesi sağlanır. Ayrıca, bu teknikte, doğrusal olarak ilişiksiz temel bileşenlerinin bulunmasının yanı sıra bu temel bileşenlerin veri içerisindeki değişkenlik karşılıkları (varyans değerleri) bulunmaktadır. İlk temel bileşen en yüksek varyans değerine sahip yani veriyi en fazla kapsayan en önemli temel bileşen olarak görülmektedir [48][49].

TBA'da, öncelikle bir eğitim verisi ele alınarak buradan temel bileşenler bulunur. Daha sonra gelecek her verinin bu eğitim verisinden çıkartılan temel bileşenlerle doğrusal

dönüşümü gerçekleştirilir. Böylelikle her veri birbirinden bağımsız değişkenlere sahip olur. Bu değişkenler arasından, eğitim verilerinden elde edilen en yüksek varyanslı temel bileşene karşılık gelen değişken en önemli değişken olarak görülür.

Şekil 5'te görüldüğü gibi TBA'da tanımlanan temel bileşenler eğitim verisinin ortasından tanımlandığı için, temel bileşen bulmak için öncelikle yapılması gereken işlem veri ortalamasını sıfıra çekmek olacaktır.



Şekil 5. Temel Bileşenler Analizi

Bunun için, öncelikle $1 \times N$ boyutlu M tane veri matris formuna çevrilir. Denklem 12'de i 'nci veri ve Denklem 13'te bütün eğitim verilerinden oluşan $M \times N$ boyutlu X vektörü görülmektedir.

$$X^i = [x_1^i \quad x_2^i \quad \dots \quad x_j^i \quad \dots \quad x_N^i] \quad (12)$$

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_j^1 & \dots & x_N^1 \\ x_1^2 & x_2^2 & \dots & x_j^2 & \dots & x_N^2 \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1^i & x_2^i & \dots & x_j^i & \dots & x_N^i \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1^M & x_2^M & \dots & x_j^M & \dots & x_N^M \end{bmatrix} \quad (13)$$

Denklem 14 ile bulunan ortalama bütün verilerden çıkartılarak, Denklem 15'te görüldüğü gibi bütün değişkenleri merkezleştirilmiş veriler elde edilir.

$$\mathbf{m} = [m_1 \quad m_2 \quad \dots \quad m_j \quad \dots \quad m_N], \quad m_j = \sum_{i=1}^M x_j^i \quad (14)$$

$$\tilde{\mathbf{X}}^i = \mathbf{X}^i - \mathbf{m}, \quad \tilde{\mathbf{X}} = \begin{bmatrix} x_1^1 - m_1 & x_2^1 - m_2 & \dots & x_j^1 - m_j & \dots & x_N^1 - m_N \\ x_1^2 - m_1 & x_2^2 - m_2 & \dots & x_j^2 - m_j & \dots & x_N^2 - m_N \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1^i - m_1 & x_2^i - m_2 & \dots & x_j^i - m_j & \dots & x_N^i - m_N \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1^M - m_1 & x_2^M - m_2 & \dots & x_j^M - m_j & \dots & x_N^M - m_N \end{bmatrix} \quad (15)$$

Merkezleştirilmiş verilerin kovaryans matrisi, \mathbf{C} , Denklem 16 kullanılarak hesaplanır.

$$\text{cov}(\tilde{\mathbf{X}}) = \mathbf{C} = \frac{1}{M} \sum_{i=1}^M \tilde{\mathbf{X}}^i \tilde{\mathbf{X}}^{iT} \quad (16)$$

$N \times N$ boyutlu kovaryans matrisi \mathbf{C} , N boyutlu değişkenin birbiri ile olan bağıntısı hakkında bilgi vermektedir. Bu matrisin köşegenleri, her bir değişkenin varyans değerini yani ortalama değere göre dağılımını gösterir. Köşegen olmayan kovaryans değerleri ise seçilen iki değişkenin birbirleri arasındaki ilişkiyi göstermektedir. Eğer bu değer pozitif ise iki değişken arasında doğru orantılı bir bağlantı vardır. Eğer bu değer negatif ise iki değişken arasında ters orantılı bir bağlantı bulunmaktadır. Ayrıca, bu değer büyüklüğü, iki değişken arasındaki bağlantının miktarını göstermektedir. Yani eğer bu değer sıfıra çok yakınsa, iki değişken arasında belirli bir bağlantı bulunmamakta, sıfırdan çok uzaksa iki değişken arasında kuvvetli bir bağlantı bulunmaktadır [48].

Bu kovaryans matrisinin özvektörleri TBA'da ihtiyacımız olan temel bileşenleri oluşturmaktadır. Denklem 17'yi sağlayan \mathbf{v} vektörü \mathbf{C} matrisinin özvektörü olarak adlandırılır. Aynı şekilde, Denklem 17'yi sağlayan λ katsayısı \mathbf{C} matrisinin özdeğeri olarak adlandırılır.

$$Cv = \lambda v \quad (17)$$

$N \times N$ boyutlu C matrisinin toplamda N tane N boyutlu özvektörü bulunmaktadır. Bu özvektörlerin her biri birbirinden bağımsızdır. Bu N tane N boyutlu özvektöre karşılık gelen N tane sabit özdeğer bulunmaktadır. Bu özdeğerlerin büyüklüğü karşılık gelen özvektörün veriyi ne kadar kapsadığı yani verinin o yöndeki varyans değeri ile ilişkilidir. TBA için bu özvektörler, karşılık gelen özdeğerlerin büyüklüğüne göre büyükten küçüğe doğru sıralanır. Daha sonra sıralanan bu özvektörlerin baştan p tanesi seçilir ve Denklem 18'de görülen D dönüşüm vektörü elde edilir.

$$v^i = \begin{bmatrix} v_1^i \\ v_2^i \\ v_3^i \\ \vdots \\ v_N^i \end{bmatrix}, \quad D = [v^1 \quad v^2 \quad \dots \quad v^p] = \begin{bmatrix} v_1^1 & v_1^2 & \dots & v_1^p \\ v_2^1 & v_2^2 & \dots & v_2^p \\ v_3^1 & v_3^2 & \dots & v_3^p \\ \vdots & \vdots & \ddots & \vdots \\ v_N^1 & v_N^2 & \dots & v_N^p \end{bmatrix} \quad (18)$$

Dönüşüm vektörünü de elde ettikten sonra, TBA için eğitim verileri üzerinde yapılan işlemler tamamlanmış olur. Daha sonra yeni gelen her N boyutlu X^{yeni} verisi için önce eğitim verilerinden bulunan ortalama çıkartılarak \tilde{X}^{yeni} bulunur (Denklem 19).

$$\begin{aligned} & \tilde{X}^{yeni} \\ & = [(x_1^{yeni} - m_1) \quad (x_2^{yeni} - m_2) \quad \dots \quad (x_j^{yeni} - m_j) \quad \dots \quad (x_N^{yeni} - m_N)] \end{aligned} \quad (19)$$

Daha sonra, merkezleştirilmiş bu yeni veri eğitim verilerinden bulunan dönüşüm matrisi D ile çarpılır (Denklem 20).

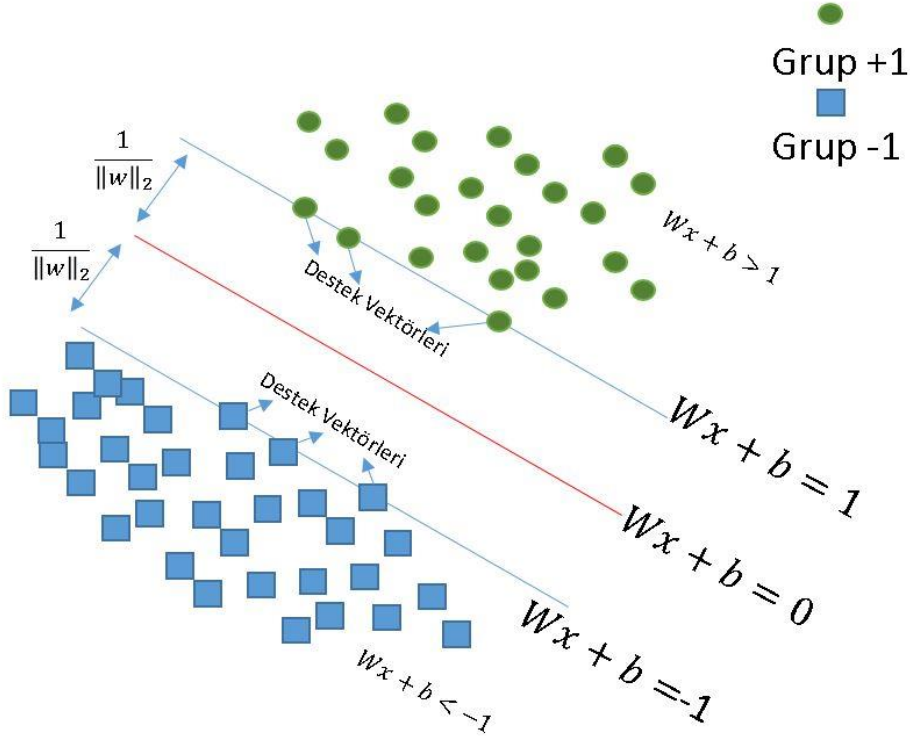
$$Y = \tilde{X}^{yeni} D, \quad y_i = \sum_{j=1}^N (x_j^{yeni} - m_j) * v_j^i \quad (20)$$

Sonuç olarak, yeni gelen $1 \times N$ boyutlu K tane veri için yukarıdaki işlem yapıldığında, K tane P boyutlu veri elde edilir. Yani, verilerin N boyut sayısı P 'ye düşürülmüş aynı zamanda en önemli P tane özvektör seçildiği için verideki önemsiz olan bölüm elenmiş olur.

Sınıflandırıcılar, TBA sonucunda elde edilen bu yeni veriyi öznitelik olarak kabul edilip bu veriye göre sınıflandırma yapmaktadır.

4.2.1.2. Destek Vektör Makineleri - DVM

İlk olarak Corinna Cortes ve Vladimir Vapnik tarafından oluşturulan ve kullanılmaya başlanan Destek Vektör Makineleri, bir doğrusal ikili sınıflandırma yöntemidir [50][51]. İki sınıfı birbirinden ayırmak için kullanılan bu algoritmanın asıl amacı iki sınıfın birbirine en yakın verilerini seçerek bu veriler ile seçilecek doğrusal sınıflandırıcı arasındaki mesafenin en yüksek olmasını sağlamaktır. Bu şekilde sınıflandırıcı mümkün olan en genel şekline kavuşmuş olur.



Şekil 6. Destek Vektör Makineleri Örnek Veri İncelemesi

Şekil 6'da Destek Vektör Makinelerinin sınıflandırma için kullandığı en uygun hiperdüzlem, $w^T x + b = 0$ gösterilmiştir. Bu hiperdüzlemin optimum olması sınıflar arasındaki uzaklığın, $\frac{2}{\|w\|}$ maksimum olması ile sağlanır. Ancak, bu fonksiyon maksimize edilirken verilerin doğru sınıflandırılmış olması optimizasyon algoritması için bir kısıt teşkil eder ve Denklem 21'deki gibi formüle edilir.

$$\text{maksimum} \left(\frac{2}{\|w\|} \right) \quad (21)$$

$$\begin{aligned} \text{kısıt: } \mathbf{w}^T \mathbf{x}_i + \mathbf{b} &\geq 1, & +1 \text{ grubu için} \\ \mathbf{w}^T \mathbf{x}_i + \mathbf{b} &\leq -1, & -1 \text{ grubu için} \end{aligned}$$

Kısıtları tek bir fonksiyon içinde yazmak istersek denklem, Denklem 22'deki şeklini alır. z_i , x_i verisinin grubunu belirtir.

$$\begin{aligned} \text{maksimum} \left(\frac{2}{\|\mathbf{w}\|} \right) & \quad (22) \\ \text{kısıt: } z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) &\geq 1, \quad \forall \mathbf{x}_i \text{ için} \end{aligned}$$

$\frac{2}{\|\mathbf{w}\|}$ değerinin maksimum olduğu yerde $\frac{\|\mathbf{w}\|^2}{2}$ değeri de minimumdur. Tersisi de doğrudur. Yani $\frac{\|\mathbf{w}\|^2}{2}$ değerinin minimum olduğu noktada $\frac{2}{\|\mathbf{w}\|}$ değeri de maksimumdur. Optimizasyon problemlerinde genellikle maksimizasyon yerine minimizasyon tercih edilir [52]. O yüzden, problem Denklem 23'teki gibi $\frac{\|\mathbf{w}\|^2}{2}$ değerinin en düşüğünü bulma şeklinde değiştirilebilir.

$$\begin{aligned} \text{minimum} \left(\frac{\|\mathbf{w}\|^2}{2} \right) & \quad (23) \\ \text{kısıt: } z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) &\geq 1, \quad \forall \mathbf{x}_i \text{ için} \end{aligned}$$

Kısıtlı optimizasyon problemleri Lagrangian yöntemi ile çözülebilmektedir [52]. Bu yöntemle göre problemin çözümü eğer Denklem 24 formundaysa Lagrangian fonksiyonunun çözümüne eşit olmaktadır [52].

$$\begin{aligned} \min f(x, y) &\quad \Rightarrow \quad L(x, y, \lambda) = f(x, y) - \lambda g(x, y) & \quad (24) \\ \text{kısıt: } g(x, y) &\geq 0 \end{aligned}$$

Denklem 25'de görüldüğü gibi minimize edilecek fonksiyon, Lagrangian fonksiyonuna çevrilmiştir.

$$L(\mathbf{w}, \mathbf{b}, \lambda) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^M \lambda_i [z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) - 1] \quad (25)$$

Bu problemin çözümü, Lagrangian fonksiyonunun \mathbf{w} ve \mathbf{b} 'ye göre minimum λ_i 'ye göre maksimum olduğu noktadadır. Lagrangian fonksiyonunun \mathbf{w} ve \mathbf{b} 'ye göre minimum olması

\mathbf{w} ve \mathbf{b} 'ye göre türevinin sıfır olması anlamına gelir. Lagrangian fonksiyonunun \mathbf{w} 'ya göre türevi Denklem 26'da \mathbf{b} 'ye göre türevi Denklem 27'de gösterilmiştir.

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, \boldsymbol{\lambda})}{\partial \mathbf{b}} = \sum_{i=1}^M \lambda_i \mathbf{z}_i = 0 \quad (26)$$

$$\frac{\partial L(\mathbf{w}, \mathbf{b}, \boldsymbol{\lambda})}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^M \lambda_i \mathbf{z}_i \mathbf{x}_i = 0 \Rightarrow \mathbf{w}^* = \sum_{i=1}^M \lambda_i \mathbf{z}_i \mathbf{x}_i \quad (27)$$

Denklem 26 ve Denklem 27'de bulunan verileri Denklem 25'te yerine yazarsak Lagrangian fonksiyonu sadece $\boldsymbol{\lambda}$ 'ya bağlı hale gelmiş olur. Sadece $\boldsymbol{\lambda}$ 'ya bağlı Lagrangian fonksiyonu Denklem 28'de gösterilmiştir.

$$L(\boldsymbol{\lambda}) = \sum_{i=1}^M \lambda_i - \frac{1}{2} \sum_{j=1}^M \sum_{i=1}^M \lambda_i \lambda_j \mathbf{z}_i \mathbf{z}_j (\mathbf{x}_i^T \mathbf{x}_i) \quad (28)$$

$L(\boldsymbol{\lambda})$ 'ın maksimize edilmesi $-L(\boldsymbol{\lambda})$ 'ın minimize edilmesi anlamına gelmektedir. Bu yüzden optimum $\boldsymbol{\lambda}$ değeri, $\boldsymbol{\lambda}^*$ denklemi Denklem 29'de gösterilmiştir.

$$\boldsymbol{\lambda}^* = \underset{\boldsymbol{\lambda}}{\operatorname{argmin}}(-L(\boldsymbol{\lambda})) = \underset{\boldsymbol{\lambda}}{\operatorname{argmin}} \left(\frac{1}{2} \sum_{j=1}^M \sum_{i=1}^M \lambda_i \lambda_j \mathbf{z}_i \mathbf{z}_j (\mathbf{x}_i^T \mathbf{x}_i) - \sum_{i=1}^M \lambda_i \right) \quad (29)$$

KKT şartlarının [53] sağlanması için Denklem 30'un sağlanması gerekmektedir.

$$\lambda_i [z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) - 1] = 0 \quad (30)$$

Denklem 30'un iki tane çözümü vardır ya $\lambda_i = 0$ veya $z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) = 1$ olmalıdır. $z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) = 1$ durumunu sağlayan i 'nci veri destek vektörleri olarak adlandırılırken eğer i 'nci veri destek vektörü değilse $\lambda_i = 0$ olur. Bu duruma göre, sadece destek vektörleri kullanılarak sınıflandırıcı parametreleri bulunabilir.

Denklem 29 ile bulunan $\boldsymbol{\lambda}^*$ vektörü sayesinde Denklem 31 ve Denklem 32'de görüldüğü gibi $\lambda_i \neq 0$ için \mathbf{w}^* ve \mathbf{b}^* değerleri bulunur ve Denklem 33'teki gibi sınıflandırıcı fonksiyonunda yerine yazılır. S destek vektörü sayısını ifade etmektedir.

$$\mathbf{w}^* = \sum_{i=1}^M \lambda_i^* \mathbf{z}_i \mathbf{x}_i, \quad \lambda_i \neq 0 \text{ için} \quad (31)$$

$$z_i(\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) - 1 = 0, \quad \lambda_i \neq 0 \text{ için} \Rightarrow \mathbf{b}^* = \frac{1}{z_i} - \mathbf{w}^T \mathbf{x}_i \quad (32)$$

$$g(\mathbf{x}) = \mathbf{w}^{*T} \mathbf{x}_i + \mathbf{b}^* = \left(\sum_{i=1}^S \lambda_i^* \mathbf{z}_i \mathbf{x}_i \right) \mathbf{x} + \left(\frac{1}{z_i} - \mathbf{w}^T \mathbf{x}_i \right) \quad (33)$$

Daha sonra her yeni gelen veri bu sınıflandırıcı fonksiyonuna sokularak hiperdüzlemin hangi tarafında kaldığına göre sınıflandırılır. Şekil 6'da görülen grup +1'in etiketi 1 grup -1'in etiketi 0 olacak şekilde Denklem 34 yazılabilir.

$$l_k = \text{sign} \left\{ \left(\sum_{i=1}^S \lambda_i^* \mathbf{z}_i \mathbf{x}_i \right) \mathbf{x}_k + \left(\frac{1}{z_i} - \mathbf{w}^T \mathbf{x}_i \right) \right\} \quad (34)$$

Şimdiye kadar yapılan işlemler doğrusal bir çizgiyle birbirinden ayrılabilen veriler içindi, ancak doğrusal bir çizgi ile birbirinden ayıramayacak bir veri geldiğinde Denklem 34 yetersiz kalmaktadır. Çekirdek hilesi ile yukarıdaki denklem geliştirildiğinde Destek Vektör Makineleri doğrusal olmayan çizgi ile iki veriyi birbirinden ayırabilecek duruma gelebilir.

Çekirdek hilesi gelen her veriyi doğrusal olmayan bir fonksiyondan, $\phi(\mathbf{x})$ geçirmektedir. Radyal Bazlı Fonksiyon, RBF (ing. radial basis function) örnek bir çekirdek fonksiyonudur ve Denklem 35'de verilmiştir.

$$\phi(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}\|^2}{k^2}\right) \quad (35)$$

Denklem 35'de görülen k sabiti çekirdek ölçeği olarak tanımlanmaktadır. Çekirdek ölçeği, destek vektör makineleri sayesinde kurulan sınıflandırma modelinin, kullanılan veriye ne kadar oturacağını belirlemek için kullanılır. Çok küçük çekirdek ölçeği modelin, eğitim verilerine aşırı oturmasına sebep olurken çok büyük çekirdek ölçeği de modelin veriye hiç oturmamasına sebep olabilir. Bu iki durum da, modelin eğitim verilerinde doğru sonuç vermesine rağmen yeni gelen verilerde yanlış sınıflandırma yapmasına sebep olur. Bu sebeple, daha iyi bir performans için bu parametrenin doğru ayarlanması gerekmektedir [54].

Çekirdek hilesi sonrası oluşan Destek Vektör Makineleri denklemi Denklem 36'da görülmektedir.

$$l_k = \text{sign} \left\{ \left(\sum_{i=1}^S \lambda_i^* z_i \phi(x_i) \right) \phi(x_k) + \left(\frac{1}{z_i} - \mathbf{w}^T \phi(x_i) \right) \right\} \quad (36)$$

Destek vektör makineleri $\left(\frac{2}{\|\mathbf{w}\|} \right)$ değerini maksimum etmesinden dolayı maksimum uzaklık sınıflandırıcısı olarak adlandırılır. Ancak, bazı durumlarda, özellikle seçilen destek vektörleri yanlış grupta ise maksimum uzaklık yöntemi yanlış sonuçlar doğurmaktadır. Bu yüzden destek vektör makinelerine bir ceza terimi eklenerek yumuşak uzaklık sınıflandırıcısı haline getirilebilir [50] [55]. Yumuşak uzaklıklı destek vektör makinelerinin denklemi Denklem 37'de görülmektedir.

$$\begin{aligned} & \text{minimum} \left(\frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^M \xi_i \right) \quad (37) \\ & \text{kısıt: } z_i (\mathbf{w}^T \mathbf{x}_i + \mathbf{b}) \geq 1 - \xi_i, \quad \forall \mathbf{x}_i \text{ için} \end{aligned}$$

Denklem 37'de görülen ξ_i terimi hatayı belirtirken C terimi bu hatayı ne kadar önemseyeceğimizi göstermektedir. C terimi sabit sayı olup ceza sabiti olarak adlandırılır. Bu ceza sabitinin, C artması daha fazla hataya izin verirken daha az destek vektörünün seçilmesini sağlamaktadır. Ceza sabitinin azalması ile de daha az hatalı eğitim verisi sonucuna ulaşılırken Destek Vektör Makineleri'nin karmaşıklığı artar. Ceza sabitinin belirlenmesi için test verileri üzerindeki sonucun incelenmesi ve test verileri üzerindeki hatanın en az olmasını sağlayan ceza sabitinin seçilmesi gerekmektedir.

Her ne kadar Destek Vektör Makineleri ikili sınıflandırma için tasarlanmış olsa da, bu algoritma çok sınıflı senaryolar için de geliştirilebilir. Çok Sınıflı Destek Vektör Makineleri için genelde iki farklı yöntemden biri kullanılmaktadır [56]. Bu yöntemlerden ilki biri-diğerine-karşı (BDK) (ing. one-against-one (OAO)) diğeri ise biri-hepsine-karşı (BHK) (ing. one-against-all) yöntemidir. Biri-diğerine-karşı (BDK) yönteminde her iki sınıf için yukarıda anlatıldığı gibi bir sınıflandırıcı hiperdüzlemi bulunur. Yani bu yöntemde n kadar farklı sınıf varsa toplamda $\frac{n*(n-1)}{2}$ tane sınıflandırıcı hiperdüzlemi bulunması gerekmektedir [57]. Daha sonra her yeni gelen veri sırasıyla bütün sınıflandırıcılardan geçirilir. Veri,

sınıflandırıcılar tarafından en çok hangi sınıfta işaretlenmişse o sınıfta olarak kabul edilir. Çok Sınıflı Destek Vektör Makineleri için kullanılan biri-hepsine-karşı yönteminde ise her bir sınıf kalan sınıflara göre sınıflandırılır. Bu yöntemde ise n kadar farklı sınıf varsa toplamda n tane sınıflandırıcı hiperdüzlemi bulunur [58]. Her yeni gelen veri bu hiperdüzlemlerde kazanan-hepsini-alır (ing. winner-takes-all) yolu izlenilerek sınıflandırılır [59]. Yani, yeni gelen veri sınıflandırıcılar tarafından, kalan veriler grubunda değil de herhangi bir sınıfta sınıflandırılırsa bu veri o sınıfa ait kabul edilir.

Bu tez için yapılan çalışmalarda biri-hepsine-karşı (BHK) yöntemi izlenmiştir. Yani, Madde-1 ile kalan veri grubu için bir sınıflandırıcı, Madde-2 ile kalan veri grubu için bir sınıflandırıcı, ... Madde-8 ile kalan veri grubu için bir sınıflandırıcı hesaplanmış, eğer yeni gelen veri hiçbir maddeye ait değilse arka plan verisi olarak sınıflandırılmıştır. Bu tez içeriğinde sadece Madde-1 verisinin sınıflandırılma sonuçları incelendiği için, Çok Sınıflı Destek Vektör Makineleri için yapılan sınıflandırma sonuçları gösterilmemiştir.

4.2.2. İmza Tabanlı Sınıflandırma

İmza tabanlı sınıflandırma, verilerden öznitelik çıkartıp bunlar üzerinden sınıflandırma yapmak yerine veriyi bütünüyle ele alan algoritmaları içerir. Boyut indirgeyerek herhangi bir veri elenmediği için her veri önemli olduğu durumlarda öznitelik tabanlı sınıflandırıcılara göre daha iyi sonuç verebilmektedir [60]. Ancak, hem çok boyutlu durumda boyut indirgeme yapılmadığı için daha yavaş hem de yüksek gürültülü durumda veri olduğu gibi kullanıldığında daha az performansla çalışabilmektedir.

İmza tabanlı sınıflandırıcılarda temel olarak, bulunmak istenen nesnenin imzasının, yani nesnenin ilgili algılayıcı karşısındaki davranışının bilindiği kabul edilir. Aynı şekilde, arka plan olarak kabul edilen nesnenin imzasının da modellenebileceği düşünülmektedir. Yeni gelecek her verinin bilinen nesne imzasına ve arka plan imzasına yakınlığı incelenir. Yeni veri, hedef imzasına seçilecek eşik değerinden daha fazla yaklaşmış ise bu veri hedef olarak sınıflandırılır.

4.2.2.1. Uyumlu Filtre

Uyumlu filtre ikili hipotez testine dayanan bir yöntemdir [61]. Bu yöntemde tanımlanan hedef ve hedef olmayan hipotezleri Denklem 38 ve Denklem 39'da görüldüğü gibi

olmaktadır. t vektörü bilinen bir hedefin imzasını ifade etmekteyken x vektörü sınıflandırılmak için gelen yeni veriyi ifade eder.

$$H_0: x = v, \quad \text{arka plan} \quad (38)$$

$$H_1: x = t + v, \quad \text{hedef} \quad (39)$$

Bu hipotezlerin olabilirlik oranı testi Denklem 40'taki gibi yazılabilir. e eşik değeri olarak kabul edildiğinde, eğer Λ değeri bu eşik değerinden fazla ise H_1 hipotezinin doğru olduğu yani yeni gelen x verisinin hedef olduğu kabul edilirken bu eşik değerinden düşüğe H_0 hipotezinin doğru olduğu yani yeni gelen x verisinin arka plan olduğu düşünülür.

$$\Lambda = \frac{f(x|H_1)}{f(x|H_0)} \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} e \quad (40)$$


Uyumlu filtre, hedef modelinin de aynı arka plan modeli gibi normal dağılıma sahip olduğunu ve hedef kovaryansı ile arka plan kovaryansının aynı olduğunu kabul eder [61]. Bu kabul ile birlikte hedef tespit denklemi Denklem 41 gibi olmaktadır [62].

$$D_{MF}(x) = \frac{(t - \mu_b)^T \Sigma_b^{-1} (x - \mu_b)}{(t - \mu_b)^T \Sigma_b^{-1} (t - \mu_b)} \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} e \quad (41)$$

Uyumlu filltre genel olarak, yeni gelen piksellin imzası ile hedef olarak seçilen pikselin imzası arasındaki korelasyonu incelemektedir.

4.2.2.2. Spektral Açı Eşleyici

Spektral Açı Eşleyici, herhangi bir arka plan karakterizasyonuna gerek kalmadan iki imza arasındaki benzerliği betimleme algoritmasıdır [63]. Bu algoritma temel olarak iki imza arasındaki açı değerini göstermektedir. İki imza arasındaki açı ve kosinüsü Şekil 7'de görülmektedir.



Şekil 7. İki İmza Arasındaki Açılı ve Kosinüsü

Şekil 7’de gösterilen açının değerini bulan Spektral Açılı Eşleyici algoritmasının denklemleri Denklem 42’de gösterilmiştir.

$$D_{SAE} = \cos^{-1} \left(\frac{\mathbf{t}^T \mathbf{x}}{(\mathbf{t}^T \mathbf{t})^{\frac{1}{2}} (\mathbf{x}^T \mathbf{x})^{\frac{1}{2}}} \right) \begin{matrix} H_1 \\ > e \\ H_0 \end{matrix} \quad (42)$$

İki imza birbirine ne kadar yakınsa birbirleri arasındaki açılı o kadar küçük olacak, bu açılıın kosinüsü de o kadar büyük olacaktır. Böylece yeni gelen x verisi hedef verisi olan t ’ye benzer kabul edilip hedef olarak sınıflandırılacaktır.

4.3. Son İşleme

Ön işleme işlemleri sınıflandırıcıların hata yapmaması için kullanılırken, son işleme algoritmaları ise sınıflandırıcıların yaptığı hataları ayıklamak için kullanılır. Son işleme algoritmalarında, sınıflandırma bölümünde kullanılan kuvvetli sınıflandırıcılara ek zayıf bir sınıflandırıcı algoritması da kullanılabilir.

Bu tez kapsamında iki tane son işleme algoritması geliştirilmiştir. Tezin bu bölümünde, geliştirilen son işleme tekniklerinin teorik bilgileri anlatılmış olup veri üzerindeki sonuçları Bölüm 5’te incelenmiştir.

4.3.1. Eğim Eşikleme

Tek boyutta N elemanı olan her veriyi parçalalı doğrusal çizgi ile belirtmek mümkündür. Bu çizgi içerisinde veriye göre artışlar ya da azalışlar olacaktır. Eğim eşikleme algoritması, N elemanlı verinin belirlenen bölgedeki artış ya da azalış hızını belirlemek ve belirlenen bir eşik değerinden fazla olup olmadığını kontrol etmek için kullanılır.

Seçilen n_L ve n_U aralığında eğim bulabilmek için önce verinin bu bölgesi üzerine $y = mx + c$ şeklinde bir doğru oturtulur. Oturtulan bu doğruya m eğimi verirken c ise y ekseninin kesim noktası olan sabit sayıyı vermektedir. En iyi doğruyu oturtabilmek için Denklem 43'ün sağlanabiliyor olması gerekmektedir. Denklem 43'deki y veriyi gösterirken x ise verinin x eksenindeki değerlerini gösterir.

$$y = mx + c, \quad \begin{bmatrix} y_{n_L} \\ y_{n_L+1} \\ y_{n_L+2} \\ \vdots \\ y_{n_U} \end{bmatrix} = m \begin{bmatrix} x_{n_L} \\ x_{n_L+1} \\ x_{n_L+2} \\ \vdots \\ x_{n_U} \end{bmatrix} + c \quad (43)$$

Denklem 43 matris formunda yazılırsa Denklem 44 elde edilir.

$$\begin{bmatrix} y_{n_L} \\ y_{n_L+1} \\ y_{n_L+2} \\ \vdots \\ y_{n_U} \end{bmatrix} = \begin{bmatrix} x_{n_L} & 1 \\ x_{n_L+1} & 1 \\ x_{n_L+2} & 1 \\ \vdots & \vdots \\ x_{n_U} & 1 \end{bmatrix} \begin{bmatrix} m \\ c \end{bmatrix} \quad (44)$$

Bu formdaki matristen m ve c değerlerini bulabilmek için denklemin sağındaki matris ters çevrilerek çarpılır. Böylelikle m ve c değerleri Denklem 45'de görüldüğü gibi bulunabilir.

$$\begin{bmatrix} m \\ c \end{bmatrix} = \begin{bmatrix} x_{n_L} & 1 \\ x_{n_L+1} & 1 \\ x_{n_L+2} & 1 \\ \vdots & \vdots \\ x_{n_U} & 1 \end{bmatrix}^+ \begin{bmatrix} y_{n_L} \\ y_{n_L+1} \\ y_{n_L+2} \\ \vdots \\ y_{n_U} \end{bmatrix} \quad (45)$$

Ancak, kare olmayan matrislerin tersi olmadığı için matris, yalancı ters çevirme yöntemi ile ters çevrilir. Denklem 46'da yalancı ters çevirme yönteminden sonra elde edilen Eğim Eşikleme denklemi görülmektedir.

$$\begin{bmatrix} m \\ c \end{bmatrix} = \begin{bmatrix} x_{n_L} & 1 \\ x_{n_L+1} & 1 \\ x_{n_L+2} & 1 \\ \vdots & \vdots \\ x_{n_U} & 1 \end{bmatrix}^T \left(\begin{bmatrix} x_{n_L} & 1 \\ x_{n_L+1} & 1 \\ x_{n_L+2} & 1 \\ \vdots & \vdots \\ x_{n_U} & 1 \end{bmatrix} \begin{bmatrix} x_{n_L} & 1 \\ x_{n_L+1} & 1 \\ x_{n_L+2} & 1 \\ \vdots & \vdots \\ x_{n_U} & 1 \end{bmatrix}^T \right)^{-1} \begin{bmatrix} y_{n_L} \\ y_{n_L+1} \\ y_{n_L+2} \\ \vdots \\ y_{n_U} \end{bmatrix} \quad (46)$$

Bu denklem ile bulunan c değeri, veri üzerine oturtulan doğrunun y eksenini kestiği noktayı göstermektedir. Bu algorithmada sadece eğim incelendiği için c değeri

kullanılmamıştır. N elemanlı bir veriden Denklem 46 ile çıkartılan m değeri, e eşik değerinin altında ise sınıflandırıcı tarafından hedef olarak sınıflandırılmış olsa bile arka plan olarak işaretlenir. Bu karşılaştırma Denklem 47’de gösterilmiştir.

$$\begin{aligned} m < e, & \quad \text{arka plan} \\ m > e, & \quad \text{hedef} \end{aligned} \quad (47)$$

e eşik değeri ise arka plan olduğu bilinen verilerin eğiminden yüksek, hedef olduğu bilinen verilerin eğiminden düşük olacak şekilde belirlenir.

4.3.2. Piksel Silme

Bölüm 3’te anlatıldığı gibi her bir materyal ve arka plan için toplanan veriler bir veri küpü oluşturmaktadır. Bu veri küpünün içerisindeki uzamsal boyuttaki her veri piksel olarak değerlendirilmektedir. Hedef veya arka plan olarak değerlendirilen bu piksellerin tamamı daha önceki bölümlerde anlatılan algoritmalar ile sınıflandırılır.

Bu algoritma, “veri küpünde eğer gerçekten bir hedef varsa n ’den fazla piksel hedef olarak işaretlenmelidir” varsayımında bulunmaktadır. Bu yüzden, eğer bütün bir veri küpünde sadece n tane piksel hedef olarak işaretlenmiş ise bu pikseller hatalı sınıflandırma olarak değerlendirilip, bütün hedef işaretleri silinerek arka plan olarak işaretlenir. Bu algoritma, sınıflandırma işlemine hata toleransı sağlamaktadır.

Denklem 48’de bu algoritmanın yöntemi gösterilmiştir. M veri küpündeki toplam veri sayısını, i verisinin indeksini gösterir. Hedef olarak işaretlenen piksellerin etiket değeri, l_i 1 iken arka plan olarak işaretlenen piksellerin etiket değerleri, l_i 0’dır.

$$\sum_{i=1}^M l_i < n \Rightarrow \forall l_i = 0 \quad (48)$$

5. DENEYSEL SONUÇLAR

Bölüm 3'te anlatıldığı gibi bu tez kapsamında hedef için 8 farklı madde 5 farklı arka plan ve her birinden 5 farklı örnek olmak üzere 200 veri küpü incelenmiştir. Her bir veri küpünde tarama süresi farklı olabildiği için toplam tarama sayısına bağlı olarak toplam piksel sayısı da farklılık gösterebilmektedir. Ancak bu tez için, her bir veri küpünde 16 tarama olacak şekilde veri toplanmıştır. Her taramada 908 piksel bulunduğu için her veri küpü 14528 pikselden oluşmaktadır. Her madde-materyal eşleşmesi için 5 örnek alındığından her eşleşme için toplam 72640 piksel vardır. Ayrıca, her piksel için 548 farklı dalga boyu bulunmaktadır. Hedef için toplanan verilerin boyutları Tablo 2'de görülebilir.

Tablo 2. Hedef Verilerinin Boyutları

		Örnek Sayısı	Tarama Sayısı	Her Taramadaki Piksel Sayısı	Her Örnekteki Toplam Piksel Sayısı	Toplam Piksel Sayısı	Dalga boyu
Madde-1	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-2	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-3	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-4	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-5	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-6	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-7	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548
Madde-8	Materyal-1	5	16	908	14528	72640	548
	Materyal-2	5	16	908	14528	72640	548
	Materyal-3	5	16	908	14528	72640	548
	Materyal-4	5	16	908	14528	72640	548
	Materyal-5	5	16	908	14528	72640	548

Tablo 2’de görüldüğü gibi toplam 200 adet veri küpü incelenmiş her bir Madde için ayrı ayrı sınıflandırma çalışması yapılmıştır. Ancak, bu tezde sadece Madde-1 için sonuçlar gösterilmiştir. Yani tezin ilerleyen bölümlerinde her biri 5 örnekten 5 Materyal için toplamda 25 veri küpü sonuçları görülmektedir.

Hedef için toplanan verilerin yanısıra arka plan için de veriler toplanmıştır. Toplanan arka plan verilerinin veri boyutları Tablo 3’te gösterilmiştir.

Tablo 3. Arka Plan Verilerinin Boyutları

	Tarama Sayısı	Her Taramadaki Piksel Sayısı	Toplam Piksel Sayısı	Dalga boyu
Arka Plan-1	16	908	14528	548
Arka Plan-2	8	908	7264	548
Arka Plan-3	8	908	7264	548
Arka Plan-4	8	908	7264	548
Arka Plan-5	8	908	7264	548
Arka Plan-6	20	908	18160	548
Arka Plan-7	20	908	18160	548
Arka Plan-8	20	908	18160	548
Arka Plan-9	20	908	18160	548
Arka Plan-10	20	908	18160	548
Arka Plan-11	20	908	18160	548
Arka Plan-12	20	908	18160	548
Arka Plan-13	20	908	18160	548
Arka Plan-14	20	908	18160	548
Arka Plan-15	20	908	18160	548


Tablo 3’te görüldüğü gibi toplamda 15 arka plan verisi kullanılmıştır. Her bir arka plan veri küpünün toplam piksel sayısı farklılık göstermektedir.

Tablo 2 ve Tablo 3’te görüldüğü gibi incelenen veri boyutları oldukça fazladır. Bu tez kapsamında sunulan sonuçlarda bütün sonuçların gösterilmesinin zorluğundan dolayı en fazla bilgi içeren sonuçlar seçilerek onlar gösterilmiştir.

5.1. Ön İşleme İçin Deneysel Sonuçlar

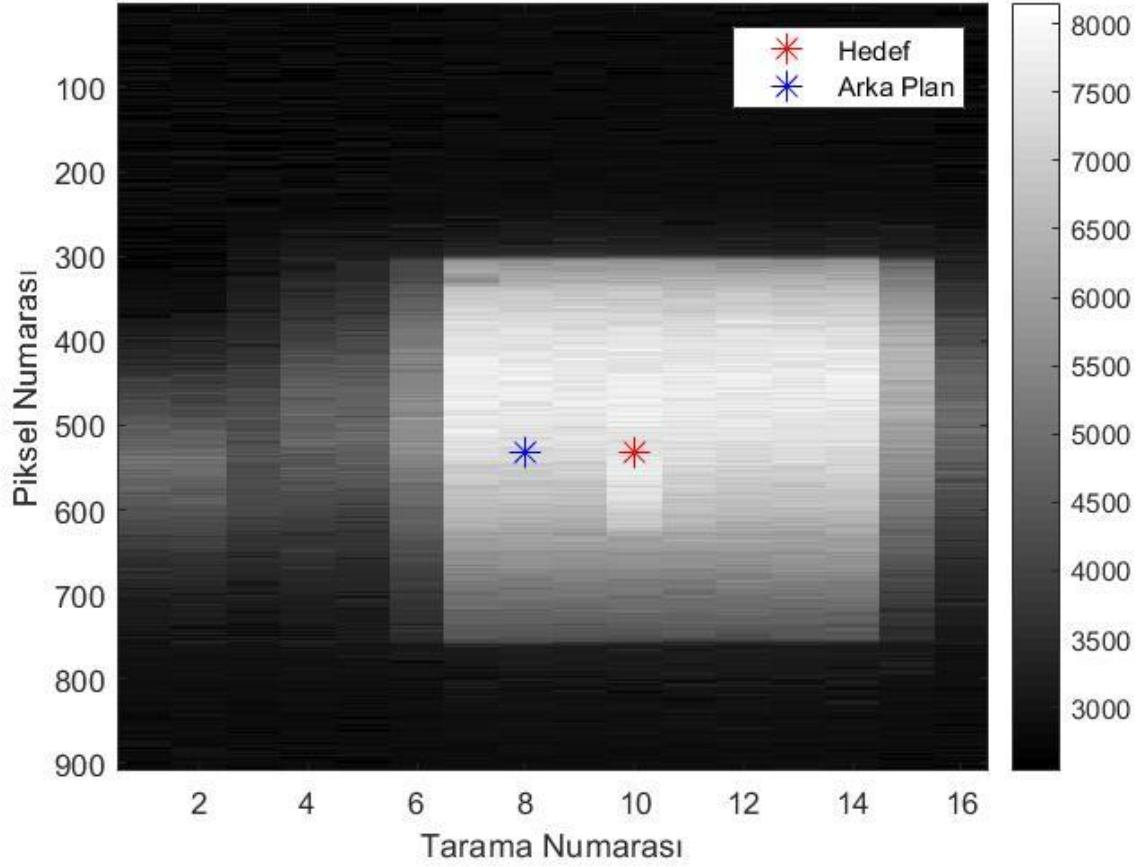
Toplanan verilerin herhangi bir işlem uygulamadan önceki durumlarının incelenmesi bu kısımda yapılacaktır. Veri incelemesi için Materyal-1 üzerine Madde-1 konarak toplanan

veri küplerinden biri seçilmiştir. Şekil 8’de veri küpünün ham verilerinin 320nm dalga boyundaki resmi görülmektedir.



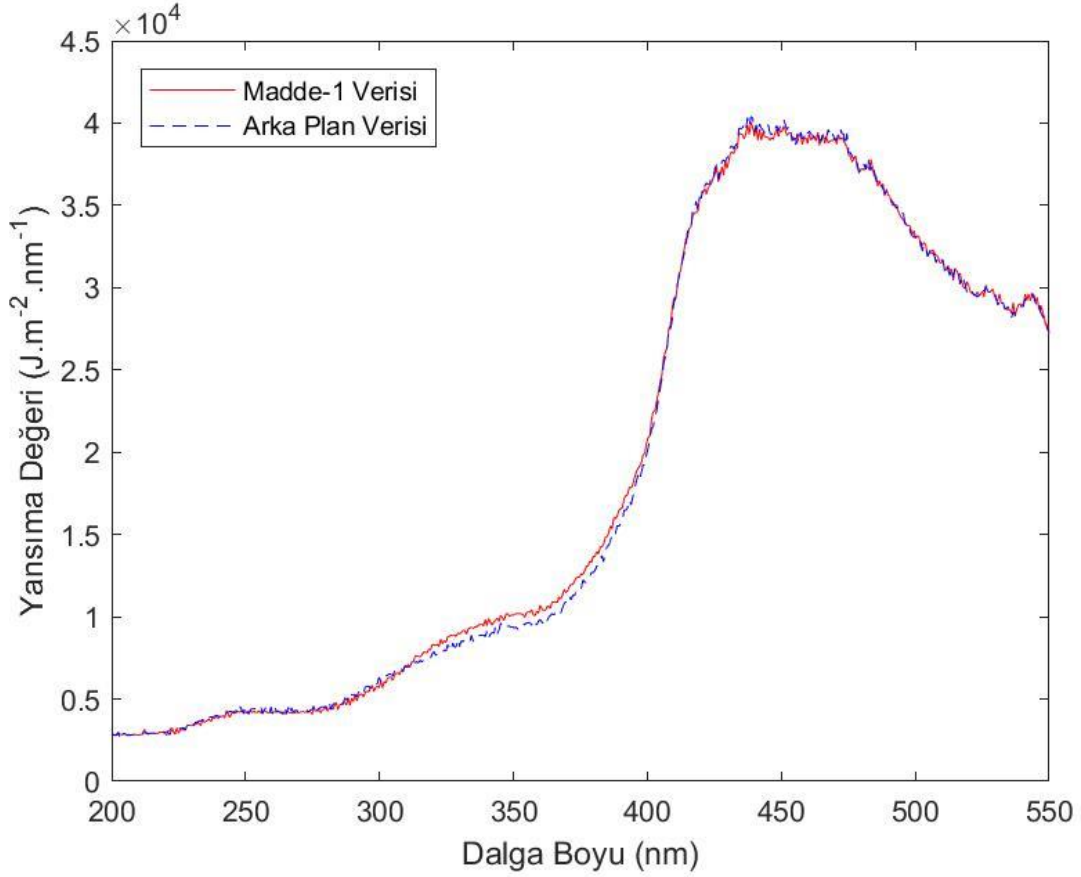
Şekil 8. Materyal-1 Üzerindeki Ham Madde-1 Verisi (Dalga boyu: 320nm)

Bütün veri küplerinde hedef kontrollü olarak konulduğu için hedef olan piksellerin indeksi bilinmektedir. Hedef için seçilen herhangi bir piksel ile arka plan için seçilen herhangi bir pikselin ham veri üzerindeki konumları Şekil 9’da gösterilmiştir. Hedef için rastgele seçilen Madde-1 pikseli kırmızı ile işaretlenirken arka plan için seçilen piksel mavi ile işaretlenmiştir.



Şekil 9. Seçilen Hedef Ve Arka Plan Verilerinin Ham Veri Üzerindeki Konumları

Veri küpü 3 boyutlu olduğu için iki boyutlu düzlemde sadece kesitler alınarak görülebilmektedir. Bu yüzden, veri küpü Şekil 8 ve Şekil 9'da bir dalga boyunda (320 nm) kesit alınarak gösterilmiştir. Şekil 8 ve Şekil 9'daki piksellerin her birinin 548 farklı dalga boyunda yansıma değerleri bulunmaktadır. Şekil 9'da hedef için seçilen Madde- pikseli ile arka plan için seçilen Materyal-1 pikselinin dalga boyuna bağlı yansıma değeri grafikleri Şekil 10'da görülmektedir.

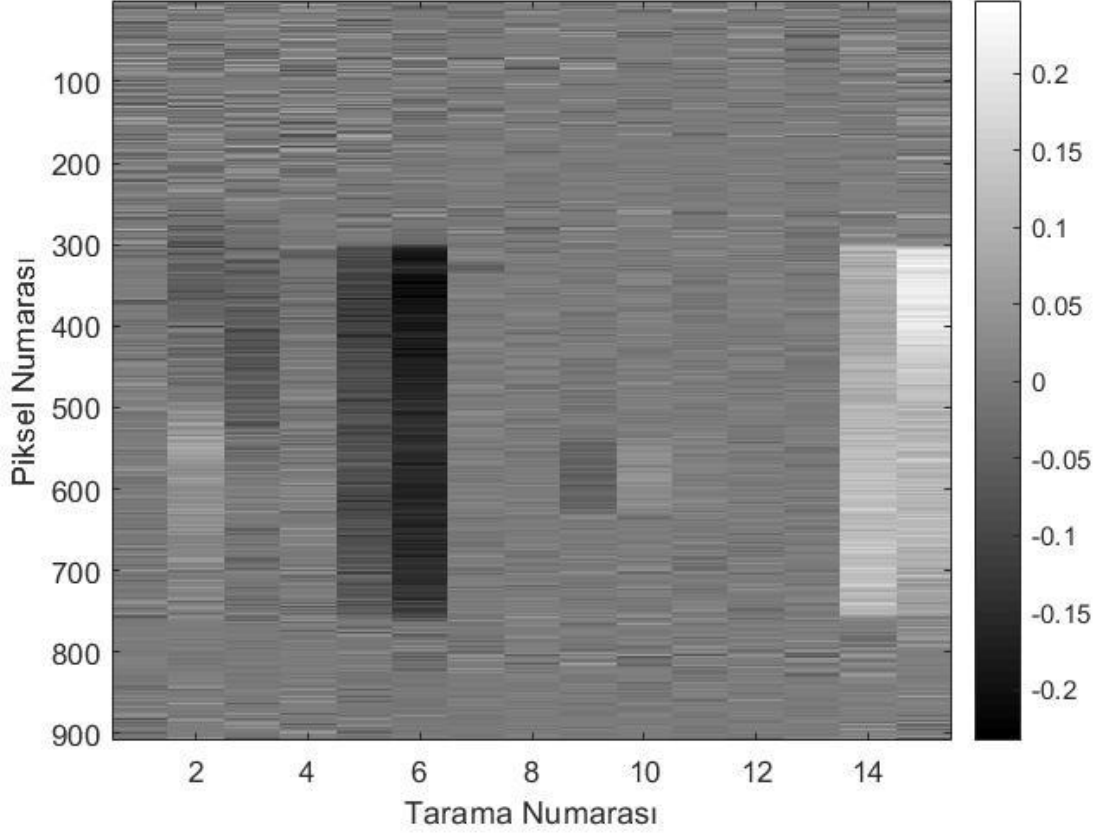


Şekil 10. Bir Pikselin Dalga Boyuna Göre Yansıma Değerleri

Şekil 8 ve Şekil 10'da görüldüğü gibi herhangi bir işlem yapılmadığında veriler birbirine çok benzemektedir. Bu sebeple veriler önce ön işleme tabi tutulacaklardır.


5.1.1. Diferansiyel Alma Sonuçları

Ön işlemenin ilk basamağı diferansiyel almadır. Diferansiyel alma işlemi Bölüm 4'te anlatıldığı gibi tarama eksenini yani x eksenini üzerinde yapılmaktadır. Daha önce kullanılan örnek veri küpü için diferansiyel alınmış verilerin yine 320nm dalga boyundaki resmi Şekil 11'de görülmektedir.




Şekil 11. Materyal-1 Üzerindeki Diferansiyel Madde-1 Verisi (Dalga Boyu: 320nm)

Şekil 11'de görüldüğü gibi diferansiyel alma işlemi sonrasında tarama boyutu bir eksilmektedir. Piksel numaraları ise sabit kalmaktadır. Piksellerdeki veri ise yansıma değeri yerine normalize edilmiş diferansiyel yansıma değeri olduğu için değişmiş bir oran ifadesi olduğu için de birimsiz hale gelmiştir. Şekil 12'de Madde-1 ve arka plan için bu değerler görülmektedir.




Şekil 12. Diferansiyel İşlemi Sonrası Dalga Boyuna Göre Madde-1 ve Arka Plan Yansıma Grafiği

Şekil 12'de görüldüğü gibi Madde-1 ve arka planın normalize edilmiş diferansiyel verileri birbirinden farklı olmaktadır. Alınan fark dolayısıyla arka plan verileri sıfıra daha yakınken Madde-1 verileri sıfırdan biraz daha uzak kalmaktadır. Her ne kadar aradaki fark bu durum için belirgin olsa da gürültünün çok fazla olmasından dolayı bu farkın belirgin olmadığı durumlar mevcuttur. Bu sebeple, bir gürültü filtreleme algoritması kullanma ihtiyacı doğmuştur. Örnek olarak, çerçeve boyutu 21 olan 2. dereceden Savitzky–Golay filtresiyle filtrelenmiş arka plan ve Madde-1 verilerinin grafiği Şekil 13'te gösterilmiştir.



Şekil 13. S.Golay (Derece:2 Çerçeve:21) ile Filtrelenmiş Madde-1 ve Arka Plan Yansıma Grafiği

Çıkan bu sonuçta Madde-1 verileri pozitif yönde gözükmesine rağmen her zaman bu yönde olmak zorunda değildir. Fark işleminde, Madde-1'den arka plan çıkarsa, sonuç pozitif olmaktadır. Ancak, bir tarama sonraki piksel için, arka plandan Madde-1 çıkartıldığında ise sonuç negatif olmaktadır. Şekil 13'te gösterilen hedef verisi ile bir tarama sonraki hedef verisinin grafikleri Şekil 14'te gösterilmiştir.




Şekil 14. Pozitif ve Negatif Yöndeki Madde-1 Verileri


Pozitif ya da negatif yönde çıkan hedef sinyallerinden dolayı bu tez kapsamında veri işaretinden bağımsız çalışan algoritmalar kullanılmıştır.

5.1.2. S.Golay Filtresi Sonuçları


Bölüm 4'te anlatıldığı gibi S.Golay filtresinin derece ve çerçeve boyutu olmak üzere 2 değişkeni bulunmaktadır. Bu parametreler üzerinde değişiklikler yapılarak filtreleme sonuçları incelenmiştir. Madde-1 ve arka plan verileri için farklı parametreler ile yapılan filtreleme sonuçları sırasıyla Şekil 15 ve Şekil 16'da gösterilmiştir.




Şekil 15a. S.Golay Filtresi (Derece:1, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 15b. S.Golay Filtresi (Derece:1, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 15c. S.Golay Filtresi (Derece:1, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 15ç. S.Golay Filtresi (Derece:1, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 15d. S.Golay Filtresi (Derece:2, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 15e. S.Golay Filtresi (Derece:2, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 15f. S.Golay Filtresi (Derece:2, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 15g. S.Golay Filtresi (Derece:2, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 15ğ. S.Golay Filtresi (Derece:4, Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 15h. S.Golay Filtresi (Derece:4, Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 15i. S.Golay Filtresi (Derece:4, Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 15i. S.Golay Filtresi (Derece:4, Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 16a. S.Golay Filtresi (Derece:1, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi




Şekil 16b. S.Golay Filtresi (Derece:1, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi




Şekil 16c. S.Golay Filtresi (Derece:1, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi




Şekil 16ç. S.Golay Filtresi (Derece:1, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi




Şekil 16d. S.Golay Filtresi (Derece:2, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi




Şekil 16e. S.Golay Filtresi (Derece:2, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi




Şekil 16f. S.Golay Filtresi (Derece:2, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi




Şekil 16g. S.Golay Filtresi (Derece:2, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi




Şekil 16ğ. S.Golay Filtresi (Derece:4, Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi



Şekil 16h. S.Golay Filtresi (Derece:4, Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi




Şekil 16i. S.Golay Filtresi (Derece:4, Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi




Şekil 16i. S.Golay Filtresi (Derece:4, Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi

5.1.3. Hareketli-Ortalama Filtresi Sonuçları


Bölüm 4'te görüldüğü gibi hareketli ortalama filtresinin ayarlanabilen tek parametresi n yani komşuluk değeridir. Madde-1 ve arka plan verileri için farklı çerçeve, $2n + 1$ değerleri ile yapılan filtreleme sonuçları sırasıyla Şekil 17 ve Şekil 18'de görüldüğü gibidir.




Şekil 17a. Hareketli Ortalama Filtresi (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 17b. Hareketli Ortalama Filtresi (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 17c. Hareketli Ortalama Filtresi (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 17ç. Hareketli Ortalama Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 18a. Hareketli Ortalama Filtresi (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi



Şekil 18b. Hareketli Ortalama Filtresi (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi




Şekil 18c. Hareketli Ortalama Filtresi (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi




Şekil 18ç. Hareketli Ortalama Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi

5.1.4. Gaussian Filtresi Sonuçları


Gaussian filtresi için tek parametrenin standart sapma, σ olduğu, Bölüm 4'te anlatılmıştır. Ancak, diğer filtreler ile benzerlik olması açısından standart sapma, σ yerine çerçeve parametresi $2n + 1 = 4\sigma + 1$ kullanılmıştır. Madde-1 ve arka plan verileri için farklı çerçeve, $2n + 1$ değerleri ile yapılan filtreleme sonuçları sırasıyla ve Şekil 19 ve Şekil 20'de görülmektedir.




Şekil 19a. Gaussian Filtresi (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 19b. Gaussian Filtresi (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 19c. Gaussian Filtresi (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 19ç. Gaussian Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 20a. Gaussian Filtresi (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi



Şekil 20b. Gaussian Filtresi (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi




Şekil 20c. Gaussian Filtresi (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi




Şekil 20ç. Gaussian Filtresi (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi

5.1.5. Medyan Filtre Sonuçları


Medyan Filtre'nin madde-1 ve arka plan verileri için farklı çerçeve parametresine göre sonuçları Şekil 21 ve Şekil 22'de gösterilmiştir.




Şekil 21a. Medyan Filtre (Çerçeve:11) ile Filtrelenmiş Madde-1 Verisi




Şekil 21b. Medyan Filtre (Çerçeve:21) ile Filtrelenmiş Madde-1 Verisi




Şekil 21c. Medyan Filtre (Çerçeve:51) ile Filtrelenmiş Madde-1 Verisi




Şekil 21ç. Medyan Filtre (Çerçeve:11-21-51) ile Filtrelenmiş Madde-1 Verisi




Şekil 22a. Medyan Filtre (Çerçeve:11) ile Filtrelenmiş Arka Plan Verisi



Şekil 22b. Medyan Filtre (Çerçeve:21) ile Filtrelenmiş Arka Plan Verisi



Şekil 22c. Medyan Filtre (Çerçeve:51) ile Filtrelenmiş Arka Plan Verisi



Şekil 22ç. Medyan Filtre (Çerçeve:11-21-51) ile Filtrelenmiş Arka Plan Verisi

5.2. Ön İşleme Sonuçlarının İncelenmesi

Gaussian, Hareketli-Ortalama, ve Savitky-Golay filtreleri doğrusal filtreler olup veri üzerindeki uygulaması çarpma ve toplama işlemlerinin kombinasyonlarından oluşmaktadır. Buna karşın Medyan filtresi doğrusal olmayan bir filtre olmasından dolayı daha çok zaman alan bir filtre olarak ortaya çıkmıştır. Bölüm 3'te anlatıldığı gibi algoritmaların toplam hızı, taşıyıcı bandın hızından daha fazla olmalıdır. Bu yüzden fazla zaman alan bir uygulamanın götürüsü de fazla olmaktadır.

Filtrelemenin esas hedefi gürültüyü gidermektir. Ancak, gürültüyü giderirken herhangi bir veri kaybının yaşanmaması gerekmektedir. O yüzden daha yumuşak veri her zaman daha iyi veri anlamına gelmemektedir. Veri içerisinde olması gereken iniş ve çıkışların kaybedilmesi sınıflandırıcıların yanlış sınıflandırmasına sebebiyet verebilir.

Filtrelerdeki çerçeve boyutunun artmasıyla gürültünün azaldığı görülmektedir. Ancak, en yüksek tepeler kaybolmasa da veri içerisindeki bazı zirve ve dip noktalarının da

kaybolduğu görülmektedir. Daha fazla veri işleme alındığı için zirve ve dip noktaları için oluşan eğim azalmaktadır. Savitzky–Golay filtresinde derece yükseldikçe veri üzerine oturtulan fonksiyonun derecesi yükseldiği için veriyi daha iyi takip edebilmektedir. Böylelikle, zirve ve dip noktaları arasında oluşan eğim korunabilmektedir. Ancak veri fazla iyi takip edildiğinde gürültüden kaynaklanan veriler de takip edilir ve veri üzerinde bulunmaması gereken zirve ve dipler oluşmaktadır.


Bütün filtreler incelendiğinde, normalize edilmiş diferansiyel verileri için en iyi filtrenin çerçeve boyutu 21 olan 2. dereceden Savitzky–Golay filtresi olduğu karar verilmiştir. Tezin devamında bu filtre sonucunda ortaya çıkan veri kullanılarak işlemler yapılacaktır.

5.3. Sınıflandırma İçin Deneysel Sonuçlar


Bölüm 3'te anlatıldığı gibi, farklı arka planlardaki farklı nesnelere için toplanan veriler, içine algoritma yüklenen bir bilgisayar tarafından sınıflandırılacaktır. Hedef olarak seçilen 8 farklı nesne olmasına rağmen, bu tez kapsamında yapılan çalışmalarda tek seferde tek nesnenin bulunması amaçlanmıştır. Bu sebeple, kullanıcının, tarama yapmadan önce, bulmak istediği nesne için özelleştirilen algoritma parametrelerini sisteme yüklemesi gerekmektedir. Eğer farklı bir nesne bulunmak isteniyorsa yüklenen algoritma parametrelerini değiştirerek tekrar tarama yapması gerekecektir. Her tarama için hedef nesne belirli olmasına rağmen, arka plandaki materyaller değişiklik gösterebilir. Bu yüzden, toplanan veriler hedef nesnelere göre gruplandırılmış ve sınıflandırma algoritmalarının parametreleri bu gruplara özel olarak belirlenmiştir.

Bütün sınıflandırma işlemleri her veri grubu için ayrı ayrı yapılmış olmasına rağmen, bu tezde sadece, filtreleme bölümünde örnek olarak verilen veri küpünün de içinde bulunduğu Madde-1 veri grubu anlatılacaktır. Bu veri grubunun içerisinde, arka planları Materyal-1, Materyal-2, Materyal-3, Materyal-4 ve Materyal-5'den biri olan 5 adet veri küpü kümesi bulunmaktadır. Her veri küpü kümesinde ise 5 adet tarama verisi bulunmaktadır. Ayrıca, içerisinde Madde-1 bulunmayan sadece arka planın olduğu 15 adet veri küpü de sınıflandırmayı daha doğru yapabilmek adına bu veri grubuna dahil edilmiştir. Sonuç olarak, tezin bu bölümünde toplamda 40 veri küpü incelenecektir.


Sınıflandırma işlemlerinden önce Bölüm 4'te bahsedilen eğitim verisini belirlemek önemli bir başlangıç olacaktır. Her bir veri kümesinden bir veri küpü seçilmiş ve seçilen veri küplerinden örnek olarak alınan bir hedef pikselin görüntüleri Şekil 23'te gösterilmiştir.




Şekil 23a. Materyal-1 Üzerindeki Filtrelenmiş Madde-1 Verisi




Şekil 23b. Materyal-2 Üzerindeki Filtrelenmiş Madde-1 Verisi



Şekil 23c. Materyal-3 Üzerindeki Filtrelenmiş Madde-1 Verisi



Şekil 23ç. Materyal-4 Üzerindeki Filtrelenmiş Madde-1 Verisi




Şekil 23d. Materyal-5 Üzerindeki Filtrelenmiş Madde-1 Verisi

5.3.1. Öznitelik Tabanlı Sınıflandırma Sonuçları

Öznitelik tabanlı sınıflandırma için Madde-1 veri grubundan 2 adet veri küp kümesi eğitim sınıfına ayrılırken kalan 3 veri küp kümesi test verisinde incelenecektir. Bu veri grubu için eğitim sınıfına seçilen veri küp kümeleri Materyal-2 ve Materyal-5 üzerindeki veri küpleridir. Arka plan veri küplerinden ise 10 tanesi eğitim sınıfına, 5 tanesi test sınıfına ayrılmıştır. Arka plan verilerinin piksel sayısı hedef piksellerden fazla olduğu için arka plan verilerinden hedef piksel sayısı kadar piksel alınarak eğitim verileri içerisinde hedef sayısı ile arka plan sayısı eşitlenmiştir. Bu durum, sınıflandırıcının bir sınıfa meyilli olmasını engeller.

5.3.1.1. Temel Bileşenler Analizi Sonuçları


Ayrılan eğitim verileri Bölüm 4'te anlatılan TBA tekniği ile analiz edilmiştir. Analiz sonucunda eğitim verilerinden çıkartılan özdeğerlerin logaritmik gösterimi Şekil 24'te görülmektedir.



Şekil 24. Temel Bileşenler Analizi Özdeğerlerin Logaritmik Gösterimi

Şekil 24'te görüldüğü gibi λ 'lar azalan değerlerine göre sıralanmıştır. Çok fazla özdeğerin seçilmesinin işlem karmaşıklığı yaratabileceği ve çok az özdeğerin seçilmesinin de önemli verilerin kaybına sebep olabileceği gerekçesinden dolayı baştan 6 özdeğerin önemli olduğuna karar verilmiştir. Daha sonra veriler, Bölüm 4'te anlatıldığı gibi seçilen bu 6 özdeğere karşılık gelen 6 özvektörlere yansıtılarak, sınıflandırma için hazır hale getirilir.

Yeni oluşan 6 boyutlu yansıtılmış verilerin grafiği, 2 boyutlu düzlemde görülemeyeceği için gösterilememiştir. Onun yerine, ilk iki boyuta yansıtılmış verilerin grafiği Şekil 25'te gösterilmiştir. Şekil 25'te görülen w_1 ilk özvektörü ifade ederken w_2 ikinci özvektörü ifade etmektedir. Buna göre de $w_1^T x$ verilerin birinci özvektör üzerindeki yansımalarını gösterirken $w_2^T x$ de ikinci özvektör üzerindeki yansımalarını göstermektedir.




Şekil 25. Hedef Ve Arka Plan Verilerinin İki Boyutta İncelenmesi


Bu madde için yapılan analizde Şekil 25'te görüldüğü gibi ilk 2 boyutta önemli bir kısım veri ayırt edilebilmektedir. Ancak, hem performansı arttırmak hem de yazılan algoritmayı bütün maddeler için genelleştirebilmek açısından 6 boyut da incelenmektedir.

5.3.1.2. Destek Vektör Makineleri Sonuçları


Bölüm 4'te anlatıldığı gibi Destek Vektör Makineleri için çekirdek ölçeği k ve ceza sabiti C ayarlanması gereken önemli parametrelerdir. Çekirdek ölçeğinin ve ceza sabitinin, iki boyutlu düzlemde bulunan eğitim verileri üzerindeki etkileri Şekil 26'da gösterilmiştir.




Şekil 26a. Çekirdek Ölçeği:0.3 Ceza Sabiti:1 Olan Destek Vektör Makineleri




Şekil 26b. Çekirdek Ölçeği:0.3 Ceza Sabiti:10 Olan Destek Vektör Makineleri




Şekil 26c. Çekirdek Ölçeği:0.3 Ceza Sabiti:1000 Olan Destek Vektör Makineleri




Şekil 26ç. Çekirdek Ölçeği:1 Ceza Sabiti:1 Olan Destek Vektör Makineleri




Şekil 26d. Çekirdek Ölçeği:1 Ceza Sabiti:10 Olan Destek Vektör Makineleri




Şekil 26e. Çekirdek Ölçeği:1 Ceza Sabiti:1000 Olan Destek Vektör Makineleri



Şekil 26f. Çekirdek Ölçeği:10 Ceza Sabiti:1 Olan Destek Vektör Makineleri



Şekil 26g. Çekirdek Ölçeği:10 Ceza Sabiti:10 Olan Destek Vektör Makineleri




Şekil 26ğ. Çekirdek Ölçeği:10 Ceza Sabiti:1000 Olan Destek Vektör Makineleri

Şekil 26'da görüldüğü üzere, Bölüm 4'te anlatıldığı gibi, ceza sabitinin artmasıyla daha az destek vektöre sahip, çekirdek ölçeğinin azalması ile daha iyi oturmuş bir model elde edilebilir. Hangi modelin daha iyi sonuçlar vereceğini bulmak için K (K=5) Parça Çapraz Doğrulama Testi yöntemi kullanılmıştır. Bu yöntemle göre, veri 5 ayrı bölüme ayrılmıştır. Ayrılan bu 5 bölümden ilk 4 bölüm eğitim verisi, kalan bölüm ise doğrulama verisi olarak seçilmiştir. Eğitim verisi üzerinde öğrenilen Destek Vektör Makinesi modeli doğrulama verisi üzerinde denenmiştir. Daha sonra seçilen 4 bölüm eğitim verileri değiştirilerek modelin farklı veriler ile eğitilip farklı veriler ile doğrulanması sağlanmıştır. Daha sonra çekirdek ölçeği ve ceza sabiti değiştirilerek, doğrulama sonuçlarından elde edilen toplam hata miktarının en az olması sağlanır.


Bu tez kapsamında incelenen veriler için en az doğrulama hatası ceza sabiti $C = 961.82$ ve çekirdek ölçeği $k = 0.73$ olduğunda sağlanmıştır.

Materyal-2 ve Materyal-5 eğitim verileri için ayrılmıştı. Kalan Materyal-1, Materyal-3 ve Materyal-4 için yapılan öz nitelik tabanlı sınıflandırmanın sonuçları sırasıyla Şekil 27, Şekil 28 ve Şekil 29'da görülmektedir. Her bir materyal ile 5 ayrı veri küpü toplandığı için her bir şekilde bu veri küplerinin sonuçlar ayrı ayrı gösterilmiştir. Ayrıca, test için ayrılan arka plan verilerinin sonuçları da Şekil 30'da görülebilir.


Şekil 27, Şekil 28, Şekil 29 ve Şekil 30'da görülen Doğru Negatif (DN) tabiri, hedef olmayan bir pikselin hedef değil yani arka plan olarak etiketlendiğini gösterir. Doğru Pozitif (DP) tabiri hedef olan bir pikselin hedef olarak etiketlendiğini gösterir. Yanlış Negatif (YN) tabiri hedef olan bir pikselin arka plan olarak işaretlendiğini gösterir. Yanlış Pozitif (YP) tabiri ise hedef olmayan bir pikselin yanlışlıkla hedef olarak etiketlendiğini ifade etmektedir.




Şekil 27a. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları




Şekil 27b. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları




Şekil 27c. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları




Şekil 27ç. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları




Şekil 27d. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları




Şekil 28a. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları




Şekil 28b. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları




Şekil 28c. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları




Şekil 28ç. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları




Şekil 28d. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları




Şekil 29a. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-1) İçin DVM Sonuçları




Şekil 29b. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-2) İçin DVM Sonuçları




Şekil 29c. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-3) İçin DVM Sonuçları



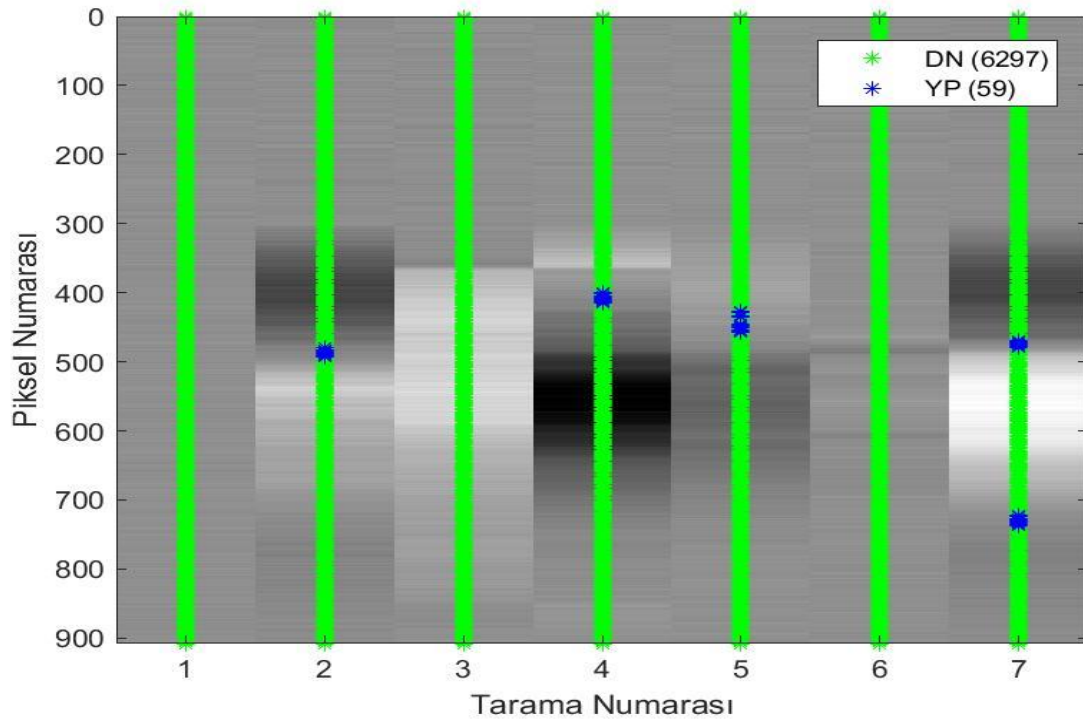
Şekil 29ç. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-4) İçin DVM Sonuçları




Şekil 29d. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-5) İçin DVM Sonuçları




Şekil 30a. Arka Plan Verileri (Örnek-1) İçin DVM Sonuçları




Şekil 30b. Arka Plan Verileri (Örnek-2) İçin DVM Sonuçları



Şekil 30c. Arka Plan Verileri (Örnek-3) İçin DVM Sonuçları



Şekil 30ç. Arka Plan Verileri (Örnek-4) İçin DVM Sonuçları



Şekil 30d. Arka Plan Verileri (Örnek-5) İçin DVM Sonuçları

Madde-1 verisi için yapılan Destek Vektör Makineleri sınıflandırma ve performans sonuçları sırasıyla Tablo 4 ve Tablo 5'te görülmektedir.

Tablo 4. Madde-1 Verisi İçin DVM Sonuçları

		DN	DP	YN	YP	TOPLAM
Materyal-1	Örnek-1	13257	355	0	8	13620
	Örnek-2	13113	465	0	42	13620
	Örnek-3	13088	473	2	57	13620
	Örnek-4	13196	361	0	63	13620
	Örnek-5	13151	370	33	66	13620
TOPLAM		65805	2024	35	236	68100
Materyal-3	Örnek-1	12947	373	0	300	13620
	Örnek-2	12926	539	0	155	13620
	Örnek-3	12982	498	0	140	13620
	Örnek-4	12899	440	0	281	13620
	Örnek-5	12974	422	0	224	13620
TOPLAM		64728	2272	0	1100	68100
Materyal-4	Örnek-1	12507	0	515	598	13620
	Örnek-2	12704	0	431	485	13620
	Örnek-3	13133	13	415	59	13620
	Örnek-4	13228	0	376	16	13620
	Örnek-5	12989	69	479	83	13620
TOPLAM		64561	82	2216	1241	68100
Arka Plan	Örnek-1	13495	0	0	125	13620
	Örnek-2	6297	0	0	59	6356
	Örnek-3	6146	0	0	210	6356
	Örnek-4	6293	0	0	63	6356
	Örnek-5	5338	0	0	1018	6356
TOPLAM		37569	0	0	1475	39044
GENEL TOPLAM		232663	4378	2251	4052	243344

Tablo 5. Madde-1 Verisi İçin DVM Performansı

Piksel Bazlı Duyarlılık	0.6604
Piksel Bazlı Özgüllük	0.9929
Veri Küpü Bazlı Duyarlılık	12 / 15
Veri Küpü Bazlı Özgüllük	0 / 5

Tablo 5'te görülen duyarlılık, doğru pozitiflerin, doğru pozitif ve yanlış negatiflerin toplamına oranı şeklinde tanımlanırken, özgüllük doğru negatiflerin, doğru negatif ve yanlış pozitiflere oranı şeklinde tanımlanmaktadır. Diğer bir deyişle, duyarlılık, hedef piksellerin doğru bulunma oranıyken, özgüllük arka plan piksellerin doğru sınıflandırılma oranıdır. Duyarlılık için tanımlanan denklem Denklem 49'da özgüllük için tanımlanan denklem ise Denklem 50'de görülmektedir.


$$Duyarlılık = \frac{Doğru Pozitif (DP) Sayısı}{Doğru Pozitif (DP) Sayısı + Yanlış Negatif (YN) Sayısı} \quad (49)$$

$$Özgüllük = \frac{Doğru Negatif (DN) Sayısı}{Doğru Negatif (DN) Sayısı + Yanlış Pozitif (YP) Sayısı} \quad (50)$$


Veri küpü bazlı duyarlılık ise hedef için toplanmış veri küplerinden kaç tanesinde en az bir hedefin doğru bulunduğunu gösteren bir ifadedir. Aynı şekilde, arka plan için toplanmış veri küplerinden kaç tanesinde sadece arka plan etiketi olduğunu gösteren bir ifadedir.

Tablo 4'te görüldüğü gibi her materyal ve örnekte bir yanlış pozitif bulunmaktadır. Bunun yanında, üzerinde herhangi bir madde olmaya arka plan verilerinde de bazı pikseller hedef olarak işaretlenmiştir. Ancak Materyal-4 hariç yanlış negatif sayısının oldukça az olduğu görülmektedir. Tablo 5 incelendiğinde hedef piksellerin yüzde 66'sı doğru bulunmuş, hedef olan 15 küpten ise 12 sinde hedef işaretlenmiştir. Arka plan pikselleri çok fazla olduğu için 4052 yanlış pozitif piksele rağmen piksel bazlı özgüllük yüzde 99'un üzerinde olmaktadır. Ancak, hiç hedef olmayan 5 veri küpünde de hedef piksel bulunmasından dolayı veri küpü bazlı özgüllük 5'te 0 olarak görülmüştür.

Destek Vektör Makineleri için çizilen ROC ve PR eğrileri ise Şekil 31 ve Şekil 32'de görülebilir. İki eğri de ideale oldukça uzaktır.



Şekil 31. Madde-1 Verisi İçin DVM ROC Eğrisi



Şekil 32. Madde-1 Verisi İçin DVM PR Eğrisi


Yapılan analizde Materyal-4'ün diğer materyallerden farklı olduğu bu yüzden de yanlış sınıflandırıldığı görülmüştür. Toplam performansın oldukça düşük olmasının sebebinin Materyal-4 olduğu anlaşılmıştır. Materyal-4 verilerini test verilerinden çıkartığımızda performans sonuçları Tablo 6'da gösterilmiştir.

Tablo 6. Materyal-4 verisi çıkartıldıktan sonra Madde-1 Verisi İçin DVM Performansı


Piksel Bazlı Duyarlılık	0.9919
Piksel Bazlı Özgüllük	0.9835
Veri Küpü Bazlı Duyarlılık	10 / 10
Veri Küpü Bazlı Özgüllük	0 / 5

Tablo 6'da görüldüğü gibi Materyal-4 çıkartıldıktan sonra piksel bazlı duyarlılık önemli ölçüde artarak yüzde 66'dan yüzde 99'un üzerine çıkmıştır. Veri küpü bazlı duyarlılıktan da anlaşılacağı gibi neredeyse bütün hedef pikselleri doğru olarak bulunmuştur. Materyal-4 için bu algoritmanın çalışmadığı kabul edilse bile veri küpü bazlı özgüllük yani arka plan için olan veri küplerinde hedef olmayan pikselleri hedef olarak işaretleme sorunundan dolayı algoritma bu haliyle çok başarılı kabul edilememektedir.

Algoritmaların performans analiz grafikleri Şekil 33 ve Şekil 34'te gösterilmiştir. Özellikle ROC eğrisi ideale çok yakın olarak görülmektedir.




Şekil 33. Materyal-4 Verisi Çıkartıldıktan Sonra Madde-1 Verisi İçin DVM ROC Eğrisi



Şekil 34. Materyal-4 Verisi Çıkartıldıktan Sonra Madde-1 Verisi İçin DVM PR Eğrisi

5.3.2. İmza Tabanlı Sınıflandırma Sonuçları

İmza tabanlı sınıflandırmaların “şablon eşleştirme” olarak da adlandırılmasının sebebi, her bir pikselin belirlenen bir piksele olan benzerliğinin incelenmesidir. Öz nitelik tabanlı sınıflandırmada eğitim verisi olarak ayrılan veri küplerinden iki piksel seçilmiştir. Bir piksel yerine iki piksel seçilmesinin sebebi, daha önce anlatıldığı gibi diferansiyel işlemi sonucunda elde edilen piksel imzasının pozitif yönde ya da negatif yönde olabilmesidir. Seçilmiş olan, Materyal-5 üzerindeki Madde-1 verisi pikselleri Şekil 35’te görülmektedir.



Şekil 35. Hedef Olarak Seçilen Madde-1 Verilerinin İmzaları


5.3.2.1. Uyumlu Filtre Sonuçları

Her pikselin t_1 ve t_2 olarak kabul edilen iki farklı hedef için Uyumlu Filtre puanları, $D_{UF}(x, t_1)$ ve $D_{UF}(x, t_2)$ Bölüm 4’te gösterilen Denklem 41’e göre hesaplanmıştır. Denklem 41’de geçen Σ_b^{-1} ve μ_b terimleri arka plan olarak ayrılan veri küplerinin kovaryans ve ortalama değerlerini göstermektedir. Bulunan iki Uyumlu Filtre puanından herhangi biri eğer eşik değeri olan e ’den ise büyük ise o piksel hedef olarak

adlandırılır. Bu yüzden, Denklem 51'deki eşitsizlik sağlandığında, x pikselinin işareti, l_x hedef olarak işaretlenir.

$$D_{UF}(x) = \max(D_{UF}(x, t_1), D_{UF}(x, t_2)) \geq e \Rightarrow l_x = 1 \quad (51)$$

En iyi eşik değerini bulabilmek için önce bulunan uyumlu filtre puanlarına göre $D_{MF}(x)$ Şekil 36'da görülen ROC eğrisi çizilir.




Şekil 36. Madde-1 İçin Uyumlu Filtre ROC Eğrisi

Şekil 36'da görüldüğü gibi, bu ROC eğrisindeki ideale (DP Oranı=1, YP Oranı=0) en yakın noktaya karşılık genel eşik değeri, seçilebilecek en iyi eşik değeri olarak görülür. Ancak, farklı uygulamalarda DP Oranının ya da YP Oranının önemi diğer orana göre daha fazla olabileceğinden, en iyi eşik değeri uygulamaya göre farklılık göstermektedir.

Bu uygulamada ROC eğrisinden bulunan en iyi eşik değeri yerine PR eğrisinden bulunan en iyi eşik değeri kullanılmıştır. Bunun esas sebebi, bu uygulamada arka plan verilerinin hedef verilerinden oldukça fazla olmasıdır. En iyi eşik değeri bulunurken ROC kullanıldığında, arka plan verileri çok fazla olduğu için arka plan için yapılan hataların hedef için yapılan hatalara göre daha fazla olması tercih edilmiş olur. Bu sayede doğru


pozitif oranı da artar, ancak hassasiyet yani hedef olarak işaretlenen pikseller arasında doğru olanlarının oranı oldukça düşmüş olur. Hassasiyet, bu tez kapsamında incelenen uygulamada önemli kabul edildiği için en iyi eşik değeri PR eğrisinden bulunur.

PR eğrisinden en iyi eşik değeri bulmak için, önce PR eğrisinin ideale (Kesinlik=1, Hassasiyet=1) en yakın noktası bulunur. Bu noktaya karşılık gelen eşik değeri en iyi eşik değeri olarak kabul edilir. Bu uygulamada kullanılan eşik değeri Şekil 37’de görülen eşik değeridir.




Şekil 37. Madde-1 İçin Uyumlu Filtre PR Eğrisi


Şekil 38, Şekil 39, Şekil 40, Şekil 41, Şekil 42 ve Şekil 43’te uyumlu filtrenin, sırasıyla Materyal-1, Materyal-2, Materyal-3, Materyal-4 ve Materyal-5 üzerindeki Madde-1 ve arka plan verilerindeki sonuçları gösterilmiştir.




Şekil 38a. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları




Şekil 38b. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları




Şekil 38c. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları




Şekil 38ç. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları




Şekil 38d. Materyal-1 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları




Şekil 39a. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları



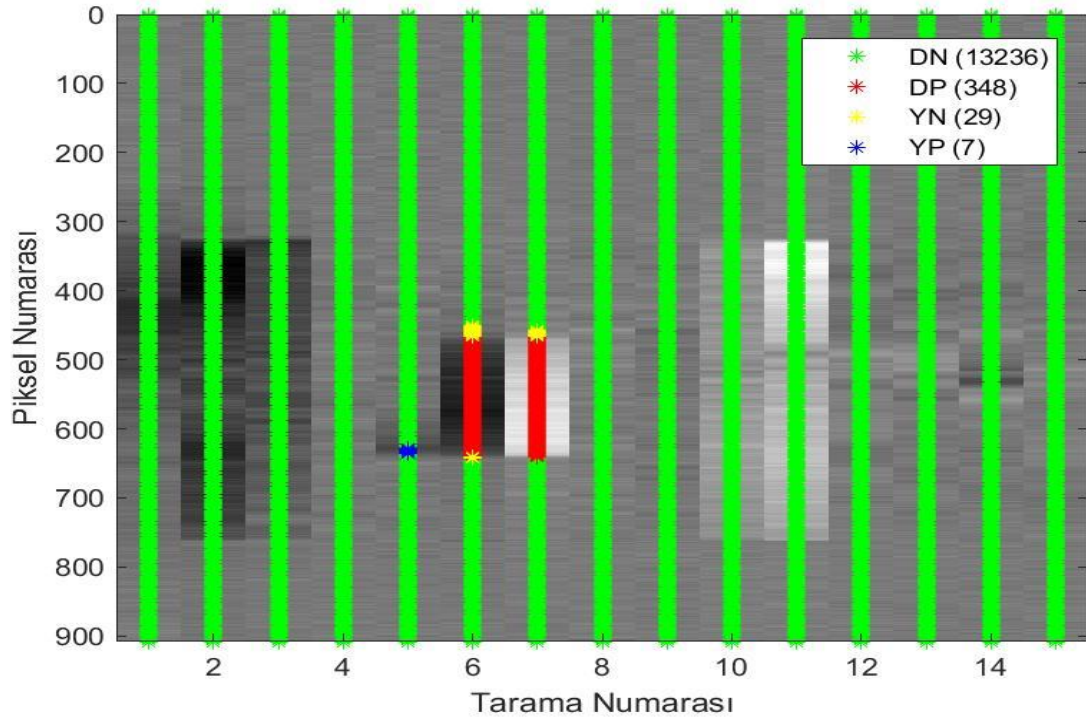
Şekil 39b. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları




Şekil 39c. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları




Şekil 39ç. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları




Şekil 39d. Materyal-2 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları




Şekil 40a. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları




Şekil 40b. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları




Şekil 40c. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları




Şekil 40ç. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları




Şekil 40d. Materyal-3 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları




Şekil 41a. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları




Şekil 41b. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları




Şekil 41c. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları




Şekil 41ç. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları




Şekil 41d. Materyal-4 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları




Şekil 42a. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-1) İçin UF Sonuçları




Şekil 42b. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-2) İçin UF Sonuçları




Şekil 42c. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-3) İçin UF Sonuçları




Şekil 42ç. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-4) İçin UF Sonuçları




Şekil 42d. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-5) İçin UF Sonuçları




Şekil 43a. Arka Plan Verileri (Örnek-1) İçin UF Sonuçları




Şekil 43b. Arka Plan Verileri (Örnek-2) İçin UF Sonuçları



Şekil 43c. Arka Plan Verileri (Örnek-3) İçin UF Sonuçları



Şekil 43ç. Arka Plan Verileri (Örnek-4) İçin UF Sonuçları



Şekil 43d. Arka Plan Verileri (Örnek-5) İçin UF Sonuçları

Tablo 7’de Madde-1 verisi üzerindeki Uyumlu Filtre algoritmasının sonuçları Tablo 8’de ise Madde-1 verisi üzerindeki Uyumlu Filtre algoritmasının performansı gösterilmektedir.

Tablo 7. Madde-1 Verisi İçin UF Sonuçları

		DN	DP	YN	YP	TOPLAM
Materyal-1	Örnek-1	13265	347	8	0	13620
	Örnek-2	13155	238	227	0	13620
	Örnek-3	13145	140	335	0	13620
	Örnek-4	13259	346	15	0	13620
	Örnek-5	13211	234	169	6	13620
TOPLAM		66035	1305	754	6	68100
Materyal-2	Örnek-1	13226	350	44	0	13620
	Örnek-2	13172	341	107	0	13620
	Örnek-3	13228	347	11	34	13620
	Örnek-4	13119	450	51	0	13620
	Örnek-5	13236	348	29	7	13620
TOPLAM		65981	1836	242	41	68100
Materyal-3	Örnek-1	13237	366	7	10	13620
	Örnek-2	13081	510	29	0	13620
	Örnek-3	13122	362	136	0	13620
	Örnek-4	13171	368	72	9	13620
	Örnek-5	13180	363	59	18	13620
TOPLAM		65791	1969	303	37	68100
Materyal-4	Örnek-1	12685	194	321	420	13620
	Örnek-2	12889	339	92	300	13620
	Örnek-3	13090	178	250	102	13620
	Örnek-4	12993	154	222	251	13620
	Örnek-5	12997	316	232	75	13620
TOPLAM		64654	1181	1117	1148	68100
Materyal-5	Örnek-1	13191	319	27	83	13620
	Örnek-2	13242	365	12	1	13620
	Örnek-3	13079	361	1	179	13620
	Örnek-4	13220	289	17	94	13620
	Örnek-5	13176	347	16	81	13620
TOPLAM		65908	1681	73	438	68100
Arka Plan	Örnek-1	13596	0	0	24	13620
	Örnek-2	6356	0	0	0	6356
	Örnek-3	6346	0	0	10	6356
	Örnek-4	6356	0	0	0	6356
	Örnek-5	6108	0	0	248	6356
TOPLAM		38762	0	0	282	39044
GENEL TOPLAM		367131	7972	2489	1952	379544

Tablo 8. Madde-1 Verisi İçin UF Performansı

Piksel Bazlı Duyarlılık	0.7621
Piksel Bazlı Özgüllük	0.9947
Veri Küpü Bazlı Duyarlılık	25 / 25
Veri Küpü Bazlı Özgüllük	2 / 5

Tablo 7 ve Tablo 8’de görüldüğü gibi Uyumlu Filtre sonuçları genel olarak Destek Vektör Makineleri algoritmasının sonuçlarından daha iyi çıkmıştır. Özellikle Destek Vektör Makineleri’nin Materyal-4 üzerindeki kötü performansından dolayı Uyumlu Filtre’nin piksel bazlı duyarlılığı daha iyi olmaktadır. Ancak, Tablo 7 incelendiğinde her ne kadar Uyumlu Filtre’nin Materyal-4 için doğru pozitif sayısı yüksek çıksa da yanlış negatif sayısı da fazladır. Bütün hedef veri küplerinin hepsinde hedef tespit ederek veri küpü bazlı duyarlılıkta başarılı bir sınıflandırma gerçekleştirdiği görülmektedir.


Uyumlu Filtre için genel olarak yanlış pozitif piksellerin Destek Vektör Makinelerine göre daha az olduğu görülmektedir. Bu sebeple de veri küpü bazlı özgüllükte 5 veri küpünden 2 doğrusu bulunmaktadır. Ancak, içerisinde hedef bulunan arka plan veri küpleri sınıflandırma işlemi için sorun oluşturmaktadır.

5.3.2.2. Spektral Açık Eşleyici Sonuçları

Uyumlu Filtre algoritmasında hedef olarak kullanılan imzalar, bu algorithmada da aynı şekilde hedef olarak kullanılmıştır. Bölüm 4’te anlatıldığı gibi bu algorithmada arka plan karakterizasyonuna ihtiyaç duyulmamaktadır. Bu yüzden bütün arka plan verileri test sınıfına ayrılmıştır. Bu algorithmada da Uyumlu Filtre’de olduğu gibi, her pikselin iki farklı hedef imzası için iki farklı $D_{SAE}(x, t_1)$ ve $D_{SAE}(x, t_2)$ değeri bulunmaktadır. Yine Uyumlu Filtre’de olduğu gibi bulunan bu değerler arasından büyük olanı Spektral Açık Eşleyici Algoritmasının puanı olarak kabul edilir ve belirlenen eşik değerinden büyükse ilgili piksel hedef olarak işaretlenir. Bu işlemin denklemi Denklem 52’de görülebilir.


$$D_{SAE}(x) = \max(D_{SAE}(x, t_1), D_{SAE}(x, t_2)) \geq e \Rightarrow l_x = 1 \quad (52)$$

Seçilen hedef imzalara göre bulunan Spektral Açık Eşleyici puanları için çizilen PR eğrisi ve seçilebilecek en iyi eşik değeri Şekil 44’te görülmektedir.




Şekil 44. Madde-1 için Spektral Açık Eşleyici PR Eğrisi


Özellikle hassasiyette oldukça kötü performans sergileyen Spektral Açık Eşleyici için eşik değeri Şekil 44'te görüldüğü gibi seçilmiştir. Bu eşik değeri ile yapılan sınıflandırma sonucunda Spektral Açık Eşleyici Materyal-1, Materyal-2, Materyal-3 ve Materyal 4 üzerinde hiç Madde-1 verisi tespit edememiştir. Bu sebeple bu materyaller üzerindeki sınıflandırma sonuçlarının gösterilmesine ihtiyaç duyulmamıştır. Materyal-5 üzerindeki Madde-1 verisi için yapılan sınıflandırma sonuçları Şekil 45'te gösterilmiştir.




Şekil 45a. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-1) İçin SAE Sonuçları




Şekil 45b. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-2) İçin SAE Sonuçları



Şekil 45c. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-3) İçin SAE Sonuçları




Şekil 45ç. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-4) İçin SAE Sonuçları



Şekil 45d. Materyal-5 Üzerindeki Madde-1 Verisi (Örnek-5) İçin SAE Sonuçları

Diğer materyallerde iyi sonuç vermemesine rağmen Şekil 45'te görüldüğü gibi Materyal-5 üzerindeki Madde-1 verisinde oldukça iyi sonuç vermiştir. Bunun sebebi, hedef olarak seçilen pikselin Materyal-5 üzerindeki Madde-1 verisi içerisinde olmasıdır. Ayrıca, Spektral Açık Eşleyici algoritması arka plan verileri içerisinde de herhangi bir hata yapmamış yani herhangi bir pikseli Madde-1 verisi olarak işaretlememiştir. Bu sebepten dolayı arka plan verilerinin sınıflandırma sonuçlarının gösterilmesine ihtiyaç duyulmamıştır.

Spektral Açık Eşleyicinin ROC eğrisi Şekil 46'da, sınıflandırma sonuçları Tablo 9'da ve sınıflandırma performansı Tablo 10'da görülmektedir.



Şekil 46 Madde-1 için Spektral Açık Eşleyici ROC Eğrisi

Tablo 9. Madde-1 Verisi İçin SAE Sonuçları

		DN	DP	YN	YP	TOPLAM
Materyal-1	Örnek-1	13265	0	355	0	13620
	Örnek-2	13155	0	465	0	13620
	Örnek-3	13145	0	475	0	13620
	Örnek-4	13259	0	361	0	13620
	Örnek-5	13217	0	403	0	13620
TOPLAM		66041	0	2059	0	68100
Materyal-2	Örnek-1	13226	0	394	0	13620
	Örnek-2	13172	0	448	0	13620
	Örnek-3	13262	0	358	0	13620
	Örnek-4	13119	0	501	0	13620
	Örnek-5	13243	0	377	0	13620
TOPLAM		66022	0	2078	0	68100
Materyal-3	Örnek-1	13247	0	373	0	13620
	Örnek-2	13081	0	539	0	13620
	Örnek-3	13122	0	498	0	13620
	Örnek-4	13180	0	440	0	13620
	Örnek-5	13198	0	422	0	13620
TOPLAM		65828	0	2272	0	68100
Materyal-4	Örnek-1	13105	0	515	0	13620
	Örnek-2	13189	0	431	0	13620
	Örnek-3	13192	0	428	0	13620
	Örnek-4	13244	0	376	0	13620
	Örnek-5	13072	0	548	0	13620
TOPLAM		65802	0	2298	0	68100
Materyal-5	Örnek-1	13273	326	20	1	13620
	Örnek-2	13243	363	14	0	13620
	Örnek-3	13256	359	3	2	13620
	Örnek-4	13280	296	10	34	13620
	Örnek-5	13200	351	12	57	13620
TOPLAM		66252	1695	59	94	68100
Arka Plan	Örnek-1	13620	0	0	0	13620
	Örnek-2	6356	0	0	0	6356
	Örnek-3	6356	0	0	0	6356
	Örnek-4	6356	0	0	0	6356
	Örnek-5	6356	0	0	0	6356
	Örnek-6	17252	0	0	0	17252
	Örnek-7	17252	0	0	0	17252
	Örnek-8	17252	0	0	0	17252
	Örnek-9	17252	0	0	0	17252
	Örnek-10	17252	0	0	0	17252
	Örnek-11	17252	0	0	0	17252
	Örnek-12	17252	0	0	0	17252
	Örnek-13	17252	0	0	0	17252
	Örnek-14	17252	0	0	0	17252
	Örnek-15	17252	0	0	0	17252
TOPLAM		211564	0	0	0	211564
GENEL TOPLAM		541509	1695	8766	94	552064


Tablo 10. Madde-1 Verisi İçin SAE Performansı

Piksel Bazlı Duyarlılık	0.1620
Piksel Bazlı Özgüllük	0.9998
Veri Küpü Bazlı Duyarlılık	5 / 25
Veri Küpü Bazlı Özgüllük	15 / 15


Tablo 9 ve Tablo 10'da görüldüğü gibi Spektral Açı Eşleyici Materyal-5 veri küpündeki pikseller hariç herhangi bir pikseli hedef olarak sınıflandırmamıştır. Her piksel arka plan olarak işaretlendiğinden dolayı piksel bazlı özgüllük ideale çok yakın çıkmış ve her arka plan veri küpü doğru sınıflandırılmıştır. Ancak, bu şekilde duyarlılıkta oldukça başarısız olduğu görülmektedir.

5.4. Sınıflandırma Sonuçlarının İncelenmesi

Bu tez kapsamında sınıflandırma için üç farklı algoritma incelenmiştir. Bu üç algoritmanın da test verileri üzerindeki performans grafikleri Şekil 47 ve Şekil 48'de görülmektedir.




Şekil 47. Tüm Verilerde DVM, UF ve SAE İçin ROC Eğrilerinin Karşılaştırılması




Şekil 48. Tüm Verilerde DVM, UF ve SAE İçin PR Eğrilerinin Karşılaştırılması


Bütün algoritmalar için problemleri olarak görülen Materyal-4 verisi test verilerinden çıkartıldığında oluşan performans grafikleri sonuç Şekil 49 ve Şekil 50'de görülmektedir. Ayrıca, daha iyi karşılaştırma için yakınlaştırılmış ROC eğrisi grafiği Şekil 51'de gösterilmiştir.



Şekil 49. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için ROC Eğrilerinin Karşılaştırılması



Şekil 50. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için PR Eğrilerinin Karşılaştırılması



Şekil 51. Materyal-4 Haricindeki Verilerde DVM, UF ve SAE için ROC Eğrilerinin Karşılaştırılması (Yakınlaştırılmış)

Bu sonuçlara göre en kötü performansı Spektral Açık Eşleyici algoritmasının verdiği söylenebilir. Ancak, Spektral Açık Eşleyicinin eğitim amaçlı kullanılan piksellerin alındığı veri kümesindeki başarı oranının kötü olmadığı gözükmemektedir. Bu sebeple, Spektral Açık Eşleyicinin özellikle arka plan karakterizasyonunu dikkate almamasından kaynaklı olarak verilerin çeşitlenmesi ile performansın dramatik bir şekilde düştüğü, arka plan ile hedef verilerinin ayrımını yapamadığı söylenebilir. Spektral Açık Eşleyicinin bu uygulama için kullanılması, test edilecek bütün veri kümelerinin bilinmesi ve bu veri kümelerinden örnekler alınarak eğitim verilerine konması ile mümkün olabilir. Ancak, arka plan verilerinin çok çeşitli olma ihtimali varsa bu algoritmanın kullanılması makul değildir.

Tüm veriler incelendiğinde, Uyumlu Filtrenin, diğer algoritmalara kıyasla ideale en yakın sınıflandırma algoritması olduğu görülmektedir. Sadece eğitim pikselinin bulunduğu veri kümesinde değil bütün veri çeşitlerinde oldukça iyi sınıflandırma sonuçları gerçekleştirmiştir. Ancak, bu algorithmada spektral imza bütün olarak ele alındığı için, gelen bir pikselin sınıflandırılması Destek Vektör Makinelere göre daha fazla vakit almaktadır.

Destek Vektör Makinelerinin eğitim süresi çok uzun olmasına rağmen bir verinin testi için geçen süre diğer iki imza tabanlı sınıflandırıcılara göre daha kısadır.

Destek Vektör Makineleri diğer veri kümelerinde iyi olmasına rağmen Materyal-4 için toplanan veri kümesinde kötü sonuçlar vermektedir. Bunun başlıca sebebi Materyal-4 üzerindeki Madde-1 imzasının diğerlerine göre biraz daha farklı olması ve bu farklılığın Destek Vektör Makineleri tarafından fark edilip elenmiş olmasıdır. Bu durum, Madde-1 veri grubu için Destek Vektör Makinelerinin genelleştirme başarısının Uyumlu Filtreye göre daha düşük olduğu anlamına gelmektedir. Materyal-4 test verilerinden çıkartıldığında ise Destek Vektör Makineleri ile Uyumlu Filtrenin birbirine yakın sonuçlar verdiği görülmektedir.

Arka plan verileri incelendiğinde, Destek Vektör Makineleri ve Uyumlu Filtre algoritması tarafından yanlış sınıflandırılan piksellerin olduğu görülmektedir. Diğer veri küplerinde olan yanlış pozitif piksellerin sebebi Madde-1 verisinin pikselden taşması ya da kesin referansın eksik işaretlenmesi olabilir. Ancak, arka plan verilerinde arka plan materyallerinden başka hiçbir maddenin olmadığı kesindir ve bu verilerin yanlış sınıflandırılması kesinlikle olmaması gereken bir durumdur. Bu sebeple, bu hatalı sınıflandırmaları gidermek için son işleme algoritmalarına ihtiyaç duyulmuştur.


5.5. Son İşleme İçin Deneysel Sonuçlar

5.5.1. Eğim Eşikleme


Eğim Eşikleme algoritması bir son işleme algoritması olarak kullanıldığı için, sadece sınıflandırıcılar tarafından hedef olarak işaretlenen pikseller üzerinde uygulanmıştır. Bölüm 4'te anlatıldığı gibi Eğim Eşikleme algoritmasını veriye uygulayabilmek için bir dalga boyu aralığının, $[x_{n_L}, x_{n_U}]$, olarak belirlenmesi gerekmektedir. Şekil 23'te de görüldüğü gibi Madde-1 imzaları yaklaşık olarak benzer dalga boylarında artış göstermiştir. Bu dalga boyu aralığını belirlemek için sadece Şekil 23'teki hedef imzaları ile kalmayıp hedef olduğu bilinen bütün Madde-1 verileri incelenmiş ve [300nm - 325nm] aralığının bu madde için en iyi dalga boyu aralığı olduğuna karar verilmiştir.

Bölüm 4'te anlatıldığı gibi, belirlenen dalga boyu aralığı, $[x_{n_L}, x_{n_U}]$, ile verilerin bu dalga boyu aralığındaki değerleri, $[y_{n_L}, y_{n_U}]$, kullanılarak bu pikselin eğimi, m , bulunmuştur. Şekil


23'te gösterilen imzalar, bu imzalara oturtulan en iyi doğru ve bu doğrunun eğimi Şekil 52'de gösterilmiştir.




Şekil 52a. Materyal-1 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi




Şekil 52b. Materyal-2 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi



Şekil 52c. Materyal-3 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi



Şekil 52ç. Materyal-4 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi




Şekil 52d. Materyal-5 Üzerindeki Madde-1 Verisine Oturtulan Doğru ve Eğimi


Hedef olarak işaretlenen bütün piksellerin ilgili aralıktaki eğimi bulunduğundan sonra belirlenen eşik değerinden büyük eğime sahip pikseller hedef olarak bırakılırken daha küçük eğime sahip piksellerin hedef işareti silinecektir. Bunun için, önce eşik değerinin belirlenmesi gerekmektedir. Arka plan verilerinde yanlış pozitif değerinin olmaması beklendiği için bu eşik değeri arka plan piksellerinin ilgili aralıktaki eğiminden yüksek olacak şekilde belirlenmiştir. Böylelikle bütün arka plan verilerinin hatasız olması sağlanmıştır. Ancak, bu şekilde arka plan imzalarına yakın imzalara sahip bazı hedef verileri de elenmiş olur. Örneğin, Şekil 52’de görülen Materyal-1 üzerindeki Madde-1 verisinin eğimi belirlenen eşik değerinden düşük kalmış ve elenmiştir.

Destek Vektör Makineleri ile yapılan sınıflandırma sonuçlarının eğitim eşikleme sonrasındaki görüntüsü Şekil 53, Şekil 54, Şekil 55, Şekil 56 ve Şekil 57’de gösterilmiştir. Şekil 53, Şekil 54, Şekil 55, Şekil 56 ve Şekil 57’de gösterilen görüntüler sırasıyla Materyal-1, Materyal-2 (eğitim verisi), Materyal-3, Materyal-4 ve Materyal-5 (eğitim verisi) üzerindeki Madde 1 verilerinin görüntüleridir. Aynı şekilde, Şekil 58, Şekil 59, Şekil 60, Şekil 61 ve Şekil 62 sırasıyla Materyal-1, Materyal-2, Materyal-3, Materyal-4 ve Materyal-5 üzerindeki Madde-1 verilerinin Uyumlu Filtre ile sınıflandırılması sonrası eğitim eşikleme sonuçlarını göstermektedir. Spektral Açık Eşleyici algoritması sonucunda ve diğer algoritmalarının arka plan verilerinde herhangi bir yanlış pozitif olmamasından dolayı, eğitim eşikleme sonuçlarının incelenmesine gerek duyulmamıştır.


Gösterilen şekillerdeki sonuçların tabloda görülebilmesi için Tablo 11 düzenlenmiştir. Tablo 4 ve Tablo 7’de gösterilen sonuçlara göre daha az hedef pikseli bulunduğu yani hedef olarak bulunan bazı piksellerin elendiği Tablo 11’de görülebilir. Tablo 12’de ise bu algoritmaların performansı gösterilmiştir. Son işleme öncesi ve sonrası arasındaki performans farkı daha sonraki bölümde incelenecektir.




Şekil 53a. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-1)




Şekil 53b. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-2)




Şekil 53c. Eğim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-3)




Şekil 53ç. Eğim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-4)




Şekil 53d. Eğitim Eşikleme Sonrası Materyal-1 İçin DVM Sonuçları (Örnek-5)




Şekil 54a. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-1)




Şekil 54b. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-2)




Şekil 54c. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-3)



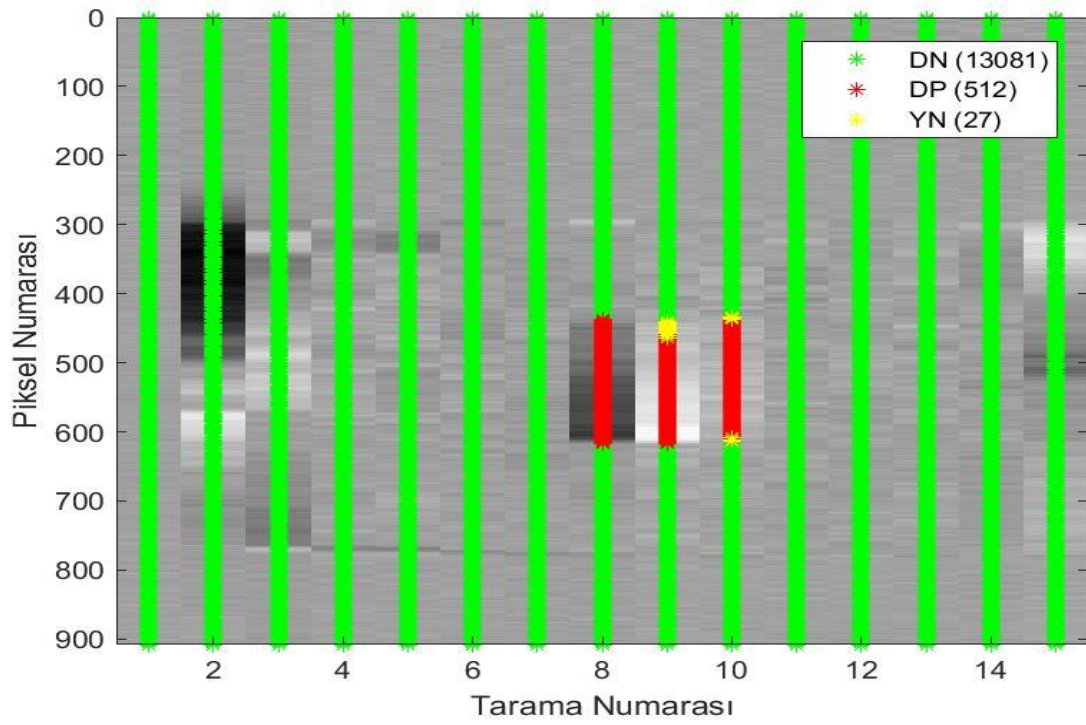
Şekil 54ç. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-4)




Şekil 54d. Eğitim Eşikleme Sonrası Materyal-2 İçin DVM Sonuçları (Örnek-5)




Şekil 55a. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-1)




Şekil 55b. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-2)




Şekil 55c. Eğim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-3)




Şekil 55ç. Eğim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-4)




Şekil 55d. Eğitim Eşikleme Sonrası Materyal-3 İçin DVM Sonuçları (Örnek-5)




Şekil 56a. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-1)




Şekil 56b. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-2)




Şekil 56c. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-3)




Şekil 56ç. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-4)




Şekil 56d. Eğitim Eşikleme Sonrası Materyal-4 İçin DVM Sonuçları (Örnek-5)



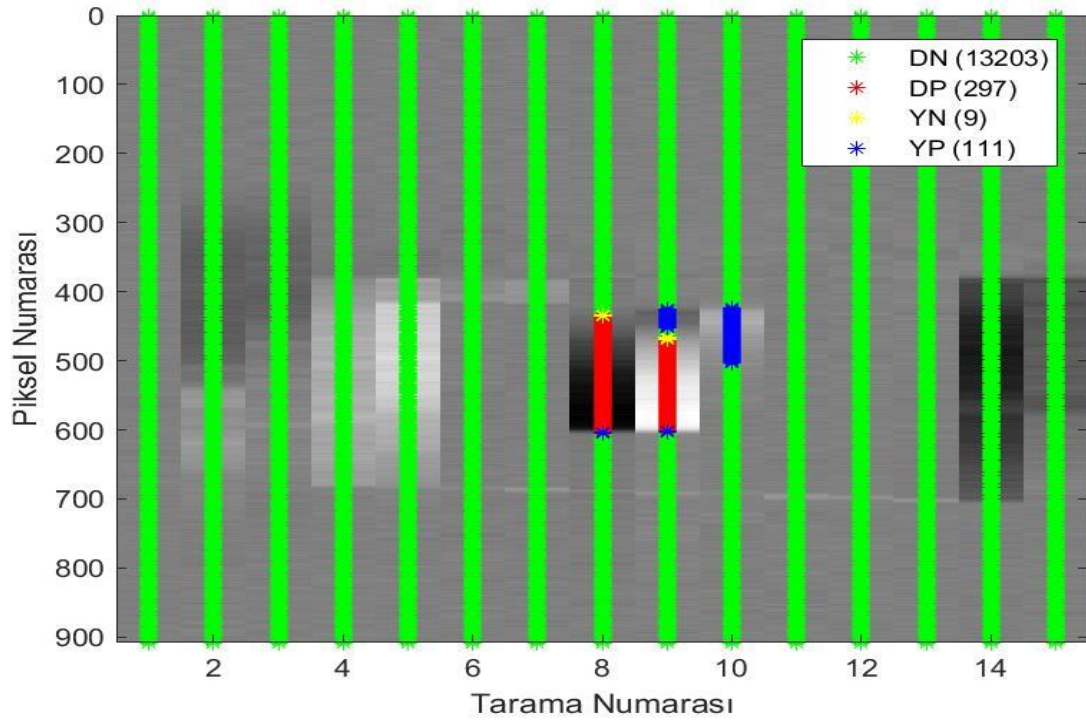
Şekil 57a. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-1)




Şekil 57b. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-2)




Şekil 57c. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-3)




Şekil 57ç. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-4)




Şekil 57d. Eğitim Eşikleme Sonrası Materyal-5 İçin DVM Sonuçları (Örnek-5)




Şekil 58a. Eğitim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-1)




Şekil 58b. Eğim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-2)




Şekil 58c. Eğim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-3)




Şekil 58ç. Eğim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-4)




Şekil 58d. Eğim Eşikleme Sonrası Materyal-1 İçin UF Sonuçları (Örnek-5)




Şekil 59a. Eğim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-1)




Şekil 59b. Eğim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-2)




Şekil 59c. Eğim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-3)




Şekil 59ç. Eğim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-4)




Şekil 59d. Eğim Eşikleme Sonrası Materyal-2 İçin UF Sonuçları (Örnek-5)




Şekil 60a. Eğim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-1)




Şekil 60b. Eğim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-2)




Şekil 60c. Eğim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-3)




Şekil 60ç. Eğim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-4)




Şekil 60d. Eğim Eşikleme Sonrası Materyal-3 İçin UF Sonuçları (Örnek-5)




Şekil 61a. Eğim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-1)




Şekil 61b. Eğim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-2)




Şekil 61c. Eğim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-3)




Şekil 61ç. Eğim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-4)




Şekil 61d. Eğim Eşikleme Sonrası Materyal-4 İçin UF Sonuçları (Örnek-5)




Şekil 62a. Eğim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-1)




Şekil 62b. Eğim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-2)



Şekil 62c. Eğim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-3)



Şekil 62ç. Eğim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-4)



Şekil 62d. Eğim Eşikleme Sonrası Materyal-5 İçin UF Sonuçları (Örnek-5)

Tablo 11. Eğitim Eşikleme Sonrası DVM ve UF Sonuçları

		Destek Vektör Makineleri				Uyumlu Filtre			
		DN	DP	YN	YP	DN	DP	YN	YP
Materyal-1	Örnek-1	13265	350	5	0	13265	347	8	0
	Örnek-2	13155	259	206	0	13155	225	240	0
	Örnek-3	13145	182	293	0	13145	136	339	0
	Örnek-4	13259	353	8	0	13259	346	15	0
	Örnek-5	13213	252	151	4	13213	217	186	4
TOPLAM		66037	1396	663	4	66037	1271	788	4
Materyal-2	Örnek-1	13226	367	27	0	13226	350	44	0
	Örnek-2	13172	397	51	0	13172	341	107	0
	Örnek-3	13204	350	8	58	13228	347	11	34
	Örnek-4	13119	462	39	0	13119	445	56	0
	Örnek-5	13207	352	25	36	13236	348	29	7
TOPLAM		65928	1928	150	94	65981	1831	247	41
Materyal-3	Örnek-1	13247	367	6	0	13247	366	7	0
	Örnek-2	13081	512	27	0	13081	506	33	0
	Örnek-3	13122	363	135	0	13122	362	136	0
	Örnek-4	13177	425	15	3	13180	368	72	0
	Örnek-5	13197	382	40	1	13198	363	59	0
TOPLAM		65824	2049	223	4	65828	1965	307	0
Materyal-4	Örnek-1	13091	0	515	14	13067	184	331	38
	Örnek-2	13189	0	531	0	13189	332	99	0
	Örnek-3	13192	8	420	0	13114	164	264	78
	Örnek-4	13243	0	376	1	13028	154	222	216
	Örnek-5	13072	58	490	0	13023	315	233	49
TOPLAM		65787	66	2332	15	65421	1149	1149	381
Materyal-5	Örnek-1	13166	331	15	108	13191	319	27	83
	Örnek-2	13243	370	7	0	13242	365	12	1
	Örnek-3	13073	361	1	185	13079	361	1	179
	Örnek-4	13203	297	9	111	13220	288	18	94
	Örnek-5	13169	359	4	88	13189	347	16	68
TOPLAM		65854	1718	36	492	65921	1680	74	425
Arka Plan	Örnek-1	13620	0	0	0	13620	0	0	0
	Örnek-2	6356	0	0	0	6356	0	0	0
	Örnek-3	6356	0	0	0	6356	0	0	0
	Örnek-4	6356	0	0	0	6356	0	0	0
	Örnek-5	6356	0	0	0	6356	0	0	0
	Örnek-6	17252	0	0	0	17252	0	0	0
	Örnek-7	17252	0	0	0	17252	0	0	0
	Örnek-8	17252	0	0	0	17252	0	0	0
	Örnek-9	17252	0	0	0	17252	0	0	0
	Örnek-10	17252	0	0	0	17252	0	0	0
	Örnek-11	17252	0	0	0	17252	0	0	0
	Örnek-12	17252	0	0	0	17252	0	0	0
	Örnek-13	17252	0	0	0	17252	0	0	0
	Örnek-14	17252	0	0	0	17252	0	0	0
	Örnek-15	17252	0	0	0	17252	0	0	0
TOPLAM		211564	0	0	0	211564	0	0	0
GENEL TOPLAM		368474	7157	3404	609	368232	7896	2565	851

Tablo 12. Eğitim Eşikleme Sonrası DVM ve UF Performansları

	Destek Vektör Makineleri	Uyumlu Filtre
Piksel Bazlı Duyarlılık	0.6842	0.7548
Piksel Bazlı Özgüllük	0.9989	0.9984
Veri Küpü Bazlı Duyarlılık	22 / 25	25 / 25
Veri Küpü Bazlı Özgüllük	15 / 15	15 / 15

Tablo 11 ve Tablo 12’de görüldüğü gibi eğim eşikleme sonrasında özellikle veri küpü bazlı duyarlılık ve özgüllükte iki algoritmanın da başarısı oldukça iyidir. Bütün materyaller ve bu materyallerin örnekleri için yanlış pozitif sayısı azalmıştır. Bu sebeple de piksel bazlı özgüllük ideale oldukça yaklaşmıştır. Özellikle bütün arka plan veri küplerinde doğru sonuç vermesi algoritmaların başarısının arttığını göstermektedir.

Piksel bazlı duyarlılık Destek Vektör Makineleri için yüzde 68 iken Uyumlu Filtre için bu oran yüzde 75’tedir. Yani Destek Vektör Makineleri toplam hedef piksellerinin yüzde 68’ini doğru bulabilmişken Uyumlu Filtre yüzde 75’ini doğru bulabilmiştir.

Materyal-4 iki algoritma için de sorun teşkil ediyorken, Destek Vektör Makineleri için bu sorun daha belirgin gözükmemektedir. Bu materyal için Destek Vektör Makineleri bazı örneklerde hiç doğru hedef bulamamıştır. Materyal-4 olmasaydı iki algoritma birbirine yakın sonuç vermişti denebilirdi, ancak sonuçlar Materyal-4 ile incelendiğinde Uyumlu Filtre’nin daha iyi sonuç verdiği görülmektedir.

5.5.2. Piksel Kaldırma

Çok nadir de olsa, sınıflandırma ve son işleme süreçlerinden elenmeyen piksellerin olabileceği değerlendirilmektedir. Bu son algoritma sayesinde veri analizi bilgisayarı, n tane pikseli hatalı sınıflandırılmış bir arka plan veri küpü için alarm vermeyecektir. Bu uygulama için n sayısı 2 olarak belirlenmiştir. Yani eğer veri küpünde tek bir piksel hedef olarak sınıflandırılmış ise o veri küpü tamamen arka plan sayılacaktır. Bu veri grubunda bu algoritmaya uyan bir veri küpü bulunmamaktadır.

5.6. Son İşleme Sonuçlarının İncelenmesi

Son işleme süreci, iki sınıflandırma algoritması için de yanlış pozitif piksellerin sayısını azaltmıştır. Ancak, bunu yaparken bazı hedef pikselleri elediği için yanlış negatif piksellerin sayısı artmıştır. Benzer olarak duyarlılık ve özgüllük değerleri de değişmiştir. Destek Vektör Makineleri ve Uyumlu Filtre için bu değerler

Tablo 13’te görülebilir.

Tablo 13. Son İşlemenin DVM ve UF Sonuçlarına Etkisi


	Destek Vektör Makineleri		Uyumlu Filtre	
	Son İşleme Öncesi	Son İşleme Sonrası	Son İşleme Öncesi	Son İşleme Sonrası
Toplam DN	535804	540994	539651	540752
Toplam DP	8209	7157	7972	7896
Toplam YN	2252	3304	2489	2565
Toplam YP	5799	609	1952	851
Piksel Bazlı Duyarlılık	0.7847	0.6842	0.7621	0.7548
Piksel Bazlı Özgüllük	0.9893	0.9989	0.9964	0.9984
Veri Küpü Bazlı Duyarlılık	22 / 25	22 / 25	25 / 25	25 / 25
Veri Küpü Bazlı Özgüllük	0 / 15	15 / 15	12 / 15	15 / 15

Tablo 13'te görüldüğü gibi, son işleme sayesinde iki algoritma için de yanlış negatif sayısındaki az bir artışa rağmen yanlış pozitif sayısı önemli ölçüde düştüğü için, son işlemenin, algoritmaların performansını arttırdığı söylenebilir. Aynı şekilde, duyarlılık son işleme ile düşerken özgüllük artmıştır. Ancak, nesne incelemesi özellikle veri küpü bazında olduğu için son işleme ile iki algoritmanın da performansının önemli ölçüde arttığı görülmektedir.

Tablo 13'te görüldüğü gibi Uyumlu filtre ile Destek Vektör Makineleri performansları birbirine yakın olsa da Uyumlu Filtre algoritması son işleme ile birlikte özellikle duyarlılıkta Destek Vektör Makineleri algoritmasından daha iyi sonuç vermiştir.


Ön işleme, sınıflandırma ve son işleme işlemlerinin sonucunda özellikle yanlış pozitif sayısının çok az olması beklenmektedir. Ancak, iki sınıflandırma algoritması için de

Tablo 13'te görülen toplam yanlış pozitif sayısının yeterince az olmadığı olduğu düşünülmektedir. Bunun sebebi incelendiğinde iki farklı tipte yanlış pozitif piksellerin olduğu görülmektedir. Bu iki tip yanlış pozitif piksellerin birer örnekleri Materyal-5 Örnek-5 üzerinde işaretlenmiş ve işaretlenen piksellerin yerleri Şekil 63'te gösterilmiştir.



Şekil 63. İki Farklı Tipteki Yanlış Pozitif Piksellerinin Materyal-5 (Örnek-5) Verisi Üzerindeki Konumları


Şekil 63'te görülen iki farklı yanlış pozitifin dalga boyuna göre filtrelenmiş diferansiyel yansıması Şekil 64'te görülebilir.




Şekil 64. İki Farklı Tipteki Yanlış Pozitif Piksellerinin Filtrelenmiş Diferansiyel Yansımaları

Şekil 64'te görüldüğü gibi 1. tipteki yanlış pozitif piksellerinin imzaları Madde-1 pikseli imzalarına benzemektedir. Bunun sebebi, Şekil 63'te açıkça görüldüğü gibi Madde-1'in işaretlenen bölgenin dışına taşması ve bunun diferansiyel spektrometre tarafından görülmesidir. Yani aslında yanlış pozitif olduğu düşünülen bu pikseller kesin referans olarak işaretlenmemiş ancak doğru bir şekilde tespit edilen Madde-1 pikselleridir. 2. Tip yanlış pozitif piksellerin diferansiyel yansıması, arka plan piksellerinin yansımalarına göre hedef piksellerin yansımalarına daha çok benzediği için hedef olarak işaretlenmiştir. Hedef pikseli olmadığı için bu pikseller gerçek yanlış pozitif pikselleridir. Tip-1 piksellerinin aslında doğru tespit olması ve Tip-2 yanlış pozitif sayısının çok az olmasından dolayı algoritmalar beklendiği gibi düşük yanlış pozitif ile çalıştığı görülmektedir.

Verilerdeki yanlış negatif pikselleri incelendiğinde materyal üzerindeki Madde-1'in uç kısmında olduğu görülmektedir. Bunun sebebi, maddeler arka plan materyallerinin üzerine Bölüm 3'te anlatıldığı gibi üçgen biçiminde yerleştirilmiştir. Bu yüzden, özellikle üçgenin uç kısmında yer alan az miktardaki madde bazı arka plan materyalleri için tespit edilememiştir. Bu, aslında beklenen bir durumdur. Bu sayede, ilgili materyal üzerindeki ilgili maddenin, tespit edilebilecek en düşük miktarı belirlenmiş olur. Şekil 65'te konumu işaretlenmiş olan yanlış negatif pikselinin diferansiyel yansıması Şekil 66'da gösterilmiştir.



Şekil 65. Seçilen Yanlış Negatif Pikselin Konumu



Şekil 66. Seçilen Yanlış Negatif Pikselinin Filtrelenmiş Diferansiyel Yansıması

Şekil 66'da görüldüğü gibi arka plan olarak işaretlenmiş Madde-1 yansımasının genliği çok küçüktür. Sonuç olarak, daha az miktardaki Madde-1 verisi hem daha az bir genliğe sahip olurken hem de daha oturtulan doğrunun eğimi daha düşük olmaktadır. Bu sebeple bu piksel hedef olarak işaretlenmemiştir.

6. SONUÇLAR VE ÖNERİLER

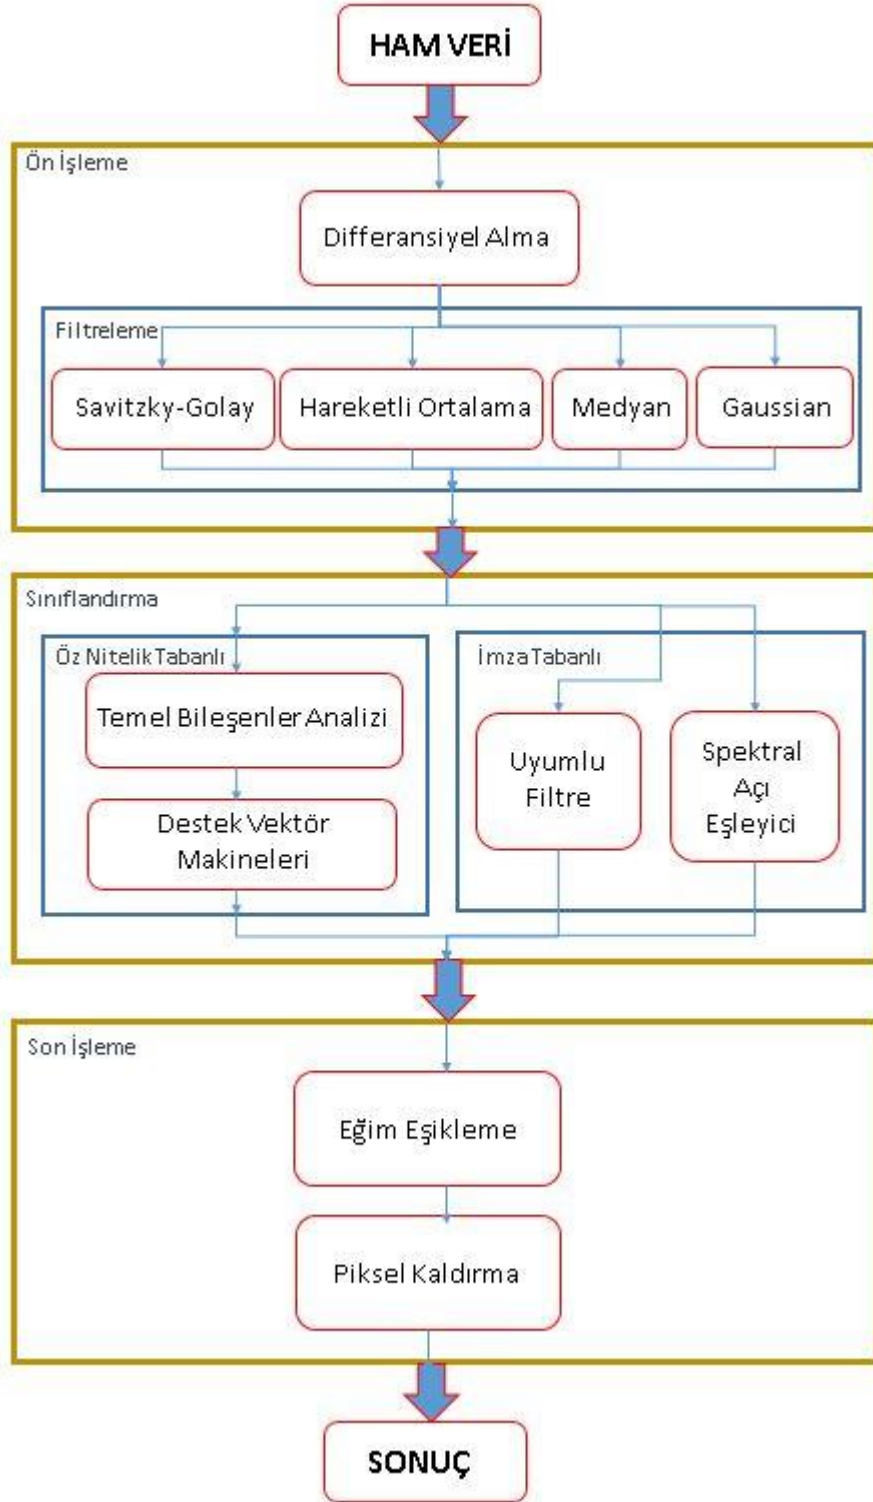
Bu tez kapsamında, uzaktan algılama yöntemlerinden biri olan hiperspektral görüntüleme tekniği kullanılarak bazı algoritmaların sınıflandırma performansı incelenmiştir. Bu çalışma için, geleneksel hiperspektral yansıma değerlerinin yerine diferansiyel hiperspektral yansıma verilerinin kullanılması önerilmiştir.

Şekil 67’de bu tez kapsamında incelenen algoritmaların akış diyagramı gösterilmiştir. Yapılan çalışmalar 3 ana bölümde toplanmıştır. Ön işleme, sınıflandırma ve son işleme olarak adlandırılan bu bölümlerin sırasıyla tamamlanmasıyla, gelen her bir ham veri arka plan ya da hedef olarak işaretlenmiştir. Bu işaretlemelerin doğruluğunun incelenmesi ile Bölüm 1’de anlatılan tezin amacı gerçekleştirilmiş olduğu için, bu işaretlemeler Şekil 67’de “sonuç” olarak gösterilmiştir.

Şekil 67’de gösterilen ön işleme bölümü, diferansiyel alma işlemi ile başlamaktadır. Daha sonra bu veriye, normalize edilmiş diferansiyel yansıma verileri gürültülü olduğu için filtreleme uygulanması önerilmiştir. Önerilen Savitzky-Golay, Hareketli Ortalama, Medyan ve Gaussian filtrelerinin farklı parametreleri ile sınıflandırılma yapılmıştır. Bu filtreleme algoritmalarının içerisinde en iyi olduğu kabul edilen algoritma ve parametreleri ile filtrelenmiş diferansiyel yansıma verisi sınıflandırma bölümüne aktarılır.

Şekil 67’deki sınıflandırma bölümünde ise iki farklı kategoride temelde üç farklı algoritma denenmiştir. Öz nitelik tabanlı sınıflandırma kategorisinde bulunan tek sınıflandırma algoritması Destek Vektör Makineleri için öncelikle öz nitelik çıkartma için kullanılan Temel Bileşenler Analizi algoritması uygulanmış daha sonra Destek Vektör Makineleri ile sınıflandırma gerçekleştirilmiştir. İncelenen üç sınıflandırma algoritmasından kalan iki algoritma, Uyumlu Filtre ve Spektral Açık Eşleyici algoritmaları, imza tabanlı sınıflandırma kategorisindedir.

Şekil 67’de gösterilen son işleme bölümünde ise, öncelikle sınıflandırma bölümünde hedef olarak tespit edilen piksellerin, belirli dalga boyları aralığındaki diferansiyel yansıma grafiğinin eğiminin belirli bir eşik değerinden fazla olmasını sağlayan Eğim Eşikleme algoritması kullanılmıştır. Son olarak da, belirli sayıdan daha az hedef pikseline sahip veri küplerinin hedef işaretlerinin iptal edildiği Piksel Kaldırma algoritması bulunmaktadır.



Şekil 67. Algoritma Akış Diyagramı

Farklı maddeler için çalışmalar yapılmasına rağmen, bu tez kapsamında algoritma detaylarını incelemek için sadece Madde-1 kullanılmıştır. Madde-1 verileri, 5 farklı materyal üzerinden toplanan ve her bir materyal için 5 farklı örneğin bulunduğu toplamda 25 veri küpüne sahip bir veri grubudur. Bu veri grubuna ilave olarak 15 arka plan veri küpü eklenmiş ve toplam 40 veri küpü analiz edilmiştir. Yapılan analizler sonucunda ön işleme filtresi olarak Savitzky-Golay filtresinin kullanılmasına karar verilmiştir. Bu filtre için farklı parametreler denenmiş ancak çerçeve boyutu 21 olan 2. dereceden polinomun gürültüyü azaltırken imzanın şeklini bozmamasından dolayı en iyisi olduğuna karar verilmiştir. Bu filtre ve parametreler ile filtrelenmiş diferansiyel yansıma verileri, önce öznitelik tabanlı daha sonra imza tabanlı algoritmalar ile sınıflandırılmıştır. Temel Bileşenler Analizi ile öznitelik belirlemesi yapıldıktan sonra 6 boyutlu veri için öz nitelik tabanlı olarak Destek Vektör Makineleri sınıflandırması uygulanmıştır. Destek Vektör Makineleri ile sınıflandırma sonucunda duyarlılık, yani hedef piksellerin doğru bulunma oranı yüzde 78.47 iken, özgüllük yani arka plan piksellerin doğru sınıflandırılma oranı yüzde 98.93 olmuştur. İmza tabanlı sınıflandırma için ise iki farklı imza için benzerliğin incelendiği Uyumlu Filtre ve Spektral Açık Eşleyici olmak üzere iki farklı algoritma denenmiştir. Algoritmaların PR eğrilerinden tespit edilen eşik değerleri ile sınıflandırma işlemleri gerçekleştirilmiştir. Bu şekilde yapılan sınıflandırma sonucunda, Uyumlu Filtre için duyarlılık yüzde 76.21 iken özgüllük yüzde 99.64 olmuş, Spektral Açık Eşleyici için ise duyarlılık yüzde 16.20 iken özgüllük yüzde 99.98 olmuştur. Sonuçlar incelendiğinde Spektral Açık Eşleyici'nin sadece hedef olarak seçilen arka plan için iyi sonuç verdiği diğer arka planlardaki veriler için iyi bir sınıflandırma yapmadığı görülmüştür. Bütün arka planlarda iyi çalışan genelleyici bir sonuç istendiği için Spektral Açık Eşleyici algoritmasının bu problem için kullanılması önerilmemektedir. Veri grubu tümüyle ele alındığında Uyumlu Filtre'nin diğer algoritmalara göre daha iyi sonuç verdiği görülmüştür. Bu yüzden bu tezde incelenen problem için Uyumlu Filtrenin kullanılması önerilmektedir. Ancak, bu algoritmanın süre bakımından daha uzun sürmesi kullanıcı tarafından tercih edilmemesine sebep olabilir. En son olarak, bu tezde incelenen Madde-1 verisinin yükseliş ya da düşüş yaptığı aralığın [300nm - 325nm] olduğu gözlemlenmiş ve bu aralıktaki eğimi 0.015'ten düşük olan ve sınıflandırıcılar tarafından hedef olarak sınıflandırılan piksellerin Eğim Eşikleme algoritması ile arka plan olarak işaretlenmesi

sağlanmıştır. Bu tez kapsamında geliştirilen ve son işleme olarak adlandırılan Eğim Eşikleme ve Piksel Kaldırma teknikleri sayesinde algoritmaların sınıflandırma başarısının arttığı görülmüştür. Bu sebeple tercih edilen sınıflandırma algoritması sonrasında son işleme algoritmalarının da kullanılması önerilmektedir.

Bu tez kapsamında yapılan çalışmalar piksel bazında yapılmış olup komşu piksellerin yansımaya etkisi düşünülmemiştir. Daha sonraki çalışmalarda bu etki hesaba katılabilir. Bununla beraber, her dalga boyu farklı bir görüntü gibi düşünülüp 2 boyutlu görüntü işleme algoritmaları veri üzerinde denenebilir. Ayrıca, bu tezde denenen bütün algoritmalar ayrı ayrı incelenmiştir. Daha sonraki çalışmalarda iki farklı algoritmanın füzyonu incelenebilir. Bunun yanı sıra, öz nitelik tabanlı ve imza tabanlı sınıflandırıcılar çeşitlendirilerek bu tezde anlatılan algoritmalar ile performansları karşılaştırılabilir. Bu tezin, ilerde yapılabilecek bu çalışmalar için katkı sağlayacağı düşünülmektedir.

KAYNAKLAR

- [1] S. E. Yuksel, T. Dubroca, R. E. Hummel, and P. D. Gader, An Automatic Detection Software For Differential Reflection Spectroscopy, SPIE Conference, vol. 8390, no. May, p. 83900B–83900B–7, **2012**.
- [2] D. S. Moore, Recent Advances In Trace Explosives Detection Instrumentation, Sens. Imaging, vol. 8, no. 1, pp. 9–38, **2007**.
- [3] M. Boyaci, Lidar ve Hiperspektral Verilerde Gölge Alanların İncelenmesi, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Ankara, **2015**.
- [4] J. B. Campbell, Introduction To Remote Sensing. New York, The Guilford Press, **2002**.
- [5] J. Maria, F. Pons, Robust target detection for Hyperspectral Imaging, Supélec **2015**.
- [6] N. Falco, Advanced Spectral And Spatial Techniques Classification, Doktora Tezi, University of Trento, **2015**.
- [7] R. E. Hummel, D. B. Dove and J. A. Holbrook, Optical Reflectivity Measurements On Alloys By Compositional Modulation, Physical Review Letters, vol. 25, no. 5, pp. 5–7, **1970**.
- [8] R. E. Hummel, A. M. Fuller, C. Schöllhorn, and P. H. Holloway, Detection Of Explosive Materials By Differential Reflection Spectroscopy, Appl. Phys. Lett., vol. 88, no. 23, pp. 2004–2007, **2006**.
- [9] A. M. Fuller, Investigation Of Select Energetic Materials By Differential Reflection Spectrometry, Doktora Tezi, University Of Florida, **2007**.
- [10] T. Dubroca, K. Vishwanathan, and R. E. Hummel, The Limit Of Detection For Explosives In Spectroscopic Differential Reflectometry, Proc. SPIE - Int. Soc. Opt. Eng., vol. 8018, no. May, pp. 1–7, **2011**.
- [11] T. Dubroca and R. E. Hummel, Detection Of Explosives By Hyper-Spectral Differential Reflectometry, MRS Proceedings, 1405, **2012**.

- [12] K. G. Furton and L. J. Myers, The Scientific Foundation And Efficacy Of The Use Of Canines As Chemical Detectors For Explosives, *Talanta Elsevier Science* vol. 54, pp. 1–14, **2001**.
- [13] I. Gazit and J. Terkel, Explosives Detection By Sniffer Dogs Following Strenuous Physical Activity, *Applied Animal Behaviour Science*, vol. 81, no. 2, pp. 149–161, **2003**.
- [14] L. Lazarowski and D. C. Dorman, Explosives Detection By Military Working Dogs: Olfactory Generalization From Components To Mixtures, *Applied Animal Behaviour Science*, vol. 151, pp. 84–93, **2014**.
- [15] I. Gazit, A. Goldblatt, and J. Terkel, Formation Of An Olfactory Search Image For Explosives Odours, *Ethology*, vol. 111, pp. 669–680, **2005**.
- [16] J. Otto, M. F. Brown, and W. Long, Training Rats To Search And Alert On Contraband Odors, *Applied Animal Behaviour Science*, vol. 77, no. 3, pp. 217–232, **2002**.
- [17] A. Corcelli, S. Lobasso, P. Lopalco, M. Dibattista, R. Araneda, Z. Peterlin, S. Firestein, Detection Of Explosives By Olfactory Sensory Neurons,” *Journal Of Hazardous Materials*, vol. 175, no. 1–3, pp. 1096–1100, **2010**.
- [18] M. E. Koscho, R. H. Grubbs, and N. S. Lewis, Properties Of Vapor Detector Arrays Formed Through Plasticization Of Carbon Black - Organic Polymer Composites, *Anal. Chem.*, vol. 74, no. 6, pp. 1307–1315, **2002**.
- [19] J. Yinon, Detection Of Explosives by Electronic Noses, *Analytical Chemistry*, pp. 99–105, **2003**.
- [20] R. T. Medary, Inexpensive, Rapid Field Screening Test For 2,4,6-Trinitrotoluene In Soil, *Anal. Chim. Acta*, vol. 258, no. 2, pp. 341–346, **1992**.
- [21] C. F. Bernasconi, Kinetic and Spectral Study Of Some Reactions of 2,4,6-Trinitrotoluene in Basic Solution. I. Deprotonation and Janovsky Complex Formation, *J. Org. Chem.*, vol. 36, no. 12, pp. 1671–1679, **1971**.

- [22] S. Singh, Sensors-An Effective Approach For The Detection Of Explosives, *Journal Of Hazardous Materials*, vol. 144, no. 1–2, pp. 15–28, **2007**.
- [23] P. Rabenecker and K. Pinkwart, A Look Behind Electrochemical Detection of Explosives, Propellants, Explos. Pyrotech., vol. 34, no. 3, pp. 274–279, **2009**.
- [24] J. S. Caygill, F. Davis, and S. P. J. Higson, Current Trends in Explosive Detection Techniques, *Talanta*, vol. 88, pp. 14–29, **2012**.
- [25] M. Tabrizchi and V. ILbeigi, Detection Of Explosives by Positive Corona Discharge Ion Mobility Spectrometry, *Journal Of Hazardous Materials*, vol. 176, no. 1–3, pp. 692–696, **2010**.
- [26] M. J. Waltman, P. Dwivedi, H. H. Hill, W. C. Blanchard, and R. G. Ewing, Characterization Of A Distributed Plasma Ionization Source (DPIS) For Ion Mobility Spectrometry and Mass Spectrometry, *Talanta*, vol. 77, no. 1, pp. 249–255, **2008**.
- [27] R. G. Ewing, D. A. Atkinson, G. A. Eiceman, and G. J. Ewing, A Critical Review Of Ion Mobility Spectrometry For The Detection Of Explosives and Explosive Related Compounds, *Talanta*, vol. 54, pp. 515–529, **2001**.
- [28] O. M. Primera-Pedrozo, Y. M. Soto-Feliciano, L. C. Pacheco-Londoño, and S. P. Hernández-Rivera, Detection Of High Explosives Using Reflection Absorption Infrared Spectroscopy With Fiber Coupled Grazing Angle Probe/FTIR, *Sens. Imaging*, vol. 10, no. 1–2, pp. 1–13, **2009**.
- [29] M. López-López, C. García-Ruiz, Infrared and Raman spectroscopy techniques applied to identification Of explosives, *TrAC - Trends Anal. Chem.*, vol. 54, pp. 36–44, **2014**.
- [30] Y. Mou and J. W. Rabalais, Detection and Identification Of Explosive Particles in Fingerprints Using Attenuated Total Reflection-Fourier Transform Infrared Spectromicroscopy, *J. Forensic Sci.*, vol. 54, no. 4, pp. 846–850, **2009**.
- [31] S. E. Yuksel, T. Dubroca, R. E. Hummel, and P. D. Gader, Differential Reflection Spectroscopy: A Novel Method for Explosive Detection, *Acta Phys. Pol. A*, vol.

123, no. 2, pp. 263–264, **2013**.


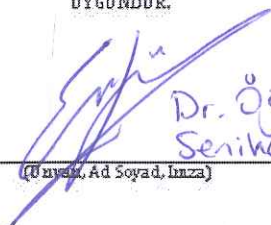
- [32] W. Zhang, Y. Tang, A. Shi, L. Bao, Y. Shen, R. Shen, Y. Ye, “Recent Developments in Spectroscopic Techniques For The Detection Of Explosives,” *Materials (Basel)*., vol. 11, no. 8, **2018**.
- [33] M. K. Choi, A. Bettermann, D. W. Van Der Weide, Potential For Detection Of Explosive and Biological Hazards with Electronic Terahertz Systems, *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.*, vol. 362, no. 1815, pp. 337–349, **2004**.
- [34] E. L. Izake, Forensic and Homeland Security Applications Of Modern Portable Raman Spectroscopy, *Forensic Sci. Int.*, vol. 202, no. 1–3, pp. 1–8, **2010**.
- [35] T. Dubroca, G. Brown, and R. E. Hummel, Detection of Explosives By Differential Hyperspectral Imaging, *Optical Engineering* 53(2), p. 021112, February **2014**.
- [36] A. Zare, P. Gader, J. Bolton, S. Yuksel, T. Dubroca, R. Close, R. Hummel, Sub-pixel Target Spectra Estimation and Detection Using Functions Of Multiple Instances , *Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS) Conference*, 6-9 June 2011, Lisbon, pp. 1–4, **2011**.
- [37] D. Pyle, S. Editor, and D. D. Cerra, *Data Preparation for Data Mining*, vol. 17. **1999**.
- [38] A. Savitzky and M. J. E. Golay, “Smoothing and Differentiation Of Data by Simplified Least Squares Procedures,” *Anal. Chem.*, vol. 36, no. 8, pp. 1627–1639, **1964**.
- [39] W. Gander and J. Hrebicek, *Solving Problems in Scientific Computing Using Maple and MATLAB*. Chapter 9, **1997**.
- [40] W. Jamil, Y. Kaliniskan, and H. Bouchachia, Aggregation Algorithm vs. Average for Time Series Prediction, *CEUR Workshop Proc.*, vol. 2069, no. October, **2017**.
- [41] G. W. Brown, Standard Deviation, Standard Error, *Am J Dis Child*, vol. 136, no. 10, pp. 937–941, **1982**.
- [42] V. Musoko and a Prochazka, Non-Linear Median Filtering Of Biomedical Images,

- 10th Conf. MATLAB, vol. 3, pp. 1–5, **2002**.
- [43] J. Tang, S. Alelyani, and H. Liu, Feature Selection for Classification: A Review, *Data Classif. Algorithms Appl.*, pp. 37–64, **2014**.
- [44] C. Lee and D. Landgrebe, Feature Extraction and Classification Algorithms for High Dimensional Data, *ECE Tech. Reports*, **1993**.
- [45] M. M. El-Gayar, H. Soliman, and N. Meko, A Comparative Study Of Image Low Level Feature Extraction Algorithms, *Egypt. Informatics J.*, vol. 14, no. 2, pp. 175–181, **2013**.
- [46] H. Abdi and L. J. Williams, Principal Component Analysis, *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 2, no. 4, pp. 433–459, **2010**.
- [47] Z. Filiz, Güvenilirlik Çözümlemesi, Temel Bileşenler ve Faktör Çözümlemesi, *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, Cilt:4 No:2, 211-222, **2003**.
- [48] I. Yazar, Temel Bileşen Analizi ve Bağımsız Bileşen Analizi Yöntemlerini Temel Alan Bazı Görüntü Tanıma Uygulamaları ve Karşılaştırmaları, *Journal Of Engineering and Architecture Faculty Of Eskişehir Osmangazi University*, Vol: XXII, No:1, **2008**.
- [49] I. T. Jolliffe, Principal Component Analysis, Second Edition, *Encycl. Stat. Behav. Sci.*, vol. 30, no. 3, p. 487, **2002**.
- [50] C. Cortes and V. Vapnik, Support-Vector Networks, *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, **1995**.
- [51] C. M. Bishop, *Pattern Recognition and Machine Learning*, vol. 53, no. 9., Springer **2013**.
- [52] S. Dong, *Methods for Constrained Optimization*, Massachusetts Institute of Technology, Cambridge, January **2006**.
- [53] S. Boyd and L. Vandenberghe, *Convex Optimization*, vol. 25, no. 3., Cambridge University Press, **2010**.
- [54] T.-M. Huang, V. Kecman, and I. Kopriva, *Kernel Based Algorithms for Mining*

Huge Data Sets, Springer-Verlag, Heidelberg, **2006**.

- [55] B. M. ÖZYILDIRIM, An Error Correcting Code Based SVM Approach for Multiclass Classification, Çukurova Üniversitesi, Adana, **2012**.
- [56] B. Ravikumar, D. Thukaram, and H. P. Khincha, Comparison Of multiclass SVM classification methods to use in a supportive system for distance relay coordination, IEEE Trans. Power Deliv., vol. 25, no. 3, pp. 1296–1305, **2010**.
- [57] C. W. Hsu and C. J. Lin, A comparison Of methods for multiclass support vector machines, IEEE Trans. Neural Networks, vol. 13, no. 2, pp. 415–425, **2002**.
- [58] M. A. Kumar and M. Gopal, Reduced one-against-all method for multiclass SVM classification, Expert Syst. Appl., vol. 38, no. 11, pp. 14238–14248, **2011**.
- [59] K.-B. Duan and S. S. Keerthi, Which Is the Best Multiclass SVM Method? An Empirical Study, pp. 278–285, **2005**.
- [60] A. Zare, C. Jiao, and T. Glenn, Discriminative Multiple Instance Hyperspectral Target Characterization, IEEE Trans. Pattern Anal. Mach. Intell., **2017**.
- [61] X. Jin, S. Paswaters, and H. Cline, A Comparative Study Of Target Detection Algorithms For Hyperspectral Imagery, vol. 7334, p. 73341W, **2009**.
- [62] S. Buganim and S. R. Rotman, Matched filters for multispectral point target detection, vol. 6302, no. 2, p. 63020Z–63020Z–8, **2006**.
- [63] S.E. Yuksel and A. Karakaya, Fusion Of Target Detection Algorithms In Hyperspectral Images, International Journal of Intelligent Systems and Applications in Engineering, 4(4), 103-110, **2016**.

EK 1 - Tez Çalışması Orjinallik Raporu

	HACETTEPE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU
HACETTEPE ÜNİVERSİTESİ FEN BİLİMLER ENSTİTÜSÜ ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA	
Tarih: 12/02/2019	
Tez Başlığı / Konusu : Diferansiyel Hiperspektral Görüntüleme Tekniği ile Kimyasal Madde Tespit Yöntemlerinin İncelenmesi	
Yukarıda başlığı/ konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç bölümlerinden oluşan toplam 168 sayfalık kısmına ilişkin, 12/02/2019 tarihinde çalışmam /tez çalışmamın tarafından Torun tarafından intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orjinallik raporuna göre, tezimin benzerlik oranı % 3'tür.	
Uygulanan filtrelemeler:	
1- Kaynakça hariç	
2- Alıntılar hariç /dâhil	
3- 5 kelimeden daha az örneğe içeren metin kısımları hariç	
Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Ahimsa ve Kullanılma Uygulama Esaslarını inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksininin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.	
Gereğini saygılarımla arz ederim.	
Tarih ve İmza	
Adı Soyadı: Fırat GÜRBÜZ	
Öğrenci No: N13221285	
Anabilim Dalı: Elektrik ve Elektronik Mühendisliği	
Programı: Tezli Yüksek Lisans	
Statusü: <input checked="" type="checkbox"/> Y Lisans <input type="checkbox"/> Doktora <input type="checkbox"/> Bütünleşik Dr.	
	12.02.2019 YGB
DANIŞMAN ONAYI	
UYGUNDUR.	
	
Dr. Öğr. Üyesi Seriha Esen YÜKSEL	
(Ünvan, Ad Soyad, İmza)	

ÖZGEÇMİŞ

Adı Soyadı : Fırat GÜRBÜZ
Doğum yeri : Şanlıurfa
Doğum tarihi : 19.02.1990
Medeni hali : Evli
Elektronik posta adresi : firatgurbuz@gmail.com
Yabancı dili : İngilizce (İleri Seviye)

EĞİTİM DURUMU

Lisans : Orta Doğu Teknik Üniversitesi (2008-2013)
Yüksek Lisans : Hacettepe Üniversitesi (2014-2019)