



**HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN ÖĞRENME  
İLE HEDEF TESPİTİ**

**TARGET DETECTION ON HYPERSPECTRAL IMAGES  
USING DEEP LEARNING**

**BATUHAN MERT SEVEROĞLU**

**DOÇ. DR. SENİHA ESEN YÜKSEL ERDEM**

**Tez Danışmanı**

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2021

## ÖZET

# HİPERSPEKTRAL GÖRÜNTÜLERDE DERİN ÖĞRENME İLE HEDEF TESPİTİ

**Batuhan Mert SEVEROĞLU**

**Yüksek Lisans, Elektrik ve Elektronik Mühendisliği**

**Tez Danışmanı: Doç. Dr. Seniha Esen YÜKSEL ERDEM**

**Ocak 2021, 110 sayfa**

Son yıllarda, patlayıcı ve uyuşturucu gibi tehlike arz eden kimyasallar birçok insanın ve özellikle de güvenlik güçlerinin çeşitli alanlarda büyük sorunlar yaşamasına neden olmuştur. Bu da tehlikeli kimyasalların mümkün olduğunca erken tespit edilmesini kritik bir görev haline getirmiştir. Bu görevi yerine getirmek için farklı türde veriyi kullanan birçok sistem ve algoritma geliştirilmiştir. Ancak son dönemde, gelişen teknoloji ile birlikte tehlikeli kimyasalların çeşitliliğinin, taşınma yöntemlerinin ve eser miktarda kullanımlarının artması hali hazırda bulunan algoritmaların yetersiz kalmasına sebep olmuştur. Bu yüzden kimyasal maddelerin tespiti için daha kapsamlı çözümler sunan sistemler üzerinde çalışmalar başlamıştır. Kimyasal maddelerin tespiti bir hedef tespiti görevi olduğundan, birçok alanda hedef tespiti için sıklıkla kullanılan Hiperspektral Görüntüleme (HSG) tekniği kimyasal maddelerin tespiti için de önemli bir alternatif olmuştur. Ayrıca son yıllarda birçok alanda başarılarını kanıtlamış, Evrişimsel Sinir Ağları (ESA) ve Uzun Kısa Süreli Bellek (UKSB) gibi derin öğrenme modelleri de hedef tespiti için en çok kullanılan yöntemlerdendir. Bu tez kapsamında, Hiperspektral Görüntüleme'yi kullanan bir düzenek ile dört farklı kimyasal madde dört farklı arka plan materyali üzerine koyularak hiperspektral görüntüler toplanmıştır. Bu görüntüler içerisinden belirli yöntemlerle seçilen pikseller ile her kimyasal için ayrı veri

kümesi oluşturulmuştur. Bu veri kümeleri kimyasal madde tespiti için çeşitli ESA ve UKSB modellerinde kullanılmıştır. Veriler ilk olarak ön işleme aşamasında Diferansiyel Reflektometri (DR) işleminden geçirilmiştir. Bu işlem ardışık iki taramanın yansıma değerleri farkının normalize edilmesi işlemidir. Türev benzeri bu işlem ile toplanan hiperspektral verilerin spektral boyutundaki öznitelikler ayırt edici hale getirilmiştir. Ön işleme aşamasının ikinci kısmında, derin öğrenme modellerine daha pürüzsüz ve gürültüsüz spektral veriler beslemek için verilerin spektral boyutuna Savitzky-Golay filtresi uygulanmıştır. Böylece hazır hale getirilen spektral veriler derin öğrenme modellerine beslenmiştir. Bu tez kapsamında temel olarak üç tür derin öğrenme modeli ele alınmıştır. İlk olarak tek boyutlu ESA modeli ele alınmıştır. Bu modelin girdileri tek boyutlu spektral vektörlerdir ve modeldeki tüm işlemler tek boyutludur. Sonra geliştirilen iki boyutlu ESA modelinde, girdi verileri ve modeldeki tüm işlemler iki boyutlu işlemlerdir. İki boyutlu ESA modeli için oluşturulan matris şeklindeki girdi verileri, tek boyutlu spektral verilerin yeniden biçimlendirilmesi ile elde edilmiştir. Son olarak geliştirilen UKSB modelinde ise tek boyutlu spektral bilgi direkt olarak kullanılmıştır. Geliştirilen modellerin dört farklı kimyasal madde için, dört farklı arka plan materyali üzerindeki hedef tespit performansları incelenmiştir. Kimyasal hedeflerin tespitini kritik biçimde etkileyen durumlar değerlendirilmiştir. Bu durumlar kimyasal maddenin türü, arka plan materyalinin türü, veri kümesindeki verilerin kullanılabilirliği ve sayısı, kimyasal maddenin yüzeydeki miktarı, görüntüdeki şekil ve nesnelerin kenarları gibi etmenlerdir. Ayrıca ön işleme, eğitim ve son işleme aşamalarında modelin performansını arttırmak için denenen yöntemlerin avantaj ve dezavantajları ortaya koyulmuştur. Sonuçta, kullanılan veri kümesi için ESA modellerinin UKSB modellerine göre daha iyi performansa sahip olduğu görülmüştür. Geliştirilen ESA modelleri çoğu kimyasalın tespitinde yüksek performans göstermiştir. Ayrıca verilerin iki boyutlu hale getirilmesi sayesinde, tek boyutlu ESA modelinden iki boyutlu ESA modeline geçişin de performansı önemli ölçüde arttırdığı belirtilmiştir. Bu tez kapsamında geliştirilen modeller ile tehlikeli kimyasal maddelerin ESA modelleriyle başarılı bir şekilde tespit edilebildiği anlaşılmış, UKSB modellerinin de bu görev için gelecek vaat ettiği görülmüştür.

**Anahtar Kelimeler:** hiperspektral görüntüleme, diferansiyel reflektometri, derin öğrenme, evrimsel sinir ağı, uzun kısa süreli bellek, hedef tespiti

## **ABSTRACT**

# **TARGET DETECTION ON HYPERSPECTRAL IMAGES USING DEEP LEARNING**

**Batuhan Mert SEVEROĞLU**

**Master of Sciences, Electrical and Electronics Engineering**

**Supervisor: Assoc. Prof. Dr. Seniha Esen YÜKSEL ERDEM**

**January 2021, 110 pages**

In recent years, hazardous chemicals such as explosives and narcotics have caused many people and particularly security forces to experience major problems in various areas. This has made the detection of hazardous chemicals as early as possible a critical task. Several systems and algorithms using different types of data have been developed to fulfill this task. However, in the last period, the increase in the diversity of hazardous chemicals, transportation methods and the use of trace amounts together with the developing technology caused the existing algorithms to fall short. Therefore, studies have been initiated on systems that offer more comprehensive solutions for the detection of chemical substances. Since the detection of chemicals is a target detection task, the Hyperspectral Imaging (HSI) technique, which is frequently used in many areas of target detection, has become an important alternative for the detection of chemicals. Furthermore, deep learning models such as Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM), which have proven their success in many fields in recent years, are among the most used methods of target detection. In the scope of this thesis, hyperspectral images were collected by placing four different chemical substances on four different background materials with a mechanism using Hyperspectral Imaging. A separate dataset for each chemical was formed with pixels selected by

certain methods in these images. These datasets have been used in several CNN and LSTM models for chemical substance detection. The data were first passed through the Differential Reflectometry (DR) process during the pre-processing stage. DR is the process of normalizing the difference between the reflection values of two sequential scans. The attributes in the spectral dimension of the hyperspectral data collected by this differential-like process are made distinctive. In the second part of the pre-processing stage, Savitzky-Golay filter was applied to the spectral dimension of the hyperspectral data with the intent of feeding smooth and noise-free spectral data to the deep learning models. Thus, spectral data prepared in this way are fed into deep learning models. In the scope of this thesis, three types of deep learning model have been discussed. Firstly, one-dimensional CNN model was discussed. The inputs of this model are one-dimensional spectral vectors and all processes in the model are one-dimensional. In the two-dimensional CNN model developed later, the input data and all the processes in the model are two-dimensional operations. The matrix-shaped inputs of the two-dimensional CNN model were obtained by reshaping one-dimensional spectral data. In the lastly developed LSTM model, one-dimensional spectral information was used directly. Target detection performances of four different chemical substances of the developed models on four different background materials were investigated. Situations that critically affect the detection of chemical targets are considered. These cases are the type of chemical substance, the type of background material, the number of availability of data in the dataset, the amount of the chemical on the surface, the shape and edges of objects in the image. In addition, the advantages and disadvantages of the methods tried to increase the performance of the model in the post-processing, training and final processing stages are exhibited. As a result, it was seen that the CNN models had better performance than the LSTM models for the used dataset. The improved CNN models demonstrate high performance in the detection of most chemicals. It is also stated that the transition from the one-dimensional CNN model to the two-dimensional CNN model has significantly improved the performance by making the data two-dimensional. With the models developed within the scope of this thesis, it has been understood that hazardous chemical substances can be detected successfully with CNN models, and it has been seen that the LSTM models are also promising for this task.

**Keywords:** hyperspectral imaging, differential reflectometry, deep learning, convolutional neural networks, long short term memory, target detection



## TEŐEKKÜR

Tez sürecim boyunca bilgi ve deneyimleri ile yol gösteren, manevi olarak da iyi niyeti ve desteęini hiçbir zaman esirgemeyen deęerli tez danıőmanım Doę. Dr. Seniha Esen YÜKSEL ERDEM'e en büyük teőekkürü borę bilirim.

Tez ęalıőmalarımda ve hayatımın her anında bir an olsun beni yalnız bırakmayan, en büyük destekçim ve en yakın arkadaőım, sevgili eőim Tuna SERÇALI SEVEROĞLU'na, hayatım boyunca her alanda beni destekleyen ve bugünlere gelmem için büyük emekler veren annem Gülőah SEVEROĞLU'na, babam Bülent SEVEROĞLU'na ve kardeőim Dila Süreyya SEVEROĞLU'na ve bu süreçte manevi olarak hep yanımda olan yakın arkadaőlarıma ve ęalıőma arkadaőlarıma sonsuz teőekkürler...

# İÇİNDEKİLER

ÖZET .....	i
ABSTRACT .....	iii
TEŞEKKÜR .....	vi
İÇİNDEKİLER .....	vii
ŞEKİLLER .....	ix
ÇİZELGELER .....	xiii
KISALTMALAR .....	xv
1. GİRİŞ .....	1
1.1 Tezin Amacı .....	4
1.2 Tezin Akışı .....	5
2. HİPERSPEKTRAL GÖRÜNTÜLERİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI .....	6
3. VERİ KÜMESİNİN İNCELENMESİ VE ÖN İŞLEME AŞAMALARI .....	15
3.1 Verilerin Toplanması .....	15
3.2 Veri Kümesinin Tanımı ve Boyutları .....	17
3.3 Dengesiz Veri Kümesi ve Değerlendirme Ölçütleri .....	20
3.4 Diferansiyel Reflektometri .....	22
3.5 Savitzky-Golay Filtreleme .....	24
4. SİNİR AĞLARININ İŞLEYİŞİ VE ÇEŞİTLERİ .....	28
4.1 Biyolojik Sinir Ağları .....	28
4.2 Yapay Sinir Ağları .....	29
4.2.1 Geri Yayılım .....	31
4.2.2 Kayıp Fonksiyonu .....	31
4.2.3 Optimizasyon .....	32
4.2.4 Hiperparametre Ayarlama .....	34
4.2.5 Eksik Uyum ve Aşırı Uyum .....	36
4.3 Evrimsel Sinir Ağları .....	37
4.3.1 Evrişim Katmanı .....	38

4.3.2	Aktivasyon Katmanı.....	41
4.3.3	Yığın Normalizasyonu Katmanı .....	42
4.3.4	Havuzlama Katmanı.....	44
4.3.5	Tam Bağlantı Katmanı .....	46
4.3.6	Sınıflandırma (Çıktı) Katmanı.....	46
4.4	Tekrarlayan Sinir Ağları .....	47
4.4.1	Uzun Kısa Süreli Bellek.....	49
5.	GELİŞTİRİLEN SİNİR AĞI MODELLERİ.....	53
5.1	Tek Boyutlu Evrişimsel Sinir Ağı Modeli .....	53
5.2	İki Boyutlu Evrişimsel Sinir Ağı Modeli .....	55
5.3	Uzun Kısa Süreli Bellek Modeli .....	59
6.	DENEYSEL SONUÇLAR.....	62
6.1	ESA-1 ile Geliştirilen Modellerin Testleri ve Sonuçları .....	63
6.1.1	Arka Plan Materyalinin Sonuçlara Etkisi.....	67
6.1.2	Kenar Piksellerde Tespit Edilen Yanlış Pozitif Piksellerin Sonuçlara Etkisi .....	71
6.1.3	Kimyasal Madde Miktarının Sonuçlara Etkisi.....	76
6.2	ESA-2 ile Geliştirilen Modellerin Testleri ve Sonuçları .....	79
6.2.1	İki Boyutlu Girdinin ve Mimarının Sonuçlara Etkisi.....	80
6.2.2	Azınlık Sınıfın Örnek Sayısının Arttırılmasının Sonuçlara Etkisi .....	83
6.2.3	Bağlı Bileşenler Yöntemi ile Tespit Elemenin Sonuçlara Etkisi.....	84
6.2.4	Sınıflandırma Olasılıkları Üzerinden Eşikleme Yapmanın Sonuçlara Etkisi .....	85
6.2.5	Çevre Piksellerin Spektrumlarının Ortalamasının Sonuçlara Etkisi .....	87
6.3	ESA-1 ve ESA-2 Modellerinin ROC ve PR Eğrilerinin Karşılaştırılması .....	89
6.4	UKSB ile Geliştirilen Modellerin Testleri ve Sonuçları .....	93
6.5	Uygulamada Kullanılan Yazılımlar ve Donanımlar .....	95
7.	SONUÇLAR VE DEĞERLENDİRME.....	97
	KAYNAKLAR .....	100

## ŞEKİLLER

1.1	Bir hiperspektral görüntünün üç boyutlu görseli, rastgele bir dalga boyundaki iki boyutlu görseli ve rastgele bir pikselindeki spektrumu. ....	2
3.1	Hiperspektral verileri toplamak için kurulan düzenek. ....	15
3.2	Veri kümesindeki rastgele bir hiperspektral görüntünün 300. bandından alınan görsel üzerindeki ayakkabı, arka plan ve kimyasalın pozisyonları. ....	17
3.3	Hedef olarak kullanılan dört kimyasal maddenin Diferansiyel Reflektometri işlemi sonrasındaki ideal spektrumlarının ve soğurum kenarlarının gösterimi. a) Kimyasal-1 spektrumu, b) Kimyasal-2 spektrumu, c) Kimyasal-3 spektrumu, d) Kimyasal-4 spektrumu. ....	18
3.4	Dört kimyasal madde için spektral boyutta gerçekleştirilen Savitzky-Golay filtreleme işlemi. a) Kimyasal-1 spektrumunun filtrelenmesi, b) Kimyasal-2 spektrumunun filtrelenmesi, c) Kimyasal-3 spektrumunun filtrelenmesi, d) Kimyasal-4 spektrumunun filtrelenmesi. ....	27
4.1	Biyolojik sinir hücresi. ....	29
4.2	Yapay sinir hücresi. ....	30
4.3	Kayıp fonksiyonu üzerinde yerel ve genel minimum noktaların gösterimi. ....	33
4.4	Öğrenme hızı parametresine göre değişen hata eğrilerinin gösterimi. ....	35
4.5	Eğitim ve test aşamalarında elde edilen hata eğrileri ile eksik uyum bölgesinin, aşırı uyum bölgesinin ve genelleme aralığının gösterimi. ....	36
4.6	$32 \times 32 \times 3$ boyutunda bir görüntünün $5 \times 5 \times 6$ boyutunda bir filtre ile evriştirilmesi sonucu 6 tane $28 \times 28$ boyutlu öznitelik haritasının oluşması. ...	39
4.7	İki boyutlu evrişim işlemi örneği. ....	40
4.8	Literatürde sıklıkla kullanılan üç aktivasyon fonksiyonunun grafikleri. a) Sigmoid fonksiyonu, b) Hiperbolik Tanjant fonksiyonu, c) ReLU fonksiyonu. ....	43
4.9	İki boyutlu maksimum havuzlama ve ortalama havuzlama örnekleri. ....	45
4.10	Tek katmanlı TSA yapısı. ....	48

4.11	Klasik TSA'daki işlem birimi. ....	49
4.12	UKSB'deki işlem birimi. ....	50
5.1	Tek boyutlu ESA mimarisindeki katmanların, her katmandaki veri boyutlarının ve temel katmanlar arasında yapılan işlemlerin gösterimi. ....	54
5.2	Bir pikselin spektral verisinin $1 \times 548$ boyutlu vektörden $24 \times 24$ boyutlu matrise dönüştürülme işlemi. ....	56
5.3	İki boyutlu ESA mimarisindeki katmanların, her katmandaki veri boyutlarının ve temel katmanlar arasında yapılan işlemlerin gösterimi. ....	57
5.4	ESA-2 mimarisinde dört kimyasal madde için geliştirilen modellerin eğitim ve doğrulama kümelerindeki kayıp fonksiyonlarının grafikleri. ....	58
5.5	UKSB mimarisindeki katmanların ve katmanlar arasında yapılan işlemlerin gösterimi. ....	60
6.1	Hiperpektral görüntüde tespit edilen DP, YP, DN ve YN piksel örneklerinin gösterimi. ....	64
6.2	Kimyasal-1'in tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-1 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-1 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-1 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-1 spektrumu. ....	68
6.3	Kimyasal-2'nin tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-2 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-2 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-2 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-2 spektrumu. ....	69
6.4	Kimyasal-3'ün tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-3 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-3 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-3 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-3 spektrumu. ....	70

6.5	Kimyasal-4'ün tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-4 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-4 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-4 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-4 spektrumu. ....	71
6.6	Hedef içeren ve içermeyen görüntüler üzerinde ayakkabının ön alt ucunda tespit edilen YP pikseller ve arka plan materyalinin ortasında tespit edilen DP piksellerin gösterimi. a) YP ve DP pikseller tespit edilen DP görüntü, b) Sadece YP pikseller tespit edilen YP görüntü.....	72
6.7	Ayakkabının ön alt ucunda YP olarak tespit edilen ve arka plan materyalinin ortasında tespit edilen Kimyasal-4 spektrumlarına önemli ölçüde benzeyen dört adet YP pikselin spektrumları. ....	72
6.8	Arka plan materyalinin ortasında DP olarak tespit edilen ve ayakkabının ön alt ucunda tespit edilen YP piksellerin spektrumlarına önemli ölçüde benzeyen 2500 ng Kimyasal-4 içeren dört adet pikselin spektrumları.....	73
6.9	Hedef içeren ve içermeyen görüntüler üzerinde arka plan materyalinin kenarlarında tespit edilen YP piksellerin ve arka plan materyalinin ortasında tespit edilen DP piksellerin gösterimi. ....	74
6.10	Arka plan materyalinin kenarlarında YP olarak tespit edilen ve arka plan materyalinin ortasında tespit edilen Kimyasal-3 spektrumlarına önemli ölçüde benzeyen dört adet YP pikselin spektrumları. ....	75
6.11	Arka plan materyalinin ortasında DP olarak tespit edilen ve arka plan materyalinin kenarlarında tespit edilen YP piksellerin spektrumlarına önemli ölçüde benzeyen 2500 ng Kimyasal-3 içeren dört adet pikselin spektrumları.....	76
6.12	Dört kimyasalın Arka-Plan-1 üzerindeki düşük ve yüksek gramajdaki örnek spektrumlarının gösterimi.....	77
6.13	Gerçek Kimyasal-4 spektrumları ile SMOTE kullanılarak üretilmiş yapay Kimyasal-4 spektrumlarının karşılaştırılması. ....	84

6.14	Kimyasal-3 modelinin test kümesi verileri üzerinde tespit ettiği DP ve YP piksellerin olasılık dağılımlarını gösteren histogramlar. a) Kimyasal-3 modelinin tespit ettiği DP piksellerin olasılık dağılımını gösteren histogram, b) Kimyasal-3 modelinin tespit ettiği YP piksellerin olasılık dağılımını gösteren histogram. ....	86
6.15	Kimyasal-1 modelinin test kümesi verileri üzerinde tespit ettiği DP ve YP piksellerin olasılık dağılımlarını gösteren histogramlar. a) Kimyasal-1 modelinin tespit ettiği DP piksellerin olasılık dağılımını gösteren histogram, b) Kimyasal-1 modelinin tespit ettiği YP piksellerin olasılık dağılımını gösteren histogram. ....	87
6.16	Kimyasal-3 içeren piksellerin normal spektrumları ile çevre piksellerin spektral bilgilerinin ortalaması alınarak elde edilen spektrumlarının kıyaslanması. .	88
6.17	ESA-1’de ve ESA-2’de geliştirilen dört kimyasal modelinin ROC eğrilerinin geniş biçimde ve sol üst bölgeye yakınlaştırılmış biçimde gösterimleri. ....	90
6.18	ESA-1’de ve ESA-2’de geliştirilen dört kimyasal modelinin PR eğrilerinin gösterimi. a) Kimyasal-1 modelinin ESA-1’deki ve ESA-2’deki PR eğrisi, b) Kimyasal-2 modelinin ESA-1’deki ve ESA-2’deki PR eğrisi, c) Kimyasal-3 modelinin ESA-1’deki ve ESA-2’deki PR eğrisi, d) Kimyasal-4 modelinin ESA-1’deki ve ESA-2’deki PR eğrisi. ....	92
6.19	Tüm katmanlardaki nöron sayıları 256 olduğu durumda UKSB modellerindeki hedef tespiti örnekleri. ....	94
6.20	Tüm katmanlardaki nöron sayıları 8 olduğu durumda UKSB modellerindeki hedef tespiti örnekleri. ....	95

## ÇİZELGELER

3.1	Dört kimyasal madde için hazırlanan eğitim kümelerinin boyutları. ....	19
3.2	Her kimyasal ve arka plan kombinasyonu için test kümesinde bulunan görüntü sayıları. ....	20
3.3	Karmaşıklık matrisi. ....	21
3.4	Dengesiz veri kümeleri ile öğrenme yöntemlerinde sıklıkla kullanılan performans ölçütlerinin matematiksel tanımları. ....	22
4.1	Sıklıkla kullanılan dört kayıp fonksiyonunun matematiksel tanımları. ....	32
4.2	Sıklıkla kullanılan optimizasyon yöntemlerinin matematiksel modelleri. ....	34
4.3	En yaygın üç aktivasyon fonksiyonunun ve türevlerinin denklemleri. ....	42
5.1	Tek boyutlu ESA mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri. ....	55
5.2	İki boyutlu ESA mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri. ....	59
5.3	UKSB mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri. ....	61
6.1	Dört kimyasal için ESA-1 mimarisi ile geliştirilen modellerin imaj bazlı performans sonuçları. ....	65
6.2	Dört kimyasal için ESA-1 mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları. ....	66
6.3	Test aşamasında kullanılan görüntülerin içerdiği kimyasalların yüksek ve düşük gramajdaki miktarları. ....	78
6.4	Dört kimyasal için ESA-2 mimarisi ile geliştirilen modellerin imaj bazlı performans sonuçları. ....	81
6.5	Dört kimyasal için ESA-2 mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları. ....	82



6.6	Dört kimyasal madde için veri kümelerinin %20'si ayrılarak elde edilen test kümelerinin boyutları. ....	92
6.7	Dört kimyasal için UKSB mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları. ....	94


## KISALTMALAR

<b>Kısaltma</b>	<b>Tanım</b>
HSG	Hiperspektral Görüntüleme
DR	Diferansiyel Reflektometri
YSA	Yapay Sinir Ağı
ESA	Evrişimsel Sinir Ağı
TSA	Tekrarlayan Sinir Ağı
UKSB	Uzun Kısa Süreli Bellek
HSI	Hyperspectral Imaging
CNN	Convolutional Neural Network
LSTM	Long Short-Term Memory
ReLU	Rectified Linear Unit

# 1. GİRİŞ

Dünya genelinde artan teknoloji ile birlikte yasal olmayan olayları engellemek amacıyla farklı türde güvenlik sistemleri geliştirilmektedir. Bu sistemler ses, görüntü, hareket gibi özellikleri algılayarak tehlike arz eden durumlarda güvenlik güçlerine uyarıda bulunulmasını sağlar. Özellikle kalabalık alanların güvenliği oldukça kritik bir konu olduğundan havaalanları, iş ve kongre merkezleri, konser alanları, stadyumlar gibi çok fazla insan bulunan mekanların güvenliği için birkaç sistem bir arada kullanılır. Havaalanlarında saldırı, patlama ve uyuşturucu kaçakçılığı gibi suçları engellemek amacıyla ciddi önlemler alınmaktadır. Bu tür olaylar son dönemlerde genellikle çeşitli kimyasal maddeler kullanılarak yapıldığından bu durumların önceden tespit edilmesi kritik bir husustur [1][2]. Bu yüzden tehlike oluşturabilecek kimyasal maddelerin tespit edilmesi önemli bir çalışma konusu haline gelmiştir. Kimyasal maddeleri tespit etmenin çeşitli yolları olsa da bunlardan en yaygınları genellikle Uzaktan Algılama yöntemleri ile yapılır. Uzaktan Algılama, belirli bir mesafeden, temas edilmeden, bir alanın veya bir nesnenin yansıyan ve yayılan radyasyonunu ölçerek fiziksel özelliklerini algılama ve izleme sürecidir. Uzaktan algılama kamera, kızılötesi sensör, hiperpektral kamera, RADAR, LİDAR, SAR, fotometre, radyometre ve spektrometre gibi birçok cihaz ile yapılabilir. RADAR, LİDAR ve SAR gibi aktif algılama yapan sistemler kendi yaydıkları enerjinin geri dönüşünü kullanırken, pasif algılama yapan sistemlerde güneş enerjisi nedeniyle yansıyan enerji veya nesnenin kendi iç enerjisi kullanılır.

Pasif Uzaktan Algılama yöntemlerinden biri olan Hiperspektral Görüntüleme (HSG) birçok alanda maddelerin veya nesnelerin tespit ve teşhis edilmesinde sıklıkla kullanılır. Hiperspektral Görüntüleme maddeleri belirlemek, nesneleri bulmak ve hedefleri tespit etmek gibi amaçlarla bir görüntüdeki tüm piksellerin elektromanyetik spektrumunun toplanması ve işlenmesi tekniğidir. Hiperspektral spektrometre elektromanyetik spektrumun ardışık yüzlerce bandından bilgileri toplar ve hiperspektral görüntüyü oluşturur. Hiperspektral görüntüler iki uzamsal boyut ve bir spektral boyuttan oluşur. Uzamsal boyutlar yüzlerce piksel ile temsil edilir. Her pikselin kendine özgü bir spektrumu olduğu gibi, her dalgaboyunda da farklı görüntüler oluşur [3]. Hiperpektral görüntünün bu özellikleri Şekil 1.1'de gösterilmiştir.



ŞEKİL 1.1: Bir hiperspektral görüntünün üç boyutlu görseli, rastgele bir dalga boyundaki iki boyutlu görseli ve rastgele bir pikselindeki spektrumu.

HSG anomali ve hedef tespiti için çeşitli alanlarda kullanılır. Bu yüzden HSG'yi kullanan birçok tespit algoritması geliştirilmiştir. RX Anomali Algılayıcı, Uyumlu Filtre (MF), Adaptif Uyumlu Filtre (AMF), Spektral Açık Eşleyici (SAM), Kısıtlı Enerji Minimizasyonu (CEM), Dikey Altuzay Projeksiyonu (OSP) ve Adaptif Bağdaşım Tahmincisi (ACE) yöntemleri hedef tespiti uygulamalarında kullanılan en klasik yöntemlerdir [4][5][6]. HSG'nin en çok kullanıldığı alanlardan biri de tehlikeli kimyasal maddelerin tespitidir. Bu kimyasalların tespitinde genellikle klasik hedef tespiti yöntemleri kullanılsa da, bunlardan ayrı olarak çeşitli makine öğrenmesi yöntemleri de kimyasal maddelerin tespiti için birçok kez kullanılmıştır [7].

Her kimyasal maddenin iç enerjisi farklı olduğundan kendine özgü bir elektromanyetik enerjisi vardır. Özellikle tehlikeli kimyasallar doğada az bulunan ve elde etmesi zor bileşenlerden meydana geldikleri için elektromanyetik enerjileri diğer maddelerden oldukça farklıdır. Bu özellik kimyasalların elektromanyetik enerjilerinin incelenmesini ve türünün belirlenmesini mümkün kılmıştır [8]. Kimyasal maddelerin elektromanyetik enerjisinin HSG ile toplanması pasif algılama olarak yapılabilir gibi, Diferansiyel Reflektometri (DR) adı verilen bir teknikte aktif algılama olarak da yapılabilir. DR maddenin spektral boyuttaki özelliklerini iyileştirmek ve spektral imzasını daha belirgin hale getirmek amacıyla kullanılan bir yöntemdir. DR'de incelenecek maddeye görünür ışık veya morötesi ışık gönderilir ve yansıyan ışınlar bir hiperspektral kamera tarafından toplanarak bilgisayara iletilir. Bilgisayarda ardışık iki pikselin elektromanyetik enerjileri arasındaki normalize edilmiş fark hesaplanır ve maddenin Diferansiyel Yansıma Spektrumu oluşturulur. Diferansiyel Yansıma Spektrumu

özellikle tehlikeli kimyasalların ayırt edilmesini kolaylaştırır. Bu yüzden patlayıcı ve uyuşturucu gibi maddelerin tespitinde kullanılması önemli avantajlar sağlar. Bundan dolayı DR kimyasal maddelerin tespitinde önemli bir ön işleme adımı haline gelmiştir [2][9][10].

Hiperspektral görüntülerde hedef tespiti teknolojisi her geçen gün gelişmekte ve kullanımı yaygınlaşmaktadır. Ancak tehlike oluşturacak kimyasal maddelerin çeşitliliğinin gitgide artması, daha az miktardaki kimyasallarla tehlikeli durumların oluşma ihtimalinin artması ve kimyasalların taşınma şeklinin sürekli değişmesi mevcut algoritmaların süreç içinde verimsiz hale gelmesine neden olmuştur. Bu durumun üstesinden gelmek amacıyla makine öğrenmesinin alt dallarından biri olan, verilerdeki en küçük detayları bile algılayabilen derin öğrenme tekniği kullanılmaya başlanmıştır. Derin öğrenme görüntü sınıflandırma, nesne tanıma, görüntü bölütleme, çeviri yapma, konuşma tanıma, görüntü üretme, metin üretme, hareket tahmini gibi birçok alanda kullanılmasının yanı sıra uzaktan algılama ile hedef tespiti uygulamalarında da sık sık kullanılır [11][12]. Hiperspektral görüntülerde hedef tespiti için Evrişimsel Sinir Ağları (ESA), Tekrarlayan Sinir Ağları (TSA), Uzun Kısa Süreli Bellek (UKSB), Sınırlı Boltzman Makineleri (SBM) ve Oto-Kodlayıcılar en çok kullanılan derin öğrenme modelleridir [13].

Özellikle görüntü ve video gibi verilerde başarısını kanıtlamış, en popüler derin öğrenme modeli olan Evrişimsel Sinir Ağı modeli, hiperspektral görüntülerdeki çeşitli hedeflerin tespiti için birçok alanda kullanılmıştır. ESA modelleri görüntülerdeki birçok detayı öğrenerek görüntü içerisindeki maddeleri sınıflandırmada oldukça başarılıdır. Bundan dolayı spektral ve uzamsal boyutta birçok bilgi içeren hiperspektral görüntülerin sınıflandırılmasında ESA'lardan büyük verim alınmıştır [14]. ESA'ların bu özellikleri onları hiperspektral görüntülerdeki kimyasal hedeflerin tespiti için uygun kılmıştır.

Tıpkı ESA modelleri gibi UKSB modelleri de son dönemlerde hiperspektral görüntülerin sınıflandırılmasında sıklıkla kullanılmıştır. Genellikle ses ve metin gibi tek boyutlu verilerle çalışan UKSB modelleri, hiperspektral görüntülerdeki piksellerin tek boyutlu spektrumlarını kullanarak sınıflandırma işlemini gerçekleştirir. UKSB'nin ses ve metin üzerinde başarılı bir şekilde işleyen uzun süreli hafıza yapısının, yüzlerce bantta bilgi içeren spektrumlar

üzerinde de başarı ile çalıştığı görülmüştür [15]. Tehlikeli kimyasalların spektrumlarının ayırt edici birçok bilgi içerdiği düşünüldüğünde, UKSB modelleri kimyasal hedef tespitinde kullanılabilir bir yöntem haline gelmiştir.

ESA ve UKSB modelleri birçok alanda kullanılmış olsa da, hiperspektral görüntülerde kimyasal maddelerin tespiti için sık rastlanan yöntemler değildir. Literatürde pek örneği bulunmadığından, tehlikeli kimyasal maddelerin ESA ve UKSB modelleri ile tespit edilebilirliği süregelen ve dikkat çekici bir araştırma konusudur. Bu tez kapsamında, çeşitli ESA ve UKSB modellerinin, hiperspektral görüntülerdeki kimyasal maddelerin tespitindeki başarımı incelenmiştir. Bu yaklaşımla hazırlanan bir düzenek ile hiperspektral görüntüler toplanmış, toplanan görüntüler derin öğrenme modellerine beslenmeden önce Diferansiyel Reflektometri işleminden geçirilmiştir. DR'den sonra spektral boyuttaki gürültüden kurtulmak amacıyla basit bir filtreleme uygulanmıştır. Son olarak, hazır hale gelen spektral veriler derin öğrenme modellerine beslenmiştir. Yapılan testler ile en uygun modeller, parametreler kümeleri, ön işleme ve son işleme adımları incelenmiş ve farklı algoritmaların avantaj ve dezavantajları analiz edilmiştir.

## **1.1 Tezin Amacı**

Bu tez çalışmasında gerçeğe en yakın verilerle çalışmak amacıyla Diferansiyel Reflektometri yöntemini kullanan bir Hiperspektral Görüntüleme sistemi ile toplanan verilerden bir veri kümesi oluşturulmuştur. Bu veri kümesi kullanılarak farklı türdeki, farklı miktardaki ve farklı arka plan üzerindeki kimyasallar yüksek performanslı ESA ve UKSB modelleri oluşturularak tespit edilmeye çalışılmıştır. Oluşturulan modeller ile kimyasal maddelerin türünün, miktarının ve arka planın hedef tespitine olan etkisi gözlenlenmiştir. Birçok model, parametre kümesi, ön işleme ve son işleme yöntemleri denenerek en iyi algoritmanın bulunması amaçlanmıştır. Geliştirilen algoritmanın güvenlik noktalarında kurulan sistemlere entegre edilmesi, patlayıcı ve uyuşturucu gibi tehlikeli kimyasalların başarılı bir şekilde erken tespit edilmesi ve bu sayede yaşanacak problemlerin önüne geçilmesi amaçlanmıştır.

## 1.2 Tezin Akışı

Bu tez raporunda 1. Bölüm’de tezde kullanılan Uzaktan Algılama, Hiperspektral Görüntüleme, Diferansiyel Reflektometri, Evrimsel Sinir Ağları ve Uzun Kısa Süreli Bellek gibi kavramlar kısaca tanıtılmış ve tezin amacı anlatılmıştır. 2. Bölüm’de hiperspektral görüntülerde derin öğrenme teknikleri kullanılarak yapılan çeşitli araştırmalardan ve çalışmalardan bahsedilmiştir. 3. Bölüm’de kullanılan veri kümesinin oluşturulması, özellikleri ve boyutları tanıtılmıştır. Ayrıca ön işleme aşamalarının matematiksel tanımları verilmiştir. 4. Bölüm’de sinir ağlarının çalışma prensipleri, yapay sinir ağlarında kullanılan yöntemler ve kavramlar, ESA, TSA ve UKSB mimarileri hakkında teorik bilgiler verilmiştir. 5. Bölüm’de bu tez kapsamında oluşturulan ESA ve UKSB modellerinin mimarileri ve parametreleri aktarılmıştır. 6. Bölüm’de geliştirilen modellerin ürettikleri sonuçlar ve performansları verilmiştir. Bu sonuçların başarılı veya başarısız olmalarının nedenleri ve çözümleri incelenmiştir. Son olarak 7. Bölüm’de ise yapılan çalışmalar değerlendirilmiş ve tez çalışmasının katkıları vurgulanmıştır.

## 2. HİPERSPEKTRAL GÖRÜNTÜLERİN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI

Hiperspektral görüntülerin sınıflandırılmasında birçok derin öğrenme yöntemi kullanılmıştır. En sık kullanılan yöntemler Evrişimsel Sinir Ağı ve Tekrarlayan Sinir Ağı modelleri olsa da, seyrek olarak Oto-Kodlayıcılar ve Derin İnanç Ağı modelleri de kullanılmıştır. Kullanılan modellerin bazıları sadece spektral veya sadece uzamsal bilgiyi kullanırken, bazıları da spektral ve uzamsal bilgiden birlikte faydalanmıştır. Bu bölümde hiperspektral görüntülerin sınıflandırılmasında kullanılan derin öğrenme yöntemleri, bu yöntemlerin uyguladıkları özgün algoritma ve teknikler, girdi verilerini modellere besleme şekilleri ve elde ettikleri sonuçlar aktarılacaktır.

Sadece spektral bilgiyi kullanan basit ESA modellerinden biri [16]'da ele alınmıştır. Genellikle görüntü verisini sınıflandırmak için kullanılan ESA modelleri, bu çalışmada nesnelere spektral imzalarına bakarak bu nesnelere sınıflandırmak amacıyla kullanılmıştır. Eğitim verisinin sayısı az olduğu için nispeten küçük olan 5 katmanlı bir ESA mimarisi tasarlanmıştır. Sonuçta, önerilen model üç farklı veri kümesini üzerinde kendinden önceki destek vektör makinesi ve diğer geleneksel derin öğrenme modellerine göre daha iyi performans göstermiştir. Bu çalışmadan ilham alınarak geliştirilen [17]'de, spektral ve uzamsal bilgiyi birlikte kullanan 5 katmanlı bir ESA mimarisi önerilmiştir. Veri sırasıyla girdi katmanına, evrişimsel katmana, yığın normalizasyonu katmanına, tam bağlı katmana ve çıktı katmanına iletilmektedir. Spektral bilginin tek başına kullanılmasının yanı sıra komşuluk yöntemiyle spektral ve uzamsal bilgiler birleştirilerek, modelin performansındaki artış gözlemlenmiştir. Örnek pikselin spektral bilgisi belirli komşuluğundaki piksellerin ortalaması veya standart sapması hesaplanarak elde edilmiştir. Bu sayede uzamsal bilgiden de faydalanılmıştır. Önerilen modelde aktivasyon fonksiyonu olarak parametrik rektifiye doğrusal birim fonksiyonu kullanılmış ve hiperbolik tanjant fonksiyonuna göre eğitimin daha hızlı olduğu gözlemlenmiştir. Ayrıca aşırı uyum sorununu önlemek için bırakma katmanı ile tam bağlı katman birlikte kullanılmıştır. Sonuçta, sadece spektral veri ile çalışan model geleneksel DVM ve ESA modellerinin performansını geçmiştir. Uzamsal ve spektral bilgi birleştirilerek oluşturulan



model ise gelişmiş ESA modellerinin performansının üstüne çıkmıştır. He ve arkadaşlarının çalışması [18]'de ortalama ve standart sapma gibi bilgilerden, daha değerli olabilecek kovaryans bilgisi ele alınmıştır. Bu çalışmada hiperspektral görüntülerin uzamsal ve spektral boyutlarından en fazla verimi alabilmek için öznitelik çıkarımı yapılırken çok ölçekli kovaryans haritaları kullanılmıştır. Bu yöntemin avantajlarından biri, belirli bir komşuluktaki piksellerin spektral bilgilerinin kovaryansları hesaplanarak bir kovaryans haritasına yazılıp girdi verisinin oluşturulmasıdır. Böylece uzamsal ve spektral bilgi birleştirilmiştir. Diğer bir avantaj ise, eğitim verileri farklı ölçeklerde elde edilerek modele beslendiği için her eğitim verisi için sağlanan bilginin artırılmasıdır. Kovaryans verileri hesaplanmadan gürültüyü ve hesap yükünü azaltmak amacıyla Maksimum Gürültü Oranı adı verilen bir boyut azaltma tekniği uygulanmıştır. Daha sonra bir pencere içerisindeki spektral vektörlerin kovaryansları hesaplanarak örnek piksel için bir kovaryans haritası oluşturulmuştur. Bu haritalar çok ölçekli strateji kapsamında farklı pencere boyutları için üretilmiştir. Daha sonra bir piksel örneğinin her bir kovaryans haritası için sınıflandırma yapılmıştır. Çoğunluk oylaması yapılarak örnek pikselin sınıfına karar verilmiştir. Bu çalışmada çok ölçekli kovaryans haritalarının ESA'ların sınıflandırma performanslarını standart tekniklere ve geleneksel ESA modellerine göre önemli ölçüde arttırdığı görülmüştür. Du ve arkadaşlarının yayınladığı [19]'da ise uzamsal bilgiden faydalanmak için ortalama, standart sapma ve kovaryans gibi istatistiksel bilgiler yerine, çevre piksellerin spektral verileri Çıkarma Yöntemi adı verilen bir yöntemle modele dahil edilmiştir. Burada Çıkarma Yöntemi ile eğitim verisinin sayısının artırılması da amaçlanmıştır. Çıkarma Yöntemi'nde yapılan işlemde hedef ve arka plan piksellerinin birbirinden çıkarılmasıyla oluşan yeni piksele "1" etiketi verilmiştir, çıkarılan piksellerin ikisinin de aynı sınıfta olması durumunda ise yeni piksele "0" etiketi verilmiştir. Bu şekilde büyütülen yeni veri kümesi ile model eğitilmiştir. Daha sonra test edilen pikselin spektral verisi çevre komşuluğundaki sekiz pikselin spektral bilgisinden çıkarılarak sırayla modele beslenmiştir. Modelden çıkan sekiz sonucun ortalaması bir eşik değeriyle kıyaslanarak test edilen pikselin hedefe veya arka plana ait olduğu sonucu çıkarılmıştır. Sonuçta, önerilen ESA modelinin diğer tespit algoritmalarına göre bazı avantajları öne çıkmıştır. Diğer algoritmalar gürültünün az olduğu belirli bantlarda işlem yaparken, önerilen

ESA modeli gürültü bantlarını verimli bir bilgiye dönüştürerek kullanmıştır. Ayrıca modeldeki doğrusal olmayan eşleme yeteneğinin kullanılan veri kümesini öğrenmek için çok uygun olduğu gözlemlenmiştir. Li ve arkadaşlarının geliştirdiği [20]'de Transferli Derin Evrişimsel Sinir Ağı modeli önerilmiştir. Bu çok katmanlı ESA modelini eğitmek için çok fazla etiketli veriye ihtiyaç duyulduğundan, [19]'daki yöntemle benzer bir veri artırma yöntemi uygulanmıştır. Ancak genellikle hedef tespiti uygulamalarında fazla sayıda etiketli veri bulunmadığından, burada önerilen yöntem ile piksel çiftleri oluşturularak eğitim verilerinin sayısı artırılmıştır. Bu çalışmadaki ESA modeli piksel çiftlerinin arasındaki farklar kullanılarak eğitilmiştir. Piksel çiftleri iki türde oluşturulmuştur. Biri aynı sınıf arasından piksellerin birleştirilmesiyle benzerlik hesabı için kullanılmış ve "0" ile etiketlenmiş, diğeri de farklı sınıflardan piksellerin birleştirilmesiyle benzersizlik hesabı için kullanılmış ve "1" ile etiketlenmiştir. Birleştirilen pikseller arasındaki farklar ESA modeline beslenmiştir. Bu çalışmada anomali tespiti ve denetimli hedef tespiti için iki farklı model tasarlanmıştır. Anomali tespitinde test edilen piksel ve çevre komşuluğundaki piksellerin farkları ESA modeline direkt beslenirken, denetimli hedef tespitinde test edilen piksel ile örnek hedef pikselleri arasındaki farklar ESA modeline beslenmiştir. ESA'nın çıkışında test edilen piksel için tüm piksel çiftlerinin ürettiği benzerlik skorları çoğunluk oylaması ile değerlendirilmiş ve hedefin tipine karar verilmiştir. Sonuçta, oluşturulan model ile var olan anomali tespiti ve hedef tespiti algoritmalarının üzerine çıkılmıştır. Tıpkı [19]'da ve [20]'de yapıldığı gibi [21]'de de veri sayısını arttırmak ve modele beslemek için piksel çiftleri oluşturulmuştur. Az veri bulunan veri kümesindeki örnek sayısını arttırmak amacıyla yeniden etiketleme işlemi yapılmıştır. Bu işlemde piksel çiftleri oluşturulmuş ve çift oluşturan pikseller farklı sınıftansa "0", aynı sınıftansa o sınıfın etiketi verilmiştir. Bu sayede çok fazla eğitim verisi ihtiyacı ortadan kalkmıştır. Oluşturulan yeni eğitim kümesi için test edilen piksel ve komşuluğundaki diğer pikseller sırayla çift haline getirilip 10 katmanlı bir ESA'ya beslenmiştir. ESA'nın çıkışında softmax katmanı ile tüm sınıflar için olasılık hesaplanmıştır. Tüm komşuluklar için bir sınıf etiketi çıktı olarak elde edilmiştir. Çoğunluk oylamasıyla en yüksek sayıda çıkan sınıfa karar verilmiştir. Sonuçta, piksel çiftleri yönteminin klasik ESA'lara göre daha başarılı olduğu görülmüştür. Bu çalışmada piksel çiftleri hem veri kümesini büyütme hem de komşuluk bilgisini almak için kullanılmıştır. Böylece daha az parametre kullanılarak

hesaplama yükü azaltılmıştır.

Lee ve arkadaşlarının geliştirdiği [22]'de hiçbir aşağı örnekleme (havuzlama vb.) katmanı kullanılmadan sadece evrimsel katmanlardan oluşan 9 katmanlı özgün bir ESA mimarisi önerilmiştir. Bu mimaride aşağı örnekleme yapılmadığı için girdi verisi ile çıktı verisinin boyu aynı çıkmaktadır. Bu yüzden değişken boyutlu girdiler üzerinde de çalışabilen bir modeldir. Modele beslenen hiperspektral veriler Başlangıç Modülü adı verilen bir yapıyla  $1 \times 1$  ve  $3 \times 3$  boyutlu filtreler ile paralel olarak evrim işleminden geçirilir.  $1 \times 1$  boyutlu filtre ile spektral özniteliklerin çıkarılması,  $3 \times 3$  boyutlu filtre ile de uzamsal özniteliklerin çıkarılması amaçlanmıştır. Filtrelerin uygulanması sonucu oluşan öznitelik haritaları derinlik boyutunda arka arkaya eklenerek ortaklanmış öznitelik haritası oluşturulmuştur. Daha sonraki katmanlarda matematiksel karmaşayı azaltmak ve aşırı uyum ihtimalini düşürmek amacıyla Artık Öğrenme yapısı ve  $1 \times 1$  boyutlu evrim işlemleri uygulanmıştır. Geliştirilen modeldeki Başlangıç Modülü ve Artık Öğrenme yapısının az sayıda örnek içeren veri kümeleri için çok uyumlu olduğu görülmüştür. Bu yöntemler sayesinde az sayıda veri ile çok sayıda parametre oluşturulmuş ve aşırı uyum probleminin önüne geçilmiştir. Bundan dolayı bu çok katmanlı mimari klasik modellerden daha iyi performans sergilemiştir. Çoğu modelden farklı olarak [23]'te genellikle el yapımı öznitelikleri tespit eden geleneksel sınıflandırıcıların performanslarını iyileştirmek amacıyla her türlü özneliği tespit edebilecek [22]'deki Başlangıç Modülü'nün benzerini içeren bir ESA modeli önerilmiştir. Bu modelin en önemli özelliklerinden biri sıklıkla kullanılan  $3 \times 3$  ve  $5 \times 5$  boyutlu evrimsel filtrelerin yerine Basamaklı Çapraz Kanal Parametrik Havuzlama adı verilen  $1 \times 1$  boyutlu evrimsel filtreler kullanmasıdır. Bu sayede spektral boyuttaki bantlar arasındaki özniteliklerin tespit edilmesi amaçlanmıştır. Uzamsal özniteliklerin çıkarımı normalizasyon ve Global Ortalama Havuzlama yöntemleriyle sağlanmıştır.  $1 \times 1$  boyutlu filtreler ile  $3 \times 3$  boyutlu filtreler karşılaştırılmış, iki şekilde de iterasyon sayısı arttıkça eğitim kaybının sifıra yakınsadığı görülmüştür. Ancak  $3 \times 3$  boyutlu filtreleri içeren modelin iterasyon sayısı arttıkça test kaybının arttığı gözlemlenmiştir. Bu durumda aşırı uyum olduğu anlaşılmıştır. Bu yüzden  $1 \times 1$  boyutlu filtrelerin kullanımının aşırı uyum ihtimalini de ciddi şekilde azaltıp daha iyi bir genelleme yaptığı görülmüştür. Ayrıca aşırı uyumu engellemek için kullanılan veri artırma ve bırakma

katmanlı yöntemlerinin de performansı önemli ölçüde arttırdığı görülmüştür. Geliştirilen model ile az sayıda örnek içeren veri kümeleri için başarılı sonuçlar üreten bir ESA modeli oluşturulmuştur. Diğer çalışmalardan farklı olarak [24]'te modelin derinliğinin modelin performansına olan etkisine değinilmiştir. Bu çalışmada derin sinir ağı modellerinin derin öznitelikleri yüksek başarımlarıyla öğrendiğini ama bunun yanında modelin derinliği arttıkça performansının düştüğü göz önüne alınarak ESA modeline özdeşlik gönderimi yöntemi eklenerek Derin Artık Ağı (DAA) modeli oluşturulmuştur. Çalışmada katkı sağlanan üç konu; DAA'nın ve ESA'nın derinliklerinin ve genişliklerinin değişiminin performans üzerindeki etkisi, yığın normalizasyonu yönteminin etkisi ve öğrenilen özniteliklerin iki boyutlu uzayda gömme yöntemiyle görselleştirilmesi olmuştur. Sonuçta bütün modellere yığın normalizasyonu işlemi eklendiğinde daha yüksek performans ile sınıflandırma yapıldığı görülmüştür. Ayrıca daha derin katmanlı ESA modellerinin daha kötü sınıflandırma performansı gösterdiği görülmüştür. Bunun aksine DAA modelleri derinleştikçe performansı diğer modeller kadar düşmemiştir. Bu da DAA modellerinin ESA modellerine göre çok katmanlı olmaya daha dayanıklı olduğunu göstermiştir. Ayrıca öznitelikler bir uygulama yardımıyla görselleştirildiğinde DAA modellerinin karşılık gelen ESA modellerinin göre daha ayırt edici öznitelikleri öğrendiği görülmüştür.

Yapılan çalışmaların bir kısmında test pikselinin spektral bilgisi direkt olarak kullanılmış, başka bir kısmında ise uzamsal bilgidен de faydalanmak amacıyla test pikselinin spektral bilgisi, bazı istatistiksel yöntemlerle çevresindeki piksellerin spektral bilgileriyle harmanlanarak kullanılmıştır. Bunlardan farklı olarak bazı çalışmalarda ise spektral ve uzamsal bilgi iki ayrı modelde kullanılmış ve çıkarılan özniteliklerin sınıflandırma için birleştirilmesi amaçlanmıştır. Bu şekilde bir yapı içeren [25]'te az sayıda örnek içeren bir veri kümesi üzerinde normal öğrenme yöntemi ile transferli öğrenme yöntemini karşılaştırmak amacıyla bir kanallı spektral bilgidен, diğer kanallı uzamsal bilgidен öznitelik çıkarımı yapan iki kanallı bir ESA modeli kullanılmıştır. İki kanalda elde edilen öznitelik vektörleri arka arkaya eklenerek tam bağı katmana beslenmiş ve ortaklanmış spektral-uzamsal özniteliklerin çıkarılması sağlanmıştır. Model önce bir veri kümesiyle eğitilmiş ve ağırlıkları kaydedilmiştir. Daha sonra çok daha az eğitim verisi için iki farklı öğrenme yöntemiyle eğitim yapılmıştır.

Önce model rastgele Gaussian dağılım ile ilklendirilerek eğitilmiştir. Sonra, modelin ilk ve orta katmanlarının ağırlıkları daha önce kaydedilen ağırlıklar transfer edilerek kullanılmış ve modelin sadece son katmanları eğitilmiştir. Rastgele Gaussian dağılım ile ilklendirilerek oluşturulan normal öğrenme yöntemi klasik makine öğrenmesi yöntemlerinden çok daha iyi performans gösterse de, daha önce başka bir veri kümesinde eğitilmiş ağırlıkların kullanılmasıyla oluşturulan transferli öğrenme yöntemi normal öğrenme yönteminin de önüne geçmiştir. Bu da ilk ve orta katmanlarda öğrenilen bilgilerin daha genel ve çok ayrıntı içermeyen bilgiler olduğunu bu yüzden de farklı veri kümeleri üzerinde başarılı sonuç üretmesine katkı sağladığını göstermektedir. Ayrıca eğitim verisindeki örnek sayısı arttırıldığında hem normal öğrenme yönteminin hem de transferli öğrenme yönteminin performansının arttığı gözlemlenmiştir. Ancak eğitim verisindeki örnek sayısı belirli bir seviyeden fazla olduğunda normal öğrenme yöntemi yeterli bilgiyi öğrenerek transferli öğrenme yönteminin önüne geçmiştir. Bu da transferli öğrenme yönteminin az sayıda veri içeren veri kümelerinde kullanımını rasyonel hale getirmiş ve etkisini kanıtlamıştır. Jiang ve arkadaşlarının [26]'daki çalışmasında Çok Katmanlı Perceptron modeli, tek boyutlu ESA modeli, iki boyutlu ESA modeli ve [25]'teki gibi spektral ve uzamsal bilgileri ayrı ayrı işleyen iki ESA modelinin birleşiminden oluşan bir füzyon modeli oluşturulmuş ve hiperspektral verilerin sınıflandırmasındaki performansları karşılaştırılmıştır. Çok Katmanlı Perceptron ve tek boyutlu ESA modelleri girdi verisi olarak bir pikselin spektral bantlarındaki bilgiyi direkt kullanırken, iki boyutlu ESA modeli bir pikselin belirli komşuluğundaki piksellerden oluşturulan üç boyutlu pencereleri girdi verisi olarak kullanmıştır. Füzyon modeli için tek boyutlu ESA modelinde ve iki boyutlu ESA modelinde ayrı ayrı evrimsel katmanlarla öznitelik çıkarımı yapılmıştır. Çıkarılan öznitelikler tam bağlı katmanlara iletilmiş ve bu katmanlar füzyon modeli içerisinde uç uca eklenerek birleştirilmiştir. Sonuçta, tek boyutlu ESA modelinin spektral bantlardaki yakın ve uzak korelasyonları Çok Katmanlı Perceptron modelinden daha iyi algıladığı görülmüştür. İki boyutlu ESA modelinin performansının tek boyutlu ESA modelinden iyi olmasının sebebi uzamsal özniteliklerin modele dahil edilmesine bağlanmıştır. Füzyon modelinin hepsinden iyi olmasının sebebi spektral ve uzamsal bilgiyi ayrı ayrı öğrenerek sınıflandırmayı bu bilgilerin birleşimi üzerinden yapması olarak gözlenmiştir.

Spektral ve uzamsal bilginin ayrı ayrı modellerde kullanılarak çıkarılan özniteliklerin birleştirilmesi ESA'dan farklı derin öğrenme modelleri ile denenmiştir. Chen ve arkadaşlarının [27]'de önerdiği yöntem iki farklı derin öğrenme konseptinin birleştirilmesiyle oluşmuştur. Birinde denetimsiz derin öğrenme modellerinde öznitelik çıkarmak amacıyla kullanılan Oto-Kodlayıcı modeline odaklanılmıştır. Diğerinde ise Temel Bileşen Analizi yöntemini kullanarak uzamsal boyutta öznitelik çıkarımı yapılmıştır. Hem sığ hem derin spektral öznitelikleri çıkarmak amacıyla çok katmanlı Yığılı Oto-Kodlayıcı kullanılmıştır. Temel Bileşen Analizi sadece uzamsal bilgiye odaklanacağından birkaç bileşen çıkaracak şekilde tasarlanmıştır. Temel Bileşen Analizi'nin sonucunda oluşan verideki bir pikselin belirli çevredeki komşuluğu vektör haline getirilmiştir. Bu vektörün ucuna o pikselin spektral bilgisi eklenmiştir. Daha sonra tüm pikseller için bu işlem tekrarlanmış ve oluşan vektörler yan yana eklenerek bir matris oluşturulmuştur. Bu matris Oto-Kodlayıcı'ya girdi olarak beslenmiştir. Oto-Kodlayıcı işlediği veriyi ince ayar yapılması için lojistik regresyon katmanına aktarmıştır. Sonuçta, önerilen spektral-uzamsal hibrit modelin sadece spektral veya sadece uzamsal bilgiyi kullanan modellere göre çok daha başarılı olduğu görülmüştür. Spektral modele eklenen uzamsal bilgi modelin performansını ciddi biçimde yükseltmiştir. Önerilen model modern modellerle kıyaslandığında istatistiksel olarak çok daha başarılı olduğu görülmüştür. Yine Chen ve arkadaşları [28]'de aynı yapıyı Oto-Kodlayıcı yerine Sınırlı Boltzmann Makinesi (SBM) ve Derin İnanç Ağı (DİA) modellerini birlikte kullanılarak tasarlanmıştır. Birkaç SBM'nin birleşiminden oluşturulan DİA modeli derin özniteliklerin çıkarımı için kullanılmıştır. Bu çalışmada kullanılan hiperspektral görüntülerde öznitelik çıkarımı için ilk kez DİA modeli kullanılmıştır. Spektral, uzamsal ve spektral-uzamsal öznitelikler için üç farklı DİA modeli önerilmiştir. Spektral bilgiyi kullanan modele girdi olarak bir pikselin tek boyutlu spektral verisi beslenmiştir. Beslenen veri DİA'da öznitelik çıkarımı işleminden geçtikten sonra sınıflandırılmak için lojistik regresyon katmanına iletilmiştir. Uzamsal veriyi kullanan modelde öncelikle Temel Bileşen Analizi yöntemiyle hiperspektral verinin boyutları küçültülmüştür. Ardından veriden iki boyutlu komşuluk bölgesi seçilmiştir. Seçilen bölge düzleştirilerek tek boyutlu hale getirilmiştir. Son olarak tek boyuta indirgenen veri, spektral modeldeki gibi öznitelik çıkarımı için DİA modeline, ardından sınıflandırma amacıyla lojistik regresyon katmanına iletilmiştir. Spektral-uzamsal bilgileri kullanan model için bir

pikselin tek boyutlu spektral verisinin ucuna düzleştirilerek tek boyuta indirgenen uzamsal veri eklenerek DİA ve lojistik regresyon katmanlarına sırayla beslenmiştir. Önerilen üç mimarinin de standart SVM'lerden daha başarılı olduğu görülmüştür. Ancak spektral-uzamsal hibrit model en başarılı model olarak, spektral ve uzamsal bilginin birlikte kullanımının önemini vurgulamıştır.

Hiperspektral görüntülerin sınıflandırılmasında kullanılan başka bir derin öğrenme yöntemi ise Tekrarlayan Sinir Ağı (TSA) modelidir. Çeşitli TSA modelleri özellikle son yıllarda hiperspektral veriler üzerinde sıklıkla kullanılmıştır. Daha önceki çalışmalardan [15]'teki spektral verilerin dizi şeklinde olması göz önüne alınmış, dizi şeklindeki verilerin sınıflandırılmasında genellikle ESA'lardan daha iyi performans gösteren TSA modeli ilk kez hiperspektral verilerin sınıflandırılması için kullanılmıştır. TSA modelindeki tekrarlayan yapının spektral korelasyonu ve bantlar arası çeşitliliği iyi bir şekilde ayırt edeceği düşünülmüştür. Ayrıca kaybolan gradyan sorununu çözmek için sıradan bir TSA yerine Geçitli Tekrarlayan Birim (GTB) ve Uzun Kısa Süreli Bellek (UKSB) adları verilen daha gelişmiş TSA türevleri kullanılmıştır. Bu çalışma kapsamında GTB modelinin performansının UKSB modelinin performansından iyi olduğu görülmüştür. Ek olarak geliştirilen GTB modelinde, TSA'larda sıklıkla kullanılan hiperbolik tanjant (tanh) aktivasyonu yerine parametrik düzeltilmiş hiperbolik tanjant (PRetanh) aktivasyonu kullanılarak performans daha da iyileştirilmiştir. Spektral ve uzamsal özniteliklerin iki ayrı model ile elde edilip, daha sonra tam bağlı katman aracılığıyla [29]'da ise hiperspektral görüntüleri sınıflandırmak amacıyla, daha önce kullanılan ESA, Oto-Kodlayıcı ve DİA modellerine benzer olarak spektral ve uzamsal bilgiyi ayrı ayrı kullanan iki UKSB modeli tasarlanmıştır. Farklı özelliklerdeki iki girdi verisi spektral ve uzamsal boyutları çıkarmak için aynı mimariden oluşan iki UKSB modeline beslenmiştir. Birinde spektral bilgi vektör halinde spektral UKSB modeline beslenmiştir. Diğerinde ise Temel Bileşen Analizi yöntemiyle spektral bantların sayısı bire düşürülmüş ve tek bantta iki boyutlu sadece uzamsal bilgi içeren görüntü elde edilmiştir. Bu görüntünün belirli komşuluktaki bölgeleri alınıp vektör haline getirilerek uzamsal UKSB modeline beslenmiştir. Bu iki modelin son katmanlarından çıkan olasılık değerleri ağırlıklandırılarak toplanmış ve sınıf tahmini bu değere göre yapılmıştır. Geliştirilen model sadece spektral bilgiyi


veya sadece uzamsal bilgiyi işleyen yöntemlerle karşılaştırılmıştır. Sonuçta, karşılaştırılan bütün modellerden daha iyi bir sonuç elde edilerek spektral ve uzamsal bilginin birlikte kullanılmasının avantajları ortaya koyulmuştur. Xu ve arkadaşlarının çalışması [30]'da da spektral ve uzamsal bilgileri aynı anda işleyen Spektral-Uzamsal Bütünleştirilmiş Ağ (SUBA) adı verilen bir model oluşturulmuştur. Bu modelde aynı anda bir UKSB modeli ile spektral öznitelik çıkarımı ve bir ESA modeli ile uzamsal öznitelik çıkarımı yapılmaktadır. Bu çalışmada spektral bilgi klasik Oto-Kodlayıcı ve Derin İnanç Ağı modellerindeki gibi tüm bantları içerecek şekilde değil, bağlamsal bilgiden faydalanmak için özgün bir gruplama algoritmasıyla gruplanarak UKSB modeline beslenmiştir. Oluşturulan gruplar farklı zaman damgalarıyla UKSB mimarisine beslenmiştir. UKSB katmanında çıkarılan öznitelikler tam bağlı katmana iletilmiştir. ESA modeline beslenen veri ise hiperspektral veriye temel bileşen analizi uygulandıktan sonra belirli bir komşulukta alınan veriler ile oluşturulmuştur. ESA mimarisinde her havuzlama katmanından sonra tam bağlı katman kullanılmıştır. Bu tam bağlı katmanlar ESA mimarisinin sonundaki tam bağlı katmanın ucuna eklenmiştir. Böylece sığ ve derin öznitelikler birleştirilmiştir. Daha sonra iki modelin sonundaki tam bağlı katmanlar da uç uca eklenerek sınıflandırma için en son çıktı katmanına iletilmiştir. Önerilen gruplama yöntemi ile daha derin mimarilere olan ihtiyaç ortadan kaldırılmıştır. Ayrıca ESA mimarisindeki tam bağlı katmanlar sayesinde sığ ve derin öznitelikler daha derin bir mimariye ihtiyaç duyulmadan öğrenilmiştir. Geliştirilen SUBA modelinin geleneksel derin öğrenme modellerinden daha iyi olduğu gözlemlenmiştir. Ayrıca sadece spektral öznitelikleri öğrenen UKSB modelinin ve sadece uzamsal öznitelikleri öğrenen ESA modelinin performanslarının önüne geçilmiştir. Bu da spektral ve uzamsal bilginin birlikte kullanılmasının etkisini kanıtlamıştır.



### 3. VERİ KÜMESİNİN İNCELENMESİ VE ÖN İŞLEME AŞAMALARI

Bu bölümde ilk olarak, bu tez kapsamında kullanılan veri kümesinin toplanişı, boyutları ve özellikleri hakkında bilgiler verilmiştir. İkinci olarak, dengesiz veri kümesiyle öğrenmede kullanılan terminolojiden bahsedilmiş ve kullanılan değerlendirme ölçütleri verilmiştir. Son olarak, ön işleme aşamasında uygulanan Diferansiyel Reflektometri ve Savitzky-Golay filtreleme işlemlerinin teorik temelleri açıklanmıştır.

#### 3.1 Verilerin Toplanması



ŞEKİL 3.1: Hiperspektral verileri toplamak için kurulan düzenek.

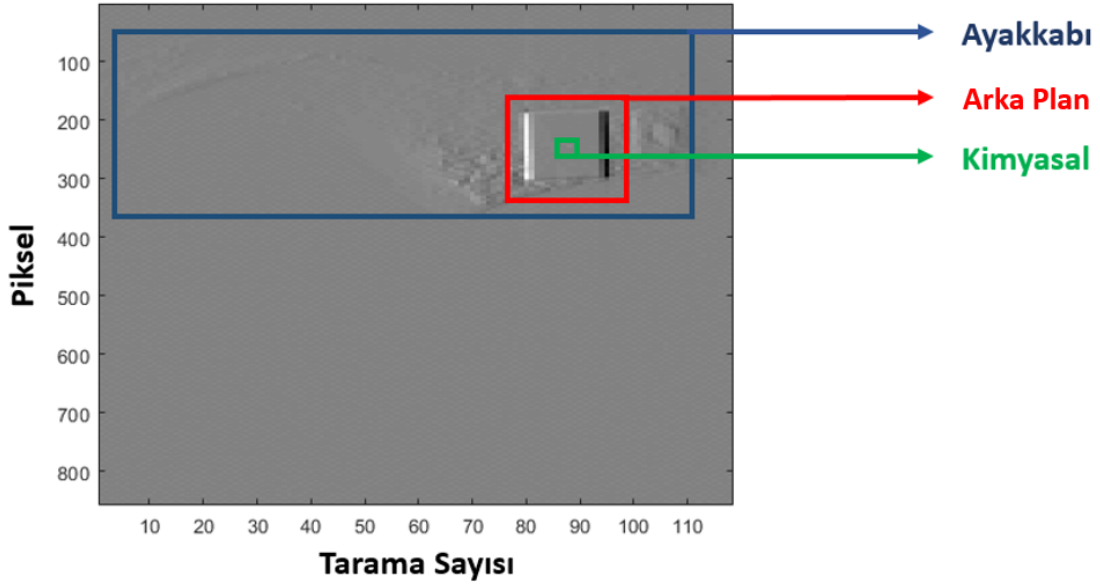
Bu tez kapsamında kullanılan hiperspektral görüntüler Şekil 3.1'deki düzenek aracılığıyla toplanmıştır. Verileri toplamak için ilk gereken şey morötesi ve görünür bantlarda ışık yayan bir ışık kaynağıdır. Bu ışık kaynağı ince bir çizgi halindeki morötesi veya görünür ışığı hareketli iletim bandı üzerindeki bir nesnenin yüzeyine gönderir. Yüzeyden yansıyan ışık bir spektrograf yardımıyla toplanır ve kırılır. Ardından ışığın yansıma değeri yük bağlaşımlı bir kamera ile kaydedilir. Kaydedilen değerler daha sonra algoritmada kullanılmak üzere bilgisayara iletilir [10].

Bu çalışmada kullanılan ışık kaynağı 200 nm ile 500 nm arasındaki dalga boylarında ışık saçan bir kaynaktır. Kaynaktan yayılan ışık nesnelere yüzeyinden yansıdıktan sonra spektrografta 548 farklı spektral bant için bilgi sağlar. Bu da toplanan görüntülerin spektral boyutunda 548 değer olması anlamına gelir.

Işık kaynağından gönderilen çizgi halindeki hüzmeye tarama alanı denir. Işık kaynağı sabit tutulup iletim bandı kaydırılarak birçok farklı tarama alanı üzerinden geçilir. Tarama bantları sırayla yan yana koyularak hiperspektral görüntü elde edilir. Oluşan hiperspektral görüntünün uzamsal boyutları tarama alanının boyu (piksel sayısı) ve tarama sayısına bağlıdır. Her tarama alanı 858 piksel içermektedir. Tarama sayısı iletim bandının akış hızına ve geçen süreye bağlıdır. Bu yüzden tüm örnekler için farklı olabilmektedir. Her örnek için değişebilen tarama alanı sayısı  $N$  olarak ifade edilirse, bir hiperspektral görüntü  $858 \times N \times 548$  boyutundadır.

Veri kümesini mümkün olduğunca gerçek şartlara benzetmek amacıyla bir ayakkabı ve farklı türde arka plan materyalleri kullanılmıştır. Dörtgen şeklindeki bir arka plan materyali ayakkabının belirli bir bölümüne yapıştırılmıştır. Hedef veriler üretilirken kimyasallar bu arka plan materyalinin ortasına yerleştirilmiş ve veriler toplanmıştır. Hedef veri için hazırlanmış Şekil 3.2'deki tarama örneğinin 300. spektral bandında ayakkabı, arka plan materyali ve kimyasal maddenin pozisyonları gösterilmiştir. Arka plan verileri üretilirken arka plan materyalinin üzerine hiçbir hedef koyulmamıştır. Ayakkabı ilgili veri örneği için hazır hale getirildiğinde iletim bandı üzerinde ayakkabının tümünün taranması sağlanmıştır. Bu tarama sayesinde hiperspektral görüntü oluşturulmuştur.

Bu çalışmada derin öğrenme modeline her pikselin spektral bilgisi besleneceği için toplanan hiperspektral görüntülerin uzamsal boyutlarındaki tüm piksellerine etiketleme uygulanmıştır. Kimyasal maddelerin koyulduğu pikseller (hedef pikseller) "1", bu piksellerin haricindeki tüm pikseller (arka plan pikseller) "0" olarak etiketlenmiştir. Eğitim veya test aşamasında bir pikselin "1" sonucunu üretmesi "hedef var", "0" sonucunu üretmesi ise "hedef yok" anlamına gelmektedir.

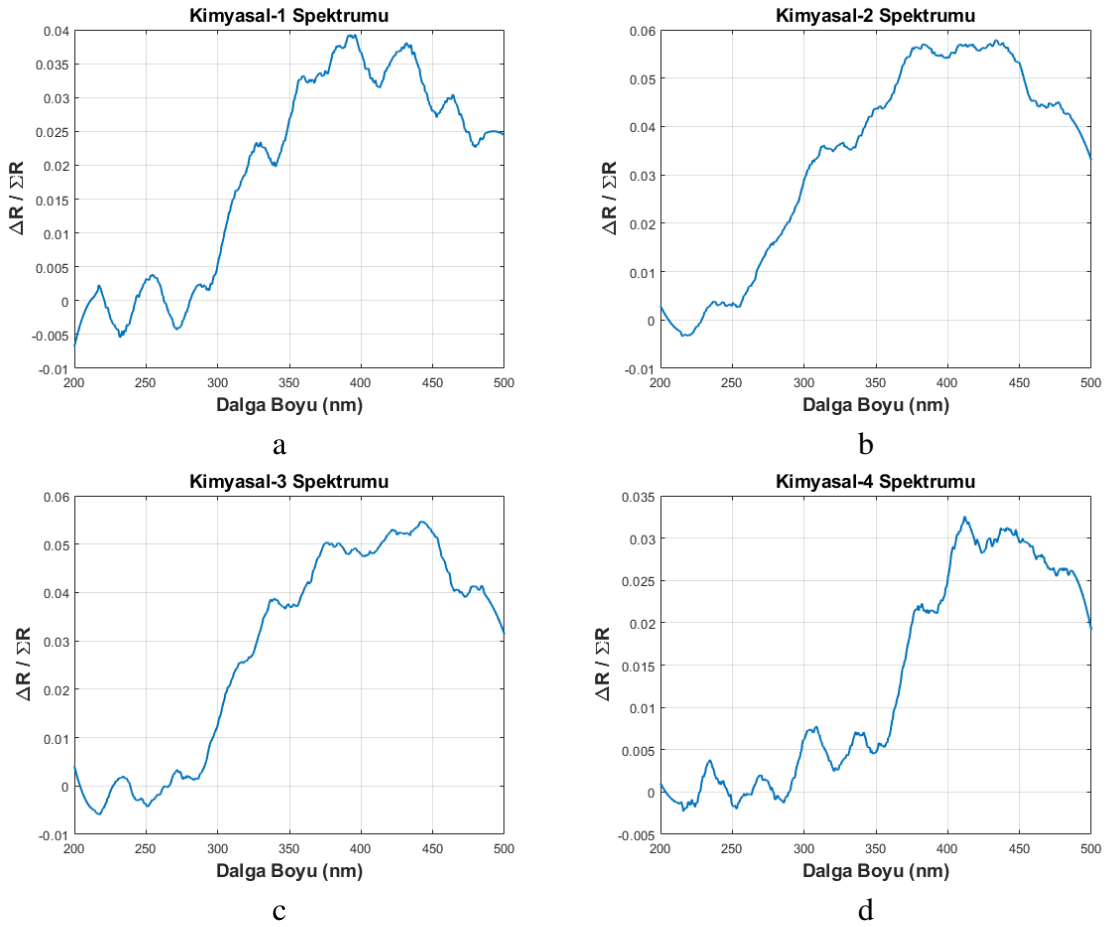


ŞEKİL 3.2: Veri kümesindeki rastgele bir hiperspektral görüntünün 300. bandından alınan görsel üzerindeki ayakkabı, arka plan ve kimyasalın pozisyonları.

### 3.2 Veri Kümesinin Tanımı ve Boyutları

Bu çalışmada hedef tespiti için kullanılacak dört farklı kimyasal madde ve dört farklı arka plan materyali vardır. Bu durumun kolay anlaşılması için bundan sonraki bölümlerde kimyasal maddelerden Kimyasal-1, Kimyasal-2, Kimyasal-3 ve Kimyasal-4 olarak, arka plan materyallerinden ise Arka Plan-1, Arka Plan-2, Arka Plan-3 ve Arka Plan-4 olarak bahsedilecektir. Her kimyasal için farklı eğitim kümeleri toplanmış ve farklı derin öğrenme modelleri geliştirilmiştir. Ayrıca her kimyasal için eğitim kümesi toplanırken tüm arka planlar kullanılmıştır. Bu tez kapsamında kullanılan kimyasal maddeler zorlayıcı arka planlar üzerinde tespit edilmeye çalışılmıştır. Geliştirilen modellerin çeşitli arka plan materyalleri üzerinde kimyasal hedefleri mümkün olduğunca doğru tespit etmesi amaçlanmıştır. Derin öğrenme modelleri kimyasal maddelerin spektral bilgisini dikkate alacağından bu kimyasalların spektrumlarındaki ayırt edici özellikler önem arz etmektedir. Şekil 3.3'te dört kimyasalın da ideal koşullara en yakın örnek spektrumlarının Diferansiyel Reflektometri uygulandıktan sonraki halleri (Diferansiyel Yansıma Spektrumları) gösterilmiştir. Bu grafiklerden yola

çıkarak yansıtılan ışığa karşı dört kimyasal maddenin de spektrumunda oluşan “soğurum kenarı” rahatça ayırt edilebilir. Soğurum kenarı, bir maddenin elektromanyetik radyasyon ile bir enerji seviyesinden başka bir enerji seviyesine geçerken yansıma spektrumundaki belirli dalga boylarında çok keskin bir yükseliş veya düşüş yapması durumudur. Kimyasal-1, Kimyasal-2, Kimyasal-3 ve Kimyasal-4 için soğurum kenarları sırasıyla 300-350 nm, 250-300 nm, 300-350 nm ve 300-400 nm dalga boyu civarlarında görülmektedir. Ancak kimyasal maddeler buldukları hiperspektral görüntüde bir piksel içerisinde herhangi bir arka plan materyali ile birleşerek soğurma yapacağından, bu soğurma kenarlarında kaymalar veya bozulmalar meydana gelmiştir. Arka plan materyalleri de kendi yansıma değerleri ile kimyasalların spektrumuna etki etmiştir.



ŞEKİL 3.3: Hedef olarak kullanılan dört kimyasal maddenin Diferansiyel Reflektometri işlemi sonrasındaki ideal spektrumlarının ve soğurum kenarlarının gösterimi. a) Kimyasal-1 spektrumu, b) Kimyasal-2 spektrumu, c) Kimyasal-3 spektrumu, d) Kimyasal-4 spektrumu.

Toplanan hiperspektral görüntülerde etiketlenen hedef piksel sayısının arka plan piksel sayısına oranı çok küçüktür. Bu oran ortalama 1:10000 civarındadır. Bu yüzden eğitim kümeleri oluşturulurken hedef piksellerin hepsi eğitim kümesine alınmış, ancak arka plan pikselleri seçilerek alınmıştır. Sonuçta tüm eğitim kümeleri için hedef piksel sayısının arka plan piksel sayısına oranı yaklaşık olarak 1:10 olarak ayarlanmıştır. Arka plan pikselleri en fazla arka plan materyallerinden olmak üzere, materyallerin kenarlarından, ayakkabıdan, ayakkabının kenarlarından ve rastgele gürültü içeren arka planlardan seçilerek eğitim kümesine eklenmiştir.

Her kimyasal için hazırlanan eğitim kümesindeki hedef piksel ve arka plan piksel sayıları Tablo 3.1’de gösterilmiştir. Tablodan da anlaşılacağı üzere tüm eğitim kümeleri için arka plan pikselleri ortaktır.

TABLO 3.1: Dört kimyasal madde için hazırlanan eğitim kümelerinin boyutları.

<b>Kimyasal Madde</b>	<b>Arka Plan Piksel</b>	<b>Hedef Piksel</b>	<b>Toplam Piksel</b>
<b>Kimyasal-1</b>	26684	2062	28746
<b>Kimyasal-2</b>	26684	2447	29131
<b>Kimyasal-3</b>	26684	2965	29649
<b>Kimyasal-4</b>	26684	3168	29852

Test aşamasında kullanılan test kümesi verileri ise eğitim kümesinden tamamen ayrı verilerden oluşmuştur. Test kümesinde her kimyasal ve arka plan kombinasyonu için 50 tane hedef içeren, 50 tane de hedef içermeyen görüntü bulunmaktadır. Görüntüler ortalama 105000 piksel içermektedir. Test aşamasında görüntülerdeki tüm pikseller sınıflandırılarak imaj bazında ve piksel bazında değerlendirme yapılmıştır. Tablo 3.2’de her kimyasal ve arka plan kombinasyonu için test kümesinde bulunan görüntü sayısı gösterilmektedir. Tablodaki “H+” kimyasal hedef içeren görüntüleri, “H-” ise hiçbir hedef içermeyen görüntüleri temsil etmektedir.

TABLO 3.2: Her kimyasal ve arka plan kombinasyonu için test kümesinde bulunan görüntü sayıları.

Kimyasal Madde	Hedef Varlığı	Arka Plan-1	Arka Plan-2	Arka Plan-3	Arka Plan-4
Kimyasal-1	H+	50	50	50	50
	H-	50	50	50	50
Kimyasal-2	H+	50	50	50	50
	H-	50	50	50	50
Kimyasal-3	H+	50	50	50	50
	H-	50	50	50	50
Kimyasal-4	H+	50	50	50	50
	H-	50	50	50	50

### 3.3 Dengesiz Veri Kümesi ve Değerlendirme Ölçütleri

Sınıflandırma için kullanılacak verilerde bazı sınıfların örnek sayısı diğer sınıflara göre çok az ise bu duruma dengesiz veri kümesi denir. Bu tez kapsamında toplanan hiperspektral görüntüler 1:10000 gibi ciddi ölçüde dengesiz bir veri kümesi oluşturmaktadır. Ancak hem bu dengesizlikten kurtulmak hem de sınıflandırma için işe yaramayacak örnekleri atmak amacıyla veri kümesi yaklaşık olarak 1:10 oranına düşürülmüştür. Bu sayede veri kümesindeki işe yaramaz pikseller atılmış ve gerçekten işe yarayan, hedef piksellerdeki özneliklerin ayrımının başarılı bir şekilde genellenmesini sağlayacak pikseller veri kümesine alınmıştır.

Veri kümesi küçültülmesine rağmen hala bir dengesizlikten bahsedilebilir. Ancak veri kümesini daha fazla küçültmek sınıflandırma performansını düşüreceğinden veri kümesi bu boyutlarda kullanılmıştır. Ayrıca çoğu zaman 1:100 oranının üstündeki veri kümeleri dengesiz olarak görüldüğünden 1:10 gibi bir oran çok da büyük bir oran değildir [31]. Bu oranda dengesizlik içeren veri kümeleri için çeşitli yöntemlerle eğitim aşamasında bu dengesizliği ortadan kaldırmak mümkündür [32]. Eğitim aşamasında uygulanan yöntemler sonraki bölümlerde anlatılmıştır.

Genellikle sınıflandırıcıların performansını ölçmek için kullanılan Doğruluk ölçütü dengesiz

TABLO 3.3: Karmaşıklık matrisi.

		<b>Tahmin Edilen Sınıf</b>	
		Doğru	Yanlış
<b>Gerçek Sınıf</b>	Doğru	DP	YN
	Yanlış	YP	DN

veri kümeleri için uygun değildir. Örnek olarak, veri kümesinde %1 sahte kredi kartı aktivitesi, %99 gerçek kredi kartı aktivitesi içeren bir model geliştirildiğinde, tüm sonuçların gerçek kredi kartı aktivitesi olarak sınıflandırılması %99 doğrulukla çalışacaktır. Ancak tüm sahte kredi kartı aktivitelerini yanlış sınıflandıracaktır. Bunun sebebi Doğruluk ölçütünün tüm sınıflara eşit önem vermesidir [33]. Bu yüzden dengesiz veri kümelerinin performansı farklı değerlendirme ölçütleri kullanılarak belirlenir. Dengesiz veri kümesi ile öğrenme yöntemlerinde performans analizi yapılırken Doğru Pozitif (DP), Yanlış Pozitif (YP), Doğru Negatif (DN) ve Yanlış Negatif (YN) terimleri sıkça kullanılır. Bu terimlerin Karmaşıklık Matrisi üzerindeki gösterimi Tablo 3.3'te verilmiştir. Bu terimler Kesinlik, Duyarlılık, F1 Skor, Alıcı İşletim Karakteristiği (ROC) eğrisi, Kesinlik-Duyarlılık (PR) eğrisi ve Eğri Altındaki Alan (AUC) gibi değerlendirme ölçütlerini hesaplamak için kullanılır. Kesinlik ölçütü, doğru olarak pozitif sınıflandırılmış sonuçların tüm pozitif sonuçlara oranıdır. Kesinlik ölçütünün yüksek olması sınıflandırıcının az sayıda yanlış alarm verdiğini gösterir. Duyarlılık ölçütü, doğru olarak pozitif sınıflandırılmış sonuçların pozitif olması gereken tüm sonuçlara oranıdır. Duyarlılık ölçütünün yüksek olması az sayıda gerçek pozitif verinin yanlış sınıflandırıldığını gösterir. F1 Skor, Kesinlik ve Duyarlılık değerlerinin harmonik ortalamasıdır. Alıcı İşletim Karakteristiği eğrisi çeşitli eşik seviyelerinde DPO ve YPO değişimine göre çizilen eğridir. PR eğrisi ise çeşitli eşik seviyeleri ele alınarak Kesinlik ve Duyarlılık değerlerinin değişimine göre çizilen eğridir. Eğri Altındaki Alan (AUC) ise Alıcı İşletim Karakteristiği (ROC) eğrisi altında kalan alanı temsil eder. Dengesiz veri kümeleri ile öğrenmede sıklıkla kullanılan performans ölçütlerinin matematiksel tanımları Tablo 3.4'te verilmiştir. Bu tez kapsamında eğitilen modellerin performanslarını test aşamasında ölçmek ve elde edilen sonuçları analiz etmek amacıyla Kesinlik ve Duyarlılık ölçütleri temel alınmıştır.

Bunun en büyük sebebi DP ve YP piksel sayılarının ve bunların birbirine göre oranının bu çalışma için çok önemli olmasıdır.

TABLO 3.4: Dengesiz veri kümeleri ile öğrenme yöntemlerinde sıklıkla kullanılan performans ölçütlerinin matematiksel tanımları.

Ölçüt	Matematiksel Tanım
Doğru Pozitif Oranı (DPO)	$\frac{DP}{DP+YN}$
Doğru Negatif Oranı (DNO)	$\frac{DN}{DN+YP}$
Yanlış Negatif Oranı (YNO)	$\frac{YN}{DP+YN}$
Yanlış Pozitif Oranı (YPO)	$\frac{YP}{DN+DP}$
Kesinlik	$\frac{DP}{DP+YP}$
Duyarlılık	$\frac{DP}{DP+YN}$
F1 Skor	$\frac{2 \times DP}{2 \times DP + YP + YN}$

### 3.4 Diferansiyel Reflektometri

Hiperspektral görüntülerde hedef tespiti uygulamalarını iyileştirmek amacıyla Diferansiyel Reflektometri (DR) yöntemi ilk kez 1970’te Rolf E. Hummel tarafından önerilmiştir [34]. Diferansiyel Reflektometri veya Diferansiyel Yansıma Spektroskopi incelenen ortamın elektronik yapısının detaylarını açığa çıkarmak için morötesi ve görünür ışığı kullanan bir yüzey analiz tekniğidir. Bu teknikte bir aygıt yardımıyla elektronların fotonlardan enerji olarak üst enerji seviyelerine geçişi (soğurum kenarı) tespit edilir. Tüm maddelerin elektronik yapısı kendine özel olduğundan elektronların bir enerji seviyesinden diğerine geçişi karakteristik enerji (soğurum kenarı) açığa çıkarır, bu enerjinin ölçülmesi maddelerin tespit edilmesinde parmak izi gibi kullanılır. Diferansiyel yansıma dalga boyunun bir fonksiyonu olan karmaşık dielektrik sabitiyle doğrudan orantılıdır, bundan dolayı her madde için eşsizdir. Diferansiyel yansımanın her madde için ayırt edici bir özellik olması Diferansiyel Reflektometri yöntemini kimyasal maddelerin spektrumunu incelemeye önemli bir nitelik haline gelir [10].



Bölüm 3.1’de anlatılan sistem sayesinde toplanıp bilgisayara iletilen hiperspektral görüntüler derin öğrenme modeline beslenmeden hemen önce ön işlemeye uğrar. Ön işlemin ilk adımı Diferansiyel Reflektometri işlemidir. DR ile elde edilecek veri, bir yüzey üzerindeki ardışık iki tarama alanının yansımaya değerleri farkının normalize edilmesi ile ölçülür. Ön işleme aşamasında yapılan bu işlem Denklem 1’de gösterilmiştir.  $R_1$  ve  $R_2$  parametreleri ardışık iki tarama alanını ifade etmektedir.  $\Delta R / \Sigma R$  ise hesaplanan yeni tarama alanının Diferansiyel Yansımaya Spektrumu’nu temsil eder.

$$\frac{\Delta R}{\Sigma R} = \frac{R_1 - R_2}{R_1 + R_2} \quad (1)$$

Bu yöntem özellikle bazı kimyasal maddeler için çok duyarlıdır ve spektrumlarını belirginleştirmede önemli rol oynar. İşlemler sonucu elde edilen spektral imzaların kalitesi yapılan işlemlerin koşullarına ve kullanılan donanımlara bağlıdır. Bazı koşullar ve donanım parametreleri değiştirilemese de, birkaç tanesi değiştirilerek daha uygun spektrumlar elde edilebilir. Önemli ayarlanabilir parametreler kameranın görüntüyü yakalama hızı ve iletim bandının geçiş hızıdır (tarama hızı). Kameranın görüntü yakalama hızı düştükçe alınan spektrum üzerindeki gürültünün arttığı gözlenmiştir. Ayrıca iletim bandının hızı arttıkça alınan sinyallerdeki gürültünün daha az olduğu görülmüştür [10]. Kısacası bu iki parametrenin sinyal-gürültü oranı üzerinde büyük etkisi vardır. Sinyal-gürültü oranının da test edilen yüzeydeki maddelerin miktarıyla doğrudan ilgisi vardır. Eğer yüzey üzerinde belirli bir miktardan az kimyasal madde varsa bu o maddenin spektrumunu daha belirsiz hale getirir ve tespit edilmesini zorlaştırır. Bu yüzden her maddenin tespiti için gerekli tespit limit değerleri vardır [35]. Diferansiyel Reflektometri yönteminden maksimum verimi almak için sinyal-gürültü oranının oldukça yüksek olması gerekmektedir. Bu çıkarımla tezde kullanılan kameranın görüntü yakalama hızı ve iletim bandının geçiş hızı donanımların desteklediği en ideal şekilde ayarlanmıştır.

### 3.5 Savitzky-Golay Filtreleme

Savitzky-Golay filtresi sinyalin eğilimini bozmadan, yumuşatma yöntemiyle sinyal üzerindeki gürültüyü azaltarak sinyali daha düzgün ve belirgin bir hale getirme yöntemidir. İlk kez 1964 yılında Abraham Savitzky ve Marcel J. E. Golay tarafından önerilen bu yöntemde verideki her nokta için kestirim aralığı içerisindeki komşuluklar hesaba katılarak en küçük kareler yöntemiyle bir polinom hesaplanmıştır [36]. Kestirim aralığı bir noktadan diğerine kaydırılarak yapılan bu işlemin kayan ayırık evrişim işlemiyle özdeş olduğu sonucunu çıkaran Savitzky ve Golay, farklı girdi verileri için sabit olan, sadece polinomun derecesine ( $N$ ) ve kestirim aralığının boyuna ( $2M + 1$ ) bağlı olan bir evrişim katsayıları tablosu yayınlamıştır. Girdi sinyalinin belirli bir polinom derecesinde ve kestirim aralığı boyunda tablodan uygun katsayılarla çarpılmasına Savitzky-Golay filtreleme işlemi denir [37]. Girdi verisi  $x[n]$  için  $2M + 1$  örnekli veri grubu değerlendirildiğinde polinomun katsayıları

$$p(n) = \sum_{k=0}^N a_k n^k \quad (2)$$

olarak elde edilir. Veri grubunun ortalama karesel hatasını en aza indiren denklem

$$\mathcal{E}_N = \sum_{n=-M}^M (p(n) - x[n])^2 \quad (3)$$

$$\mathcal{E}_N = \sum_{n=-M}^M \left( \sum_{k=0}^N a_k n^k - x[n] \right)^2 \quad (4)$$

ile hesaplanır. Bu analiz diğer  $2M + 1$  örnekli veri gruplarının hepsi için aynıdır. Kestirim aralığı hesap yapılan örnek noktaya göre simetrik olmalıdır. Bir sonraki verinin çıktısını hesaplamak için kestirim aralığı bir örnek sağa kaydırılır ve kestirim aralığının ortasındaki nokta için polinom uydurma işlemi yapılır. Bu işlemler girdi verisindeki tüm noktalar için tekrarlanır, her nokta için bir polinom uydurulur ve yumuşatma işlemi uygulanmış yeni bir

çıkı verisi oluşur. Savitzky ve Golay tarafından yazılan makalede, her nokta için polinom uydurma işlemi ile yumuşatılmış çıkı değerlerinin, girdi örneklerinin belirli bir sabit doğrusal kombinasyonuna özdeş olduğu gösterilmiştir [36]. Polinom derecesi ve kestirim aralığının boyu belirlendikten sonra ilgili örnek kümesi için sabit ağırlık katsayılarının oluştuğu görülmüştür. Bu sabit ağırlıklar katsayılarının tutulduğu tabloya evrişim katsayıları tablosu denir. Girdi verisinin bu tablodaki sabit ağırlık katsayıları ile çarpılması da ayrık evrişim işlemine denk gelmektedir.

$$y[n] = \sum_{m=-M}^M h[m]x[n-m] \quad (5)$$

$$y[n] = \sum_{m=n-M}^{n+M} h[n-m]x[m] \quad (6)$$

$h$  verisi yumuşatılmış çıkı verisini bulmak için kullanılan kaydırılmış dürtü yanıtı fonksiyonudur.  $2M + 1$  kestirim aralığıyla tüm noktalarda en küçük kareler yöntemiyle polinom uydurma işlemine özdeş olan bir sonlu süreli dürtü yanıtı bulmak için polinomun katsayıları hesaplanmalıdır. Önce Denklem 2'de hesaplanan polinomun  $N + 1$  tane katsayı için türevi alınır ve sıfıra eşitlenir.

$$\frac{\delta \mathcal{E}_N}{\delta a_i} = \sum_{n=-M}^M 2n^i \left( \sum_{k=0}^N a_k n^k - x[n] \right) = 0 \quad (7)$$

$$\sum_{k=0}^N \left( \sum_{n=-M}^M n^{i+k} \right) a_k = \sum_{n=-M}^M n^i x[n] \quad i = 0, 1, \dots, N. \quad (8)$$

Denklem 8 matris formunda açıklanırsa daha açıklayıcı olacağından  $(2M + 1) \times (N + 1)$  boyutunda bir  $\mathbf{A} = \{a_{n,i}\}$  matrisi oluşturulur.  $\mathbf{A}$  matrisine polinom kestirimi için tasarım matrisi denir ve elemanları

$$a_{n,i} = n^i, i = 0, 1, 2, \dots, N, -M \leq n \leq M \quad (9)$$

şeklinde hesaplanır.  $\mathbf{A}$  matrisi ile  $\mathbf{A}$  matrisinin transpozunun çarpımı  $(N + 1) \times (N + 1)$  boyutunda simetrik bir  $\mathbf{B} = \mathbf{A}^T \mathbf{A}$  matrisi oluşturur.  $\mathbf{B}$  matrisinin elemanları

$$\beta_{i,k} = \sum_{n=-M}^M a_{i,k} a_{n,k} = \sum_{n=-M}^M n^{i+k} = \beta_{k,i} \quad (10)$$

şeklinde hesaplanır. Girdi örnekleri vektörü  $\mathbf{x} = [x[-M], \dots, x[-1], x[0], \dots, x[M]]^T$  ve polinom katsayıları vektörü  $\mathbf{a} = [a_0, a_1, \dots, a_N]^T$  şeklinde tanımlanır. Bu tanımlamalar ile Denklem 8

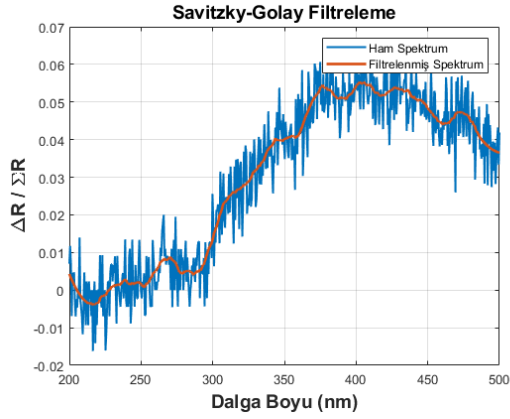
$$\mathbf{B}\mathbf{a} = \mathbf{A}^T \mathbf{A}\mathbf{a} = \mathbf{A}^T \mathbf{x} \quad (11)$$

olarak yazılabilir. Buradan da polinom katsayıları vektörü


$$\mathbf{a} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{x} = \mathbf{H}\mathbf{x} \quad (12)$$

hesaplanır. Burada  $(N + 1) \times (2M + 1)$  boyutundaki  $\mathbf{H} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$  matrisi ile  $(2M + 1) \times 1$  boyutundaki  $\mathbf{x}$  vektörü çarpılarak tüm noktalar için polinom katsayıları bulunabilir.  $\mathbf{H}$  matrisinin hesaplanması sadece  $N$  ve  $M$  değerlerine yani polinom derecesine ve kestirim aralığının (filtrenin) boyuna bağlıdır. Girdi verisinin  $\mathbf{H}$  matrisinin hesaplanmasında hiçbir önemi yoktur. Aynı  $N$  ve  $M$  değerleri için farklı girdiler aynı  $\mathbf{H}$  matrisini kullanacaktır. Buradan da anlaşılacağı üzere en küçük kareler ile yumuşatma tekniği kayan ayrık evrişim işleminin aynısıdır.


Hiperspektral veriler derin öğrenme algoritmasına beslenmeden önce son olarak Savitzky-Golay filtreleme işleminden geçirilir. Daha önceki benzer çalışmalardan olan [38]'deki



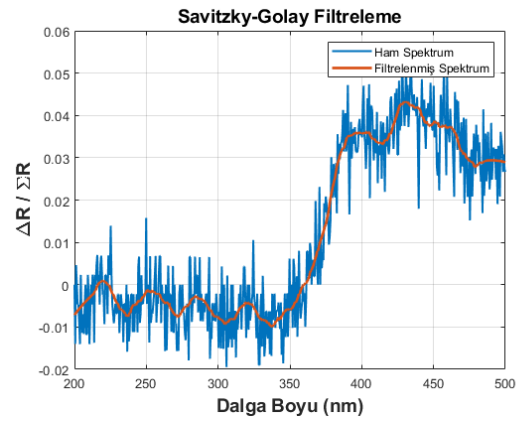
a



b



c



d

ŞEKİL 3.4: Dört kimyasal madde için spektral boyutta gerçekleştirilen Savitzky-Golay filtreleme işlemi. a) Kimyasal-1 spektrumunun filtrelenmesi, b) Kimyasal-2 spektrumunun filtrelenmesi, c) Kimyasal-3 spektrumunun filtrelenmesi, d) Kimyasal-4 spektrumunun filtrelenmesi.

değerler baz alınarak hiperspektral görüntülerdeki her pikselin 548 uzunluğundaki spektral boyutuna uygulanan Savitzky-Golay filtresinin (kestirim aralığının) boyu 51, polinomun derecesi de 2 olarak ayarlanmıştır. Şekil 3.4'te dört farklı kimyasal madde için spektral boyuta uygulanan Savitzky-Golay filtresinin etkisi gösterilmiştir. Grafiklerde mavi renkte çizilen spektrumlar filtreleme öncesini, kırmızı spektrumlar ise filtreleme sonrasını göstermektedir. Grafiklerden de görüldüğü gibi Savitzky-Golay filtelemeinden sonra spektrumlar gürültüden arınarak daha pürüzsüz ve belirgin bir hal almıştır.

## 4. SİNİR AĞLARININ İŞLEYİŞİ VE ÇEŞİTLERİ


1943'te McCulloch ve Pitts yapay sinir ağlarının her türlü aritmetik ve mantıksal problem için kullanılabileceğini önermiştir [39]. Önerilen sinir hücresi Şekil 4.2'deki gibi girdi sinyallerinin ağırlıklandırılmış toplamına eşikleme uygulayarak tetiklenip tetiklenmeyeceğini belirliyordu. Bu çalışmada ilk kez bir beyin hücresinin işleyişini tasarlama girişiminde bulunulmuştur. Daha sonra 1958'de Rosenblatt geliştirdiği Perceptron algoritmasını örüntü tanıma problemlerinde kullanmıştır [40]. Perceptron'un kullanımı yapay sinir ağlarına olan ilgiyi büyük ölçüde arttırsa da Minsky ve Papert Perceptron'un hala eksiklikleri olduğuna dikkat çekmiştir [41]. Perceptron algoritması kompleks problemleri çözmekte zorlanmıştır. Kompleks problemleri çözmek için daha güçlü hesaplamalar gerektiğinden ve bunu yapacak bilgisayarlar o dönem bulunmadığından artık son noktaya gelindiği düşünülmüştür. Bu yüzden birçok bilim insanı bu alanda çalışmayı bırakmıştır. 1980'lerde bilgisayar teknolojisinin büyümesiyle birlikte çalışmalar çok hızlı bir biçimde tekrar başlamıştır. Çalışmaların başlamasıyla aynı dönemde birçok araştırmacı tarafından geri yayılım algoritması keşfedilmiştir. Bunların en önemlilerinden biri Rumelhart ve McClelland tarafından 1986'da önerilmiştir [42]. Geri yayılım algoritmasının keşfi yapay sinir ağları alanında bir çığır açmıştır. Bu dönemden sonra yapay zeka alanında birçok çalışma yapıp birçok makale yazılmıştır. Günümüze gelene kadar birçok yeni algoritma ve sinir ağı modeli oluşturulmuştur. Hala çoğu bilim insanı ve araştırmacı için sıcak gündem olan yapay zeka günden güne gelişmeye devam etmektedir.

### 4.1 Biyolojik Sinir Ağları

Yapay Sinir Ağlarının çalışma mekanizmasını anlamak için öncelikle ilham aldıkları biyolojik karşılıklarını anlamak gereklidir. Genel olarak insanların sinir sistemi üç aşamadan oluşur; alıcılar, sinir ağı ve etkileyiciler. Alıcılar vücut içi veya vücut dışından gelen uyarıcı sinyalleri alır ve bu sinyalleri elektriksel formda sinirlere iletir. Bilgiyi alan sinir ağı bu

bilgileri işler ve bir karar verir. Etkileyiciler sinir ağından aldıkları elektriksel sinyalleri uygun bir forma çevirerek dışarıya gönderir [43].

Biyolojik sinir sisteminin ana elemanı nöronlardır. Nöronlar üç bölümden oluşur; dentrit, soma ve akson. Her bir dentrit farklı bir nörona bağlanır ve sinyalleri çevre nöronlardan alır. Soma gelen sinyalleri toplar ve akson üzerinden diğer hücrelere sinyaller yollar. Akson sinyali bir nörondan diğerine ileten yapıdır. Aksonların ucu bir sonraki nöronun dentritine sinapslar aracılığıyla bağlanır. Sinapslardaki sinyalin iletimi elektro-kimyasal difüzyon ile gerçekleşir. Bir nöron daha önceki nöronlardan aldığı sinyalleri değerlendirerek nöronun tetiklenip tetiklenmeyeceğine karar verir (eşikleme), eğer nöron içerisinde koşul sağlanırsa nöron tetiklenir ve sonraki nöronlara elektrik sinyalleri yollar [44]. Şekil 4.1’de örnek bir biyolojik sinir hücresi gösterilmiştir.

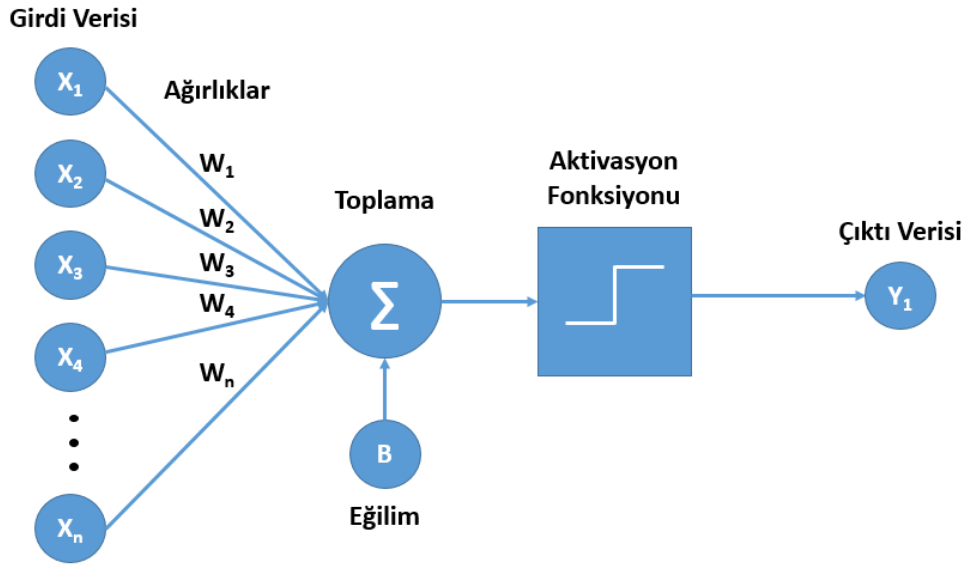


ŞEKİL 4.1: Biyolojik sinir hücresi.

## 4.2 Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) belirli bir görevi yapmak amacıyla biyolojik sinir ağlarına benzetilerek oluşturulmuş sistemlerdir. Bir Yapay Sinir Ağı birçok işlem birimi içerir, bu birimlere yapay nöron da denir. İşlem birimlerinin arasında bulunan bağlantılara ağırlık denir.

Ağırlıklar kullanılarak sinir ağı boyunca bilgi iletimi sağlanır. Önceki birimlerden ağırlıklanmış sinyali alan bir birim aktivasyon fonksiyonu uygulayarak sinyalin diğer birimlere iletilip ileilmeyeceğini belirler. Burada kullanılan aktivasyon fonksiyonu genellikle doğrusal olmayan bir eşikleme fonksiyonu görevi görür [43]. Şekil 4.2’de örnek bir yapay sinir hücresi (işlem birimi) gösterilmiştir.



ŞEKİL 4.2: Yapay sinir hücresi.

Yapay Sinir Ağları bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Her katmanda birçok yapay nöron bulunur. Sinir ağları kullanılarak yapılmak istenen görevde amaç katmanlar arasındaki ağırlıkların en uygun değerlerini bulmaktır. Böylece YSA modeli en iyi sonucu üretecektir. Ağırlıkları bulmak için YSA modelini eğitim veya öğrenme adı verilen bir aşamadan geçirmek gerekir. YSA’da öğrenme aşaması üç temel yöntemle yapılabilir. Bunlar denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir. Kısaca denetimli öğrenme veri kümesindeki örneklerin etiketli bir halde YSA modeline beslenmesi ile eğitilmesidir. Denetimsiz öğrenmede ise veri kümesindeki örnekler etiketsiz bir halde modele beslenir. Pekiştirmeli öğrenme de bu iki yöntemden farklı olarak ceza ve ödül temelli bir eğitim yöntemi uygulanır.



Bu tez kapsamında etiketli verilerle çalışıldığından denetimli öğrenme yöntemi uygulanmıştır. Denetimli öğrenmede model eğitilirken geri yayılım adı verilen bir algoritma ile ağırlıkların güncellenmesi ve bir süre sonra en uygun olan ağırlıkların bulunması sağlanır.

#### **4.2.1 Geri Yayılım**

Denetimli öğrenmede bir sinir ağı eğitilirken önce girdi verisi girdi katmanına beslenir. Girdi katmanı aldığı bilgiyi gizli katmanlara iletir. Gizli katmalar önceki katmanlardan aldıkları bilgiye içerdikleri işlem biriminin türüne göre uygun matematiksel dönüşümler uygulayarak bilgiyi sonraki katmanlara iletir. Tüm sinir ağını geçen bilgi son olarak sınıflandırma tahmini için çıktı katmanına iletilir. Çıktı katmanında uygun bir aktivasyon fonksiyonu kullanılarak tüm sınıfların olasılıkları oluşturulur. En yüksek olasılıklı sınıf çıktı olarak tahmin edilir. Tahmin edilen değer doğruluğunu kestirebilmek için tahmin değeri ile gerçek değer arasındaki hata (kayıp) hesaplanır. Hatayı hesaplamak için uygun bir kayıp fonksiyonu kullanılır. İdeal olarak amaç bu kaybı sıfır yapmaktır. Kaybı sıfır yapmak amacıyla ağıdaki ağırlık değerlerinin kademeli olarak değişimi sağlanır. Bu değişim geri yayılım algoritması ile sağlanır. Geri yayılım algoritmasında uygun bir optimizasyon yöntemi kullanılarak kayıp fonksiyonunun ağırlık değerlerine göre gradyanı (türevi) hesaplanır. Son katmanın gradyanı hesaplandıktan sonra bulunan değerler önceki katmanlara iletilir. Böylece zincir kuralıyla tüm katmanlardaki ağırlıklar güncellenir.

#### **4.2.2 Kayıp Fonksiyonu**

Kayıp fonksiyonu geliştirilen algoritmanın ve hesaplanan ağırlıkların uygulanan problem üzerinde ne kadar başarılı olduğunu hesaplamak için kullanılır. Kayıp fonksiyonunun sıfıra yaklaşması başarının arttığı anlamına gelir. İdeal durumda kayıp fonksiyonunun çıktısının sıfır olması beklenir.

TABLO 4.1: Sıklıkla kullanılan dört kayıp fonksiyonunun matematiksel tanımları.

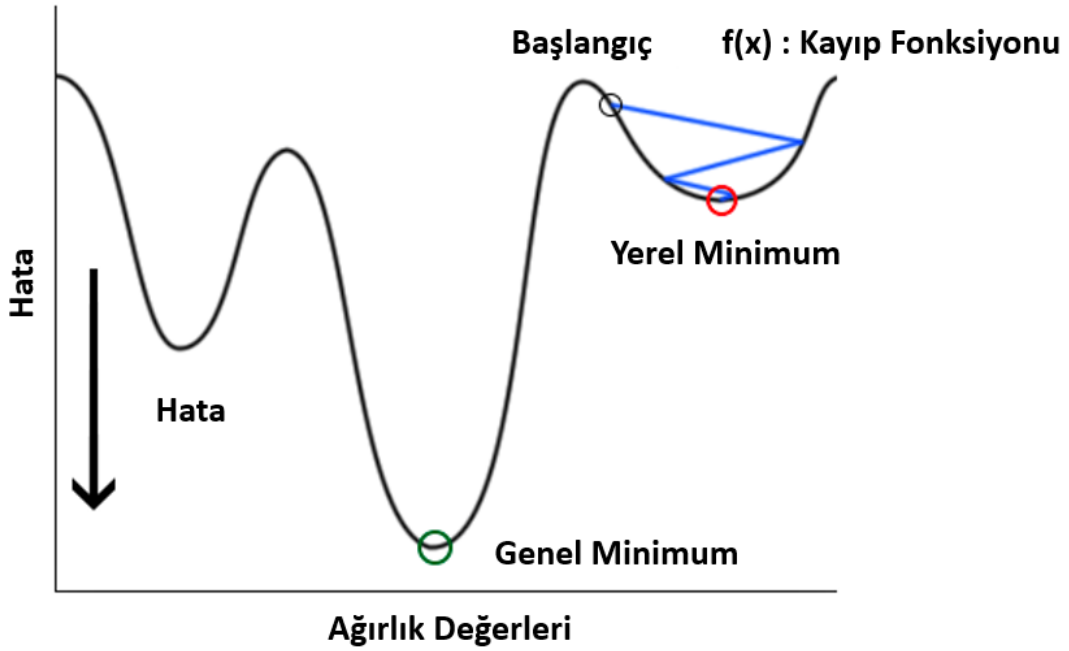
Kayıp Fonksiyonu	Matematiksel Tanım
Çapraz Entropi Kaybı	$J = -\frac{1}{N} \sum_{i=1}^N y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i))$
Ortalama Karesel Kayıp	$J = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$
Ortalama Mutlak Kayıp	$J = \frac{1}{N} \sum_{i=1}^N  y_i - \hat{y}_i $
Menteşe Kaybı	$J = \max(0, 1 - y\hat{y})$

YSA modellerinde birçok kayıp fonksiyonu kullanılır. Bunların başlıcaları çapraz entropi kaybı, ortalama karesel kayıp, ortalama mutlak kayıp ve menteşe kaybıdır. Bu tez kapsamında tüm modellerin eğitiminde çapraz entropi kaybı kullanılmıştır. Tablo 4.1’de literatürde en çok kullanılan kayıp fonksiyonlarının matematiksel tanımları gösterilmiştir. Matematiksel tanımlardaki  $J$  kayıp fonksiyonunu,  $y$  olması gereken gerçek sonucu,  $\hat{y}$  modelin tahmin ettiği sonucu,  $N$  modeldeki sınıf sayısını,  $i$  ise kayıp değeri hesaplanan sınıfı belirtmektedir.

### 4.2.3 Optimizasyon

Optimizasyon kayıp fonksiyonu sonucu üretilen hatayı en aza indirmek için modelin ağırlıkları değiştirilerek en az hatanın olduğu noktayı (genel minimum nokta) bulma yöntemidir. Derin öğrenme uygulamalarında optimizasyon genellikle gradyan inişi yöntemi temel alınarak yapılır. Bu yöntemde kayıp fonksiyonunun birinci dereceden türevi hesaplanır ve hatayı en aza indirmek için ağırlıkların hangi yönde güncelleneceği hakkında bilgi sağlanır. Gradyan inişi yöntemi kolay hesaplanabilir ve kolay uygulanabilir olsa da, genel minimum noktasını bulamadan yerel minimumda takılma sorunu yaşanabilir. Şekil 4.3 bu durumun bir örneğini göstermektedir. Ayrıca çok büyük veri kümelerinde hafıza alanı yetersizliği ve minimuma geç yakınsama gibi sorunlar da gözlenebilir. Bu sorunların çözümü olarak gradyan inişi yönteminin bir çeşidi olan rastgele gradyan inişi (SGD) kullanılmıştır. SGD’de her eğitim

verisinden sonra kayıp hesaplanarak modelin ağırlıkları güncellenir. Böylece model minimuma daha hızlı yakınsar. SGD'nin başka bir formu ise mini-yığın gradyan inişidir. Bu yöntemde SGD yöntemine yığın boyu parametresi verilir ve modelin ağırlıkları her yığından sonra güncellenir. SGD'nin dezavantajlarından biri modelin parametresinin yüksek varyansa sahip olmasıdır. Yüksek varyansı düşürmek amacıyla SGD algoritmasına momentum parametresi eklenir. Bu sayede minimum nokta bulunurken yapılan salınımlar azalır ve daha kolay bir şekilde minimum noktaya yakınsanır [45].



ŞEKİL 4.3: Kayıp fonksiyonu üzerinde yerel ve genel minimum noktalarının gösterimi.

SGD'den sonra mini-yığın ve momentum yöntemleri birleştirilerek oluşturulan dayanıklı bir optimizasyon yöntemi olan RMSProp yöntemi ortaya çıkmıştır [46]. Tüm bu çözümlere rağmen klasik optimizasyon yöntemlerinin en büyük dezavantajı öğrenme hızı parametresinin sabit olmasıdır. Bu durumu aşmak amacıyla adaptif öğrenme hızı kullanan birçok optimizasyon yöntemi geliştirilmiştir. Bunlardan başlıcaları AdaDelta [47], AdaGrad [48] ve Adam [49] yöntemleridir. Adam yöntemi performans bakımından genellikle diğer yöntemlerden daha başarılı görülür. Bunun sebebi momentum ve adaptif öğrenme hızının yanı sıra çok iyi bir eğilim düzeltme yapmasıdır. Tablo 4.2'de en çok kullanılan optimizasyon yöntemlerini

ve matematiksel tanımlarını gösterilmiştir. Matematiksel modellerde ortak olarak kullanılan  $\theta$  ağırlık matrisini,  $\eta$  öğrenme hızı parametresini,  $n$  yığın boyunu,  $\nabla_{\theta}$  ağırlıklara göre uygulanan gradyan işlemini,  $J(\theta)$  kayıp fonksiyonunu,  $x$  girdi verisini,  $y$  çıktı verisini,  $t$  zaman adımını temsil etmektedir. Momentum SGD'deki  $V$  ağırlık güncelleme matrisini,  $\gamma$  momentum parametresini belirtmektedir. RMSProp yöntemindeki  $g$  ağırlık matrisinin gradyanını,  $E[g^2]$  gradyanın ikinci momentini göstermektedir. Adam yöntemindeki  $m$  gradyanın eğilimli birinci momentini (ortalama),  $v$  gradyanın eğilimli ikinci momentini (varyans),  $\hat{m}$  gradyanın eğilimi düzeltilmiş birinci momentini,  $\hat{v}$  gradyanın eğilimi düzeltilmiş ikinci momentini,  $\beta$  üstel azalma oranı parametresini temsil ederken,  $\epsilon$  da paydanın sıfır olmaması için eklenen çok küçük bir değeri temsil etmektedir.


TABLO 4.2: Sıklıkla kullanılan optimizasyon yöntemlerinin matematiksel modelleri.

Optimizasyon Yöntemi	Matematiksel Model
Gradyan İniş	$\theta = \theta - \eta \nabla_{\theta} J(\theta)$
SGD	$\theta = \theta - \eta \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)})$
Mini-Yığın SGD	$\theta = \theta - \eta \nabla_{\theta} J(\theta; x^{(i:i+n)}; y^{(i:i+n)})$
Momentum SGD	$V(t) = \gamma V(t-1) + \eta \nabla_{\theta} J(\theta)$ $\theta = \theta - V(t)$
RMSProp	$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma) g_t^2$ $\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t^2$
Adam	$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$ $\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$ $\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t$

#### 4.2.4 Hiperparametre Ayarlama

Hiperparametre bir derin öğrenme modelini eğitmek için gereken, ne olması gerektiği veri kümesine ve uygulamaya bağlı olarak değişen, algoritma geliştiricisi tarafından belirlenen

parametrelerdir. Bir derin öğrenme modeli birden fazla hiperparametre kümesiyle istenen başarıya ulaşabilir. Ancak bir model onlarca hiperparametre içerdiği için bu hiperparametrelerin uygun olanlarının bulunması genellikle zorlayıcı, zaman alan ve bir o kadar da önemli bir iştir. Bazı hiperparametreler için çoğu uygulamada sıklıkla kullanılan değerler olsa da, bazıları için ciddi sayıda deneme yapılarak bu hiperparametrelerin değerine karar verilir. Veri kümesinin boyutu, yığın boyu, öğrenme hızı, momentum katsayısı, eğitim tur sayısı, ağırlıkların ilklendirilmesi, yapay nöron sayısı, aktivasyon fonksiyonu ve hatta optimizasyon yöntemi bunlardan bazılarıdır. En iyi modeli bulmak amacıyla bu parametrelerin tüm kombinasyonları denenmeli ve uygun olan parametreler seçilmelidir. Öğrenme hızı, yığın boyu, eğitim tur sayısı, optimizasyon yöntemi gibi bazı parametrelerdeki küçük değişimler eğitimin sonucunu ciddi şekilde değiştirebilirken, veri kümesinin boyutu, yapay nöron sayısı, momentum katsayısı, aktivasyon fonksiyonu gibi parametreler bazen o kadar etkili olmayabilir. Örnek olarak [50]'deki çalışmadan uyarlanan Şekil 4.4'te öğrenme hızı parametresine göre değişen hata eğrileri gösterilmiştir.

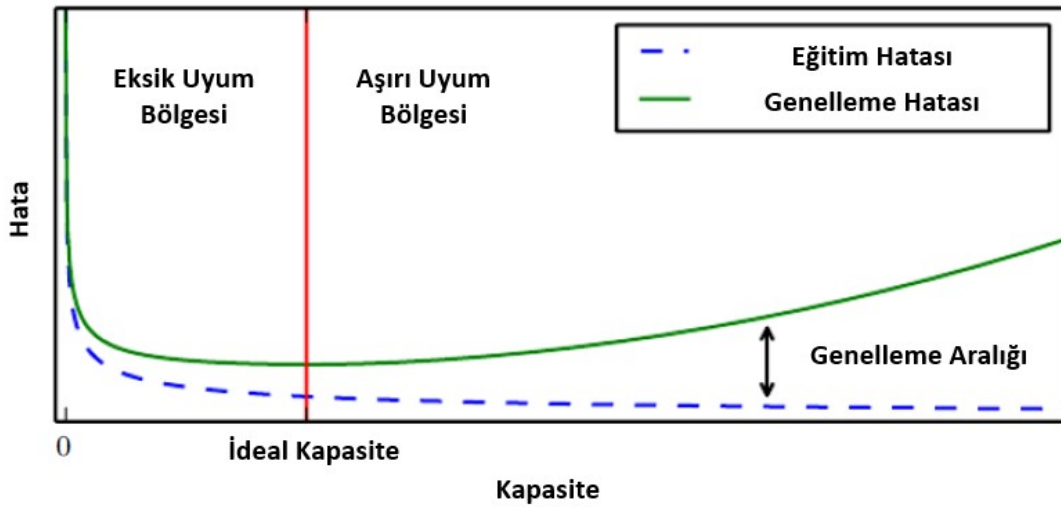


ŞEKİL 4.4: Öğrenme hızı parametresine göre değişen hata eğrilerinin gösterimi.

#### 4.2.5 Eksik Uyum ve Aşırı Uyum

Makine öğrenmesindeki ana görev daha önceden görülmemiş test verileri için iyi sonuçlar üretmektir. Eğitim verisi üzerinde iyi sonuçlar almak her zaman test verisinde de iyi sonuçlar alınacağı anlamına gelmez. Eğitim verisindeki başarıyı test verisi üzerinde de gösterme yeteneğine genelleme adı verilir. Eğitim sırasında hesaplanan en iyileme hatası (eğitim hatası), test sırasında da hesaplanır ve genelleme hatası olarak adlandırılır. Eğitim hatası ve genelleme hatası arasındaki fark yüksek ise modelde aşırı uyum durumu oluşur. Aşırı uyum modelin eğitim verisinin detaylarını öğrenip veya ezberleyip, test verisi üzerinde kötü performans sergilemesi durumudur. Eksik uyum ise eğitimin yeterince verimli olmadığı ve eğitim hatasının yeterince azaltılamadığı duruma verilen addır.

Goodfellow ve arkadaşlarının çalışması [50]'den uyarlanan Şekil 4.5'te gösterildiği gibi eğitim sırasında belirli bir noktadan sonra genelleme hatası daha fazla azalmadığı için eğitim hatası ve genelleme hatası arasındaki fark büyümeye başlayabilir. Bu farka genelleme aralığı denir. Verimli bir model elde edebilmek için genelleme aralığının en uygun seviyede olduğu kapasitede eğitim yapılmalıdır.



ŞEKİL 4.5: Eğitim ve test aşamalarında elde edilen hata eğrileri ile eksik uyum bölgesinin, aşırı uyum bölgesinin ve genelleme aralığının gösterimi.

Derin öğrenme uygulamalarında eksik uyumdan çok aşırı uyum durumuyla karşılaşıldığından bu sorunun çözümü genellikle daha önemli görülmüştür. Genelleme hatası azaltılıp eğitim hatasına yakınlaştırılırsa aşırı uyum ihtimali azaltılır. Genelleme hatasını azaltmak için birçok yöntem mevcuttur. Eğitim verisinin sayısını arttırmak [51][52] [53], bırakma katmanları kullanmak [54], Temel Bileşen Analizi gibi algoritmalarla fayda sağlamayan özneliklerden kurtulmak [55], düzenleme [56], erken durdurma ve çapraz doğrulama teknikleri bu yöntemlerden bazılarıdır.

### 4.3 Evrişimsel Sinir Ağları

Yapay Sinir Ağları'nın en çok kullanılan ve en önemli formlarından biri Evrişimsel Sinir Ağları'dır. Evrişimsel Sinir Ağları (ESA) temelde klasik Yapay Sinir Ağları gibi çalışır. ESA'daki yapay nöronlar girdi verisini alıp ağırlıklar ile vektörel çarpımları yapar, doğrusal olmayan bir aktivasyon fonksiyonundan geçirir ve sonraki katmanlara gönderir. Son katmanda da tıpkı klasik YSA'lardaki gibi çıktı verisi için bir tahmin yapılır. ESA'ları klasik modellerden ayıran en büyük fark ana katmanlarının tam bağlı katman yerine evrişimsel katman olmasıdır. Evrişim işlemi doğası gereği verideki detayların ayırt edilmesini sağladığından ESA'lardaki kullanımları ile önemli başarılar elde edilmiştir. ESA mimarilerinde genellikle ilk katmanlarda evrişim katmanları, son katmanlarda tam bağlı katmanlar bulunur. Bunun sebebi ilk katmanlarda evrişim işlemiyle öznelik çıkarımı yapmak, son katmanlarda ise sınıflandırma için veriyi uygun boyutlara getirmektir.

ESA'ların özellikle iki boyutlu görüntü verileri üzerindeki başarısı birçok kez kanıtlanmıştır. İlk kez Yann LeCun, 5 katmanlı bir ESA kullanarak el yazısı ile yazılmış rakamları doğru sınıflandırmaya çalışmıştır [57]. Daha sonra ImageNet yarışmasında Krizhevsky ve arkadaşları, Alexnet adını verdikleri 8 katmanlı bir ESA modeli geliştirmiştir. Alexnet, ImageNet veri kümesi üzerindeki performansıyla en yakın rakibinden %10 daha az hatayla sınıflandırma tahminleri yapmıştır. Alexnet'in bu başarısı dikkatleri ESA'lar üzerinde toplamıştır. Bir sonraki yıl yine ImageNet yarışması için Zeiler ve Fergus, ZFNet adını verdikleri modelde Alexnet'in hiperparametrelerini değiştirip evrişimsel katmanları genişleterek sonuçları

iyileştirmiştir [58]. Alexnet'te her filtrenin ne tür öznitelikler öğrendiği, ZFNet'te ise her katmandan sonra oluşan öznitelik haritaları görselleştirilerek ESA'ların öznitelikleri bulmadaki başarısına vurgu yapılmıştır. Daha sonraki yıllarda GoogleNet [59], VGGNet [60] ve ResNet [61] mimarileri ile daha derin ESA mimarilerinin daha çok özneliği öğrendiği ve daha başarılı olduğu gösterilmiştir.

### 4.3.1 Evrişim Katmanı

Evrişim bir sinyali sabit olan başka bir sinyal üzerinde kaydırarak iki sinyalin karışımından üçüncü bir sinyal üretme işlemidir. Bir sinyalin başka bir sinyal ile filtrelenmesi olarak da tanımlanır. Evrişim işlemi aynı zamanda iki sinyalin benzerliğini ölçmek için yapılan çapraz korelasyon işleminin bir formudur. Sürekli zaman alanındaki iki sinyalin evrişim işlemi Denklem 13'te, bu işlemin ayrık zaman alanındaki karşılığı Denklem 14'te gösterilmiştir. Evrişimsel sinir ağı terminolojisinde  $x$  sinyali girdi sinyalini,  $w$  sinyali filtre (çekirdek) sinyalini ve  $s$  sinyali ise evrişim işleminin sonucu olan çıktı sinyalini temsil etmektedir [50].

$$s(t) = x \otimes w = \int x(a)w(t-a)\delta a \quad (13)$$

$$s(n) = x \otimes w = \sum x(n)w(n-a) \quad (14)$$


Makine öğrenmesi uygulamalarında genellikle girdiler ve filtreler çok boyutlu olduğundan tüm boyutlar için evrişim işlemi gerçekleştirilmelidir. ESA'lar çoğunlukla Denklem 15'te gösterilen iki boyutlu evrişim işlemi uygulanırken, yukarıda bahsedildiği gibi evrişim işleminin başka bir formu olan, Denklem 16'da gösterilen çapraz korelasyon işlemi de bazı ESA'lar tarafından uygulanır. Eğer girdi sinyali ( $I$ ) ile çarpılan filtre (çekirdek) ( $K$ ) sinyali simetrik bir sinyal ise evrişim işlemi ile çapraz korelasyon işlemi aynı çıktıyı üretir. Bu yüzden çoğu ESA bu ayrımı gözetmeksizin bu operasyona evrişim işlemi adını verir.



$$S(i, j) = K \circledast I = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (15)$$

$$S(i, j) = I \circledast K = \sum_m \sum_n I(i + m, j + n)K(m, n) \quad (16)$$

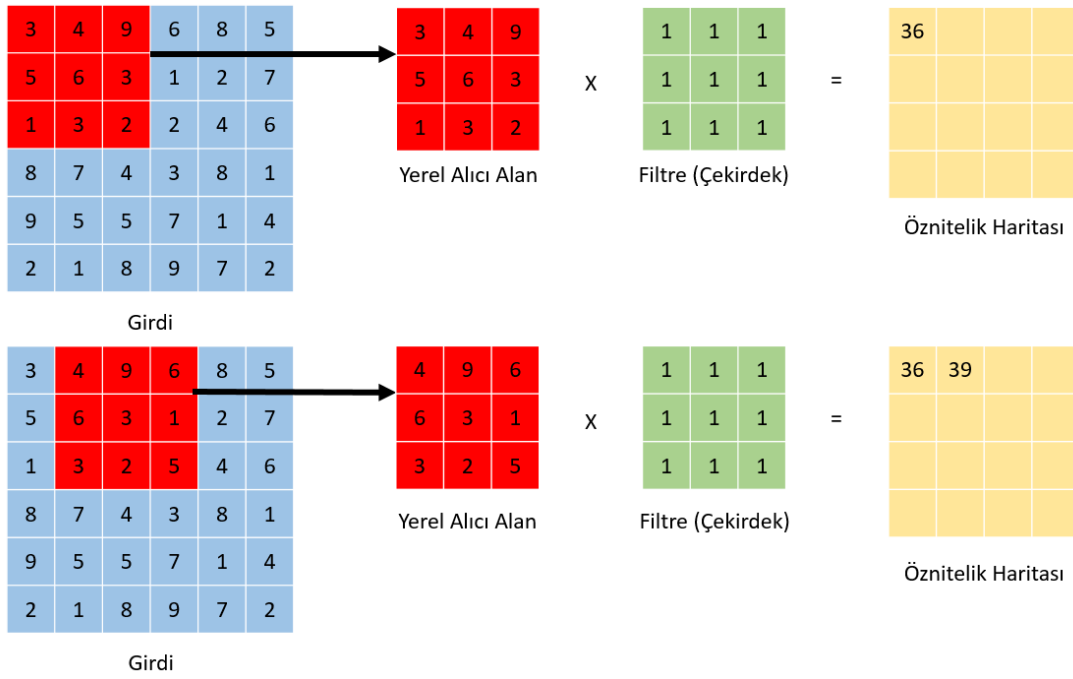
Evrişim katmanını sinir ağlarında kullanılan diğer katmanlardan ayıran üç temel özelliği vardır. Bunlar seyrek bağlantırlık, uzamsal ayarlama ve parametre paylaşımı özellikleridir.



ŞEKİL 4.6:  $32 \times 32 \times 3$  boyutunda bir görüntünün  $5 \times 5 \times 6$  boyutunda bir filtre ile evriştirilmesi sonucu 6 tane  $28 \times 28$  boyutlu öznelik haritasının oluşması.

Sinir ağları genellikle matris çarpımları yaparak parametreler matrisi üretir ve bir katmandaki tüm girdi birimleriyle tüm çıktı birimlerinin etkileşimini sağlar. Ancak ESA'lar seyrek etkileşim veya seyrek bağlantırlık özelliğine sahiptirler. Bunun sebebi evrişim katmanında girdi verileriyle etkileşime girecek filtrelerin, girdi verilerinin uzamsal boyutlarından çok daha küçük boyutlara sahip olmasıdır. Bu özellik sayesinde modelde daha az parametre tutulur. Bu da kullanılan hafıza alanını ve çıktı hesaplamalarının sayısını azaltır. Böylece model daha verimli hale gelir. Filtrelerin sağladığı seyrek bağlantırlık özelliği genişlik ve

boy ekseninde yerel olarak sağlanır. Girdi verisinde belirli genişlik ve boyda filtrelenecek bölgeye “yerel alıcı alan” denir [50]. Yerel alıcı alan girdi verisi üzerinde kaydırılarak tüm girdinin belirli sayıda filtre ile filtrelenmesi sağlanır. Girdinin herhangi bir filtre ile filtrelendikten sonra oluşan haline “öznitelik haritası” denir. Oluşan her bir öznitelik haritasında uygulanan filtreye göre farklı öznitelikler elde edilir. Dolayısıyla evrişim katmanından filtre sayısı kadar öznitelik haritası çıkar. Şekil 4.6’da 6 tane filtre ile evrişim işleminden geçirilen bir girdi sinyali ve oluşan öznitelik haritaları gösterilmiştir. Şekil 4.7’de ise rastgele bir filtre ile girdi verisindeki yerel alan kaydırılarak yapılan evrişim işleminin detayları belirtilmiştir.



ŞEKİL 4.7: İki boyutlu evrişim işlemi örneği.

Evrişim katmanının çıktısının uzamsal boyutlarını belirlemek için üç hiperparametre vardır. Girdi sinyalindeki farklı öznitelikleri bulmak amacıyla birçok filtre kullanılır. Filtrelerin sayısı “derinlik” parametresini belirler. İkinci parametre girdi verisine uygulanacak filtrenin bir sonraki hamlede kaç nokta kayması gerektiğini belirleyen “adım (kayma)” parametresidir. Adım sayısı arttıkça oluşan öznitelik haritaları uzamsal olarak küçülür. Filtrelerin girdi

verisine düzgün uygulanabilmesi için verinin uçlarına uygun bir doldurma işlemi yapılması gerekir. Bunu belirleyen parametre “doldurma (ekleme)” parametresidir [62].

Girdi verisi üzerinde birçok uzamsal noktada aynı öznitelikler çıkarılabilir. Girdi verisi üzerinde herhangi bir uzamsal bölgede bir öznitelik bulunduysa, girdinin başka bir bölgesindeki öznitelik için aynı parametreler kullanılabilir. Bu yüzden öğrenilen “derinlik” sayısı kadar filtre her bir derinlik diliminde aynı öznitelikleri aramak amacıyla kullanılabilir. Böylece her derinlik diliminin kullanacağı ağırlıklar aynı olur. Ağırlık parametrelerinin sayısı ciddi miktarda düştüğü için modelin çok daha fazla hesap yapması engellenmiş olur. Bu da eğitim aşamasını daha hızlı ve verimli bir hale getirir [63].

#### 4.3.2 Aktivasyon Katmanı

Biyolojik sinir ağlarında da bahsedildiği gibi bir sinir hücresinin tetiklenmesi (aktif olması) ve diğer hücrelere yeni bir sinyal göndermesi için gelen elektro-kimyasal sinyallerin seviyesinin belirli bir eşik değerinden fazla olması gerekmektedir. Biyolojik sinir ağlarındaki bu işlemin yapay sinir ağlarındaki karşılığı aktivasyon fonksiyonu ile sağlanır. En basit şekilde, aktivasyon fonksiyonu bir işlem birimine gelen sinyalleri belirli bir fonksiyon ile işler, eğer işlenen sinyal eşik değerinin üstündeyse bir sonraki işlem birimleri için yeni bir sinyal üretilir. Farklı işlevlere hizmet eden birçok aktivasyon fonksiyonu vardır. Yapay Sinir Ağları’nda çeşitli doğrusal ve doğrusal olmayan aktivasyon fonksiyonları denenmiştir. Bu denemeler sonucunda verideki daha karmaşık yapıları öğrenebildiği için doğrusal olmayan aktivasyon fonksiyonlarının kullanımı yaygınlaşmıştır. Bunlardan başlıcaları sigmoid (sig), hiperbolik tanjant (tanh), rektifiye doğrusal birim (ReLU) fonksiyonlarıdır. Doğrusal olmayan bu üç aktivasyonun fonksiyonunun matematiksel denklemleri Tablo 4.3’te, bu denklemlerin grafikleri Şekil 4.8’de gösterilmiştir. Tablodaki denklemlerde geçen  $x$  fonksiyonun girdisini,  $f(x)$  fonksiyonun çıktısını,  $f'(x)$  ise fonksiyonun türevini belirtmektedir. Yapay Sinir Ağları’ndaki kullanımları göz önüne alındığında birçok probleme çözüm olan ReLU aktivasyon fonksiyonu genellikle diğerlerine tercih edilmiştir.

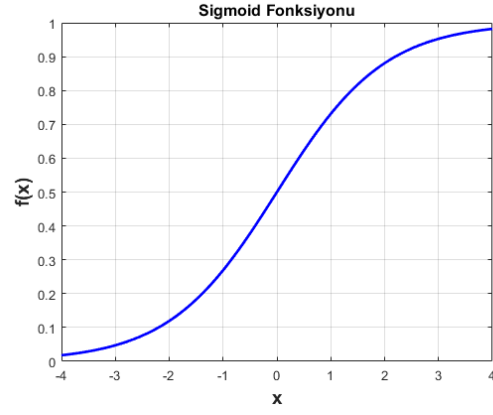
TABLO 4.3: En yaygın üç aktivasyon fonksiyonunun ve türevlerinin denklemleri.

Aktivasyon Fonksiyonu	Fonksiyonun Denklemi	Fonksiyonun Türevi
Sig	$f(x) = \frac{1}{1+e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
Tanh	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$f'(x) = 1 - f(x)^2$
ReLU	$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x \geq 0 \end{cases}$


ReLU'nun diğer fonksiyonlara göre birçok avantajı vardır. Öncelikle ReLU yarı doğrusal bir fonksiyondur. Sıfırdan küçük ve büyük değerler için farklı özellikler sergiler. Bu yüzden hem doğrusal fonksiyonları hem doğrusal olmayan fonksiyonların özelliklerini taşır, bu da onların gradyan temelli yöntemlerle optimize edilmesini kolaylaştırır [50]. Çok katmanlı Yapay Sinir Ağları modellerinde sigmoid ve hiperbolik tanjant gibi doğrusal olmayan fonksiyonların kullanımında “kaybolan gradyan” problemi ile karşılaşmaktadır [64]. Geri yayılım algoritmasıyla iletilen hata değerleri sürekli türev alınarak gerideki katmanlara iletiğinden bir süre sonra bu türev değeri sıfır olacak ve geri yayılımdaki bilgi aktarımı duracaktır. ReLU'da çıktı sinyali için eşik değeri sıfırdır. Sıfırın üstündeki değerler için aktif olduğundan ReLU fonksiyonu bu problemi çözmektedir [50][65]. Ayrıca ReLU'nun diğer aktivasyonlara göre matematiksel açıdan daha kolay işlemlerle gerçekleştirilmesi, derin öğrenme modelinin eğitim aşamasını önemli ölçüde hızlandırmaktadır [63]. Bu avantajlarına ek olarak ReLU aktivasyon fonksiyonunun Evrişimsel Sinir Ağları'yla olan sinerjisi birçok çalışmada kanıtlanmış ve önerilmiştir [66][67][68].

### 4.3.3 Yığın Normalizasyonu Katmanı

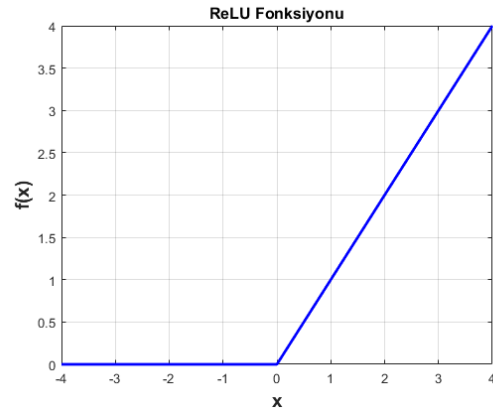
Yığın normalizasyonu tekniği derin sinir ağlarını daha kararlı hale getirmek, optimize etmek ve eğitim aşamasını daha basit hale getirmek amacıyla 2015'te Ioffe ve Szegedy tarafından önerilmiştir [69]. Derin sinir ağları eğitilirken her gradyan güncellemesi sırasında tüm katmanların parametre ilklendirmeleri, ağırlıkları ve girdi dağılımları değişir. Her katmanın



a



b



c

ŞEKİL 4.8: Literatürde sıklıkla kullanılan üç aktivasyon fonksiyonunun grafikleri. a) Sigmoid fonksiyonu, b) Hiperbolik Tanjant fonksiyonu, c) ReLU fonksiyonu.

parametrelerindeki ve girdilerindeki bu rastgele değişime dahili kovaryans kayması denir. İlk katmanlardaki küçük değişimler derin ağda ilerlerken büyüyerek sonraki katmanlarda büyük

değişimlere sebep olabilir. Yığın normalizasyonu modelin eğitimi sırasında oluşan dahili kovaryans kaymasını azaltmak amacıyla kullanılır. Yığın normalizasyonu tekniğinde her katmanın girdilerinin ortalaması ve varyansı yeniden hesaplanır. Bu işlemden sonra katmanların girdileri sabit ve standart bir dağılıma sahip olur. Bu da dahili kovaryans kaymasının etkisini azaltarak eğitim işleminin daha kararlı ve hızlı halde yapılmasını sağlar [50]. Denklem 17’de ortalama hesaplama işlemi ve Denklem 18’de kovaryans hesaplama işlemi gösterilmiştir. Buradaki  $x_i$  girdi vektörünü,  $M$  değeri girdi verisinin boyunu ve  $N$  değeri yığın büyüklüğünü ifade etmektedir. Denklem 19’daki  $y_i$  verisi sonraki katmanlara beslenecek olan normalize edilmiş veriyi temsil etmektedir.

$$\mu_N = \frac{1}{M} \sum_{i=1}^M x_i \quad (17)$$

$$\sigma_N^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \mu_N)^2 \quad (18)$$

$$y_i = \frac{x_i - \mu_N}{\sqrt{\sigma_N^2 - \epsilon}} \quad (19)$$

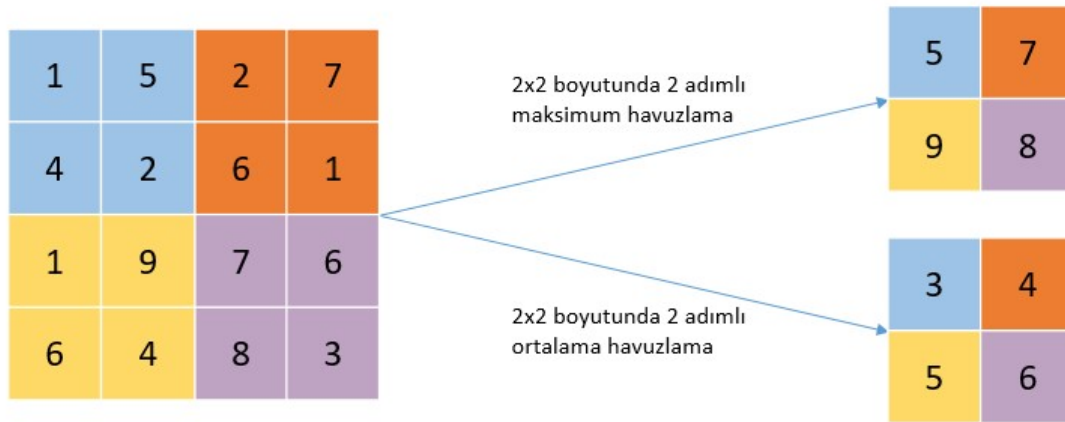
Yığın normalizasyonu yönteminin derin sinir ağının performansını iyileştiren birkaç etkisi daha vardır. Birincisi, doğrusal olmayan aktivasyon fonksiyonlarından önce girdi verisini normalize ederek çıktı verisinin değerinin çok fazla büyümesini veya küçülmesini engeller. İkincisi, modelin normalden daha büyük öğrenme hızlarıyla eğitilmesini sağlar. Üçüncüsü, eğitim sırasında düzenleme uygulayarak genelleme hatasını düşürür ve modelin aşırı uyum ihtimalini azaltır. Böylece modele ekstra katmanlar eklenmesini engeller.

#### 4.3.4 Havuzlama Katmanı

Bir evrişim katmanı genelde üç aşamadan oluşur. İlk aşamada evrişim işlemi, ikinci aşamada aktivasyon işlemi, son aşamada da havuzlama işlemi yer alır. Evrişim işleminden sonra

oluşan öznitelik haritaları girdi verisindeki özniteliklerin (nesne, şekil, kenar, çizgi, köşe, doku vb.) kesin pozisyonuna bağlıdır. Bu da girdi verisindeki özniteliğin pozisyonundaki küçük bir değişim (kırpma, döndürme, kaydırma vb.) nedeniyle evrişim işlemi sonrası farklı bir öznitelik haritası oluşmasına neden olur. Bu durumu çözmek amacıyla sinyal işleme algoritmaları aşağı örnekleme yöntemini kullanır. Havuzlama işlemi aşağı örnekleme yönteminin geçerli bir örneğidir. Havuzlama katmanı evrişim işlemi sonrası oluşan tüm öznitelik haritalarına uygulanır ve yine aynı sayıda havuzlanmış öznitelik haritası çıkarır. Böylece girdi verisindeki küçük değişimlerden bağımsız havuzlanmış yeni veri oluşur [50].

Havuzlama fonksiyonu bir pencereyi girdi verisi üzerinde gezdirerek pencere içerisine düşen belirli bir komşuluktaki verilerin havuzlama tekniğine göre istatistiğini hesaplar ve her pencere için yeni bir değer oluşturur. En çok kullanılan havuzlama teknikleri maksimum havuzlama ve ortalama havuzlamadır. Maksimum havuzlama da pencere içerisine düşen verilerin maksimumunu hesaplanır ve öznitelik haritasına yazılır. Ortalama havuzlama da ise pencere içerisine düşen verilerin ortalaması hesaplanır ve öznitelik haritasına yazılır. Şekil 4.9’da iki temel havuzlama yöntemi gösterilmiştir.



ŞEKİL 4.9: İki boyutlu maksimum havuzlama ve ortalama havuzlama örnekleri.

Girdi verisindeki deęişime bağımsızlık yaratmasına ek olarak havuzlama işleminin başka artıları da vardır. Havuzlama sırasında aşağı örneklenen verinin uzamsal boyutları küçüldüğü için modelde öğrenilecek parametre (ağırlık) sayısı azalacak, sonraki katmanların matematiksel ve istatistiksel hesaplama yükleri azalacak, kullanılan hafıza alanı küçülecek ve eğitim hızlanacaktır. Ayrıca parametre sayısının azalması aşırı uyum ihtimalini de düşürecektir. Tüm bunlar evrişim katmanındaki filtrelerin de özellikleri olmasına rağmen havuzlama işlemi daha kararlı ve basit bir yöntemdir.

#### 4.3.5 Tam Bağlantı Katmanı

Bu katmandaki her çıktı verisi her girdi verisinin ağırlıklandırılarak bir aktivasyon fonksiyonundan geçirilmesiyle oluşur. Denklem 20'deki  $x$  girdi verisini,  $w$  ağırlık katsayısını,  $b$  eğilim katsayısını,  $f$  uygulanan aktivasyon fonksiyonunu ve  $y$  çıktı verisini temsil etmektedir. Tam bağlantı katmanı geçmişte çeşitli makine öğrenmesi görevleri için kullanılsa da, Evrişimsel Sinir Ağları ve Tekrarlayan Sinir Ağları'nın yaygınlaşması ve başarılarını kanıtlamasıyla kullanımı azalmıştır. Son zamanlarda genellikle Evrişimsel Sinir Ağları'nın son katmanlarında, verinin düzleştirilmesi ve öğrenilen yüksek seviyeli özneteliklerin sınıflandırma amacıyla çıktı katmanına beslenmesinden sorumludur [70].

$$y_i = f \left( \sum_j^K w_{ji} \cdot x_j + b \right) \quad (20)$$

#### 4.3.6 Sınıflandırma (Çıktı) Katmanı

Sınıflandırma katmanı modelin son katmanıdır. Kendinden önceki katmanın çıktısı düzleştirilip sınıflandırma katmanına beslenir. Sınıflandırma katmanı girdi verilerindeki sınıf sayısı kadar nöron içerir. Her nöron kendisine iletilen ağırlıklandırılmış veriyi bir aktivasyon fonksiyonundan geçirir ve bir çıktı verisi üretir. Nöronların çıktılarının istatistiksel dağılımına bakılarak her sınıf için bir olasılık değeri hesaplanır ve en yüksek olasılıklı sınıfa karar



verilir. Bu katmanda aktivasyon fonksiyonu olarak genelde sigmoid veya softmax fonksiyonları kullanılır. Genellikle ikili sınıflandırma problemlerinde kullanılan sigmoid fonksiyonu Bölüm 4.3.2’de gösterilmiştir. Sigmoid fonksiyonunun çoklu sınıf problemlerinde kullanılan karşılığı softmax fonksiyonu da Denklem 21’de gösterilmiştir. Burada  $z$  çıktı katmanına beslenen girdi vektörünü,  $z_i$  girdi vektörünün elemanlarını,  $e^{z_i}$  girdi vektörünün üstel halini,  $K$  toplam sınıf sayısını ve  $j$  sınıf sayacını temsil etmektedir.


$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (21)$$

#### 4.4 Tekrarlayan Sinir Ağları

Bir YSA türü olan Tekrarlayan Sinir Ağı (TSA) ardışık dizi şeklindeki verileri işlemek amacıyla ilk kez 1986’da Rumelhart tarafından ortaya atılmıştır [71]. ESA’ların iki boyutlu görüntü ve video gibi verilerin işlenmesi için özelleştirilmesine benzer olarak, TSA’lar da tek boyutlu ardışık verilerin işlenmesi için özelleştirilmiştir. Bu yüzden TSA’lar genellikle metin, ses ve spektrum gibi tek boyutlu ardışık veriler üzerinde kullanılır. Literatürdeki TSA’lar ile metin verisi kullanılarak el yazısı tanıma, otomatik çeviri ve doğal dil işleme, ses verisi kullanılarak konuşma tanıma, modülasyon tanıma ve anomali tespiti, spektrum verisi kullanılarak da frekans tespiti, hedef tespiti ve anomali tespiti gibi işlevler gerçekleştirilmiştir. Ayrıca TSA’lar ve ESA’lar birleştirilerek yapılan bazı çalışmalarda görüntü manşetleme işlevi de yapılmıştır.

TSA’yı diğer sinir ağlarından ayıran en önemli özelliği girdi ve çıktı bilgilerini hafızasında tutabilmesidir. Diğer tüm sinir ağlarında girdi verileri birbirinden bağımsız olarak beslenir ve birbirinden bağımsız çıktılar elde edilir. Girdi verileri arasında hiçbir ilişki kurulmaz. Girdi verisi ağa girip çıktıktan sonra unutulur. Ancak TSA’da girdi verileri birbiriyle bağlantılıdır. TSA’daki bir işlem birimi verilen girdiyi işler ve ürettiği çıktıyı bir sonraki işlem biriminin girdisi olarak besler. Bundan dolayı bir işlem biriminin çıktısı önceki işlem birimlerinin girdileriyle bağlantılıdır. TSA’lardaki işlem birimlerinin zamansal dizi halinde birbirilerine

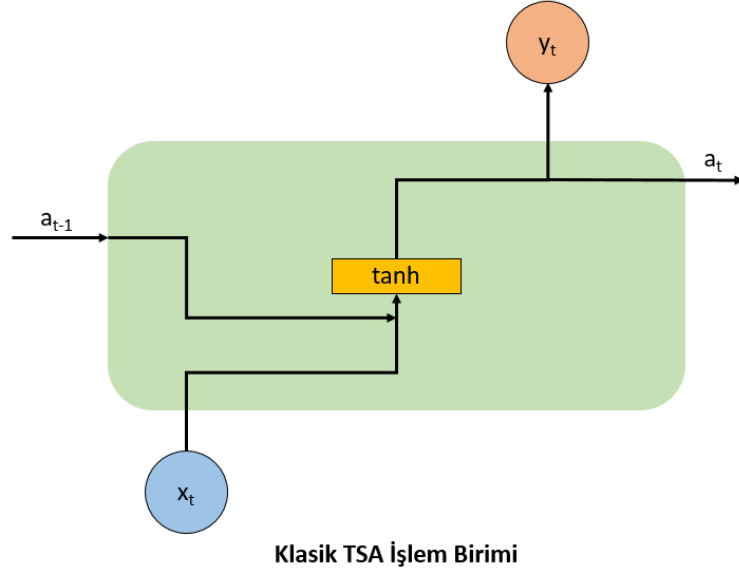
bu şekilde bağlanması ile tek yönlü bir grafik oluşturulur. Bir gizli katman içeren klasik bir TSA modelinin tek yönlü grafiği Şekil 4.10'da gösterilmiştir. Şekildeki  $x = [x_1, x_2, \dots, x_t]$  girdi verisini,  $y = [y_1, y_2, \dots, y_t]$  çıktı verisini,  $a = [a_1, a_2, \dots, a_{t-1}]$  bir önceki birimden gelen bilgiyi ve  $h = [h_1, h_2, \dots, h_t]$  işlem birimini temsil etmektedir.



ŞEKİL 4.10: Tek katmanlı TSA yapısı.

Şekil 4.11'de TSA'lardaki işlem biriminin örneği gösterilmiştir. Bu işlem biriminde girdi verisi ile bir önceki birimden gelen bilgi arka arkaya eklendikten sonra hiperbolik tanjant (tanh) fonksiyonundan geçirilir. Böylece diğer birimlere iletilecek bilgiler elde edilmiş olur. Bu bilgiler de softmax fonksiyonundan geçirildikten sonra çıktı verisi olarak dışarı verilir. Bu işlem biriminin içindeki işlemler iki denklem ile ifade edilmiştir. TSA'daki bir işlem biriminin bir sonraki birime ilettiği bilgi Denklem 22'de, çıktısı ise Denklem 23'te verilmiştir. Denklemlerdeki  $W$  değerleri ağırlık matrislerini,  $t$  zaman adımını,  $f$  ve  $g$  ise aktivasyon fonksiyonlarını belirtmektedir. Kullanılan  $f$  ve  $g$  fonksiyonları genellikle hiperbolik tanjant ve softmax aktivasyon fonksiyonları olarak temsil edilir. TSA'lardaki hafıza önceki katmanlardan sonraki katmanlara iletilen  $a_t$  değerleri ile sağlanır.

TSA'nın bir diğer önemli özelliği ise bir katmandaki tüm işlem birimlerinin aynı ağırlıkları kullanmasıdır. Bu özellik sayesinde TSA'larda çok az sayıda parametre bulunur. Klasik TSA'ların en büyük dezavantajı ise kaybolan veya patlayan gradyan problemidir. TSA'larda uzun süreli hafızayı sağlamak amacıyla daha fazla işlem birimi kullanılması gerekir. Ancak işlem birimi sayısı arttıkça geri yayılım sırasında hesaplanan gradyanlar katlanarak azalacak



ŞEKİL 4.11: Klasik TSA'daki işlem birimi.

veya artacak, sonunda da güncellenen ağırlıklar sinir ağına eğitime katkı sağlamayacaktır. Klasik TSA'larda da az sayıda işlem birimi kullanıldığından uzun süreli hafızanın olması mümkün değildir. Ancak klasik TSA'lardan farklı olarak bazı özelleşmiş TSA türlerinde bu sorunun üstesinden gelinmiştir.

$$a_t = f(W_{aa} \cdot a_{t-1} + W_{ax} \cdot x_t + b_a) \quad (22)$$

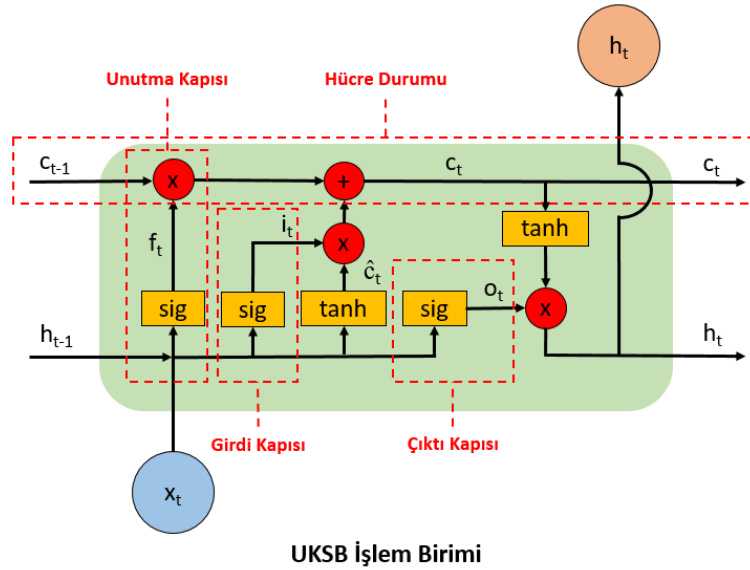
$$y_t = g(W_{ay} \cdot a_t + b_y) \quad (23)$$

#### 4.4.1 Uzun Kısa Süreli Bellek

TSA'ların en yaygın türlerinden biri olan Uzun Kısa Süreli Bellek (UKSB) ilk kez 1997'de Hochreiter ve Schmidhuber tarafından önerilmiştir [72]. Bu çalışmada klasik TSA'ların sorun yaşadığı kaybolan gradyan problemini çözen ve daha uzun süreli hafıza kullanımına

olanak sağlayan bir model tasarlanmıştır. Önerilen UKSB'nin kullanımı ile zaman aralığı 1000 adımdan fazla olan veriler arasında bağlantı kurulabildiği görülmüştür.

Klasik bir TSA'da bir işlem birimi bir önceki işlem birimin çıktısını ve kendi girdisini ağırlıklandırıp arka arkaya ekleyerek hiperbolik tanjant (tanh) aktivasyon katmanından geçirir. Daha sonra bunun sonucunu da softmax fonksiyonundan geçirerek çıktısını üretir. UKSB modelindeki bir işlem birimi ise bundan tamamıyla farklıdır. Şekil 4.12'de UKSB'deki işlem birimi gösterilmiştir. Diğer işlem birimlerinden farklı olarak bu birim içerisinde dört farklı katman vardır. Bu katmanların biri Şekil 4.12'deki UKSB işlem biriminin üst kısmında bulunan ve yatay çizginin işleyişini temsil eden "hücre durumu" adı verilen katmandır. Diğer üç katman ise "kapı" adı verilen yapılardan oluşur. Bu kapılar hücre durumuna bilgi ekleme ve çıkarma işlemlerini yürütür. Bu kapılar bir aktivasyon fonksiyonu yardımıyla açılarak veya kapatılarak bilginin kullanılıp kullanılmayacağına karar verir. Kapıların açık veya kapalı olması sigmoid (sig) aktivasyon fonksiyonu ile sağlanır. Bir UKSB işlem biriminin içerisinde üç tür kapı bulunur. Bu kapılara "giriş kapısı", "çıkış kapısı" ve "unutma kapısı" adı verilmiştir. Bu kapılar belirli işlemler uygulayarak elde ettikleri sonuçları hücre durumu aracılığıyla bir sonraki birimlere veya çıktı bilgisi olarak dışarıya aktarır.



ŞEKİL 4.12: UKSB'deki işlem birimi.

Şekil 4.12'deki UKSB işlem biriminin en solunda bulunan, girdi verisini ve bir önceki birimin çıktısını alıp sigmoid fonksiyonundan geçiren katmana unutmaya kapısı denir. Unutmaya kapısı bir önceki işlem biriminden gelen bilginin saklanıp saklanmayacağına sigmoid fonksiyonu kullanarak karar verir. Bu katmanda girdi verisi ve bir önceki birimin çıktı verisi arka arkaya eklenip ağırlıklandırılarak sigmoid fonksiyonundan geçirilir. Bu fonksiyondan çıkan sonuç sıfıra yakın ise hücre durumuna hafızayı silmesi, çıkan sonuç bir ise hafızayı koruması belirtilmiş olur. Unutmaya kapısının matematiksel işleyişi Denklem 24'te verilmiştir. Denklemdaki  $t$  zaman adımını,  $\sigma$  sigmoid fonksiyonunu,  $f_t$  unutmaya kapısının çıktısını,  $W_f$  unutmaya kapısının ağırlık matrisini,  $h_{t-1}$  bir önceki birimin çıktısını,  $x_t$  girdi verisini,  $b_f$  ise unutmaya kapısındaki eğilim sabitini göstermektedir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (24)$$

Unutmaya kapısının hemen sağındaki sigmoid ve hiperbolik tanjant fonksiyonlarını içeren katmana girdi kapısı denir. Girdi kapısı arka arkaya eklenmiş girdi verisi ve bir önceki birimin çıktısını sigmoid fonksiyonundan geçirerek güncellenecek bilgileri belirler. Bir başka taraftan ise arka arkaya eklenmiş veriyi hiperbolik tanjant fonksiyonundan geçirerek güncellenecek bilgileri önemine göre ağırlıklandırır ve hücre durumuna bir güncelleme bildirir. Girdi kapısının matematiksel işleyişi Denklem 25'te ve Denklem 26'da verilmiştir. Denklemlerdeki  $t$  zaman adımını,  $\sigma$  sigmoid fonksiyonunu,  $i_t$  girdi kapısının çıktısını,  $c_t$  güncelleme bilgisini,  $W_i$  ve  $W_c$  ağırlık matrislerini,  $h_{t-1}$  bir önceki birimin çıktısını,  $x_t$  girdi verisini,  $b_i$  ve  $b_c$  ise eğilim sabitlerini göstermektedir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (25)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (26)$$

Bu aşamada unutmaya kapısından ve girdi kapısından çıkan veriler hücre durumunu güncellemek için kullanılır. Unutmaya kapısının çıktısı bir önceki birimden gelen hücre durumuyla çarpılır ve unutulacak veriler hafızadan silinir. Daha sonra girdi kapısının çıktısından gelen güncellemeler ile hücre durumu toplanır ve bir sonraki birime iletilecek yeni hücre durumu belirlenir. Denklem 27’de hücre durumu güncellemesinin matematiksel işlemleri gösterilmiştir. Denklemdaki  $c_t$  yeni güncellenmiş hücre durumunu,  $f_t$  unutmaya kapısının çıktısını,  $c_{t-1}$  bir önceki birimden gelen hücre durumunu,  $i_t$  girdi kapısının çıktısını,  $\tilde{c}_t$  güncelleme bilgisini belirtmektedir.

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (27)$$

UKSB biriminin en sağında bulunan son katmanı çıktı kapısı olarak adlandırılır. Çıktı kapısında girdi verisi ve bir önceki birimden gelen bilgi sigmoid fonksiyonundan geçirilerek hücre durumundan çıktı olarak üretilecek bilgilerin filtrelenmesi sağlanır. Daha sonra hücre durumundaki bilgi hiperbolik tanjant fonksiyonuyla ağırlıklandırılarak sigmoidin çıktısıyla çarpılır. Bunun sonucunda hücre durumundaki belirli bilgiler ağırlıklandırılmış halde çıktı olarak üretilir. Denklem 28’de ve Denklem 29’da çıktı kapısının matematiksel işlemleri gösterilmiştir. Denklemlerdeki  $o_t$  hücre durumundan çıktı olarak verilecek bilgileri,  $h_t$  çıktı kapısının sonucunu,  $W_o$  çıktı kapısının ağırlık matrisini,  $b_o$  ise çıktı kapısının eğilim sabitini temsil etmektedir.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (28)$$

$$h_t = o_t * \tanh(c_t) \quad (29)$$

## 5. GELİŞTİRİLEN SİNİR AĞI MODELLERİ


Bu tez kapsamında, hiperspektral görüntülerde kimyasal maddelerin tespitini yapmak amacıyla temel olarak üç farklı derin öğrenme modeli incelenmiştir. Birinci model tek boyutlu ESA modeli, ikinci model iki boyutlu ESA modeli ve son model ise UKSB modelidir. Geliştirilen tüm modeller dört kimyasal maddenin tespiti için dört farklı veri kümesiyle ve farklı hiperparametre kümeleriyle eğitilmiştir. Böylece her kimyasal maddenin tespiti için en uygun modelin bulunması amaçlanmıştır. Nihai modeller elde edilirken birçok mimari yapısı ve yüzlerce hiperparametre küme denenmiştir.

### 5.1 Tek Boyutlu Evrişimsel Sinir Ağı Modeli

Tek boyutlu ESA modelinde, adından da anlaşılacağı gibi, girdi verisi tek boyutlu bir vektör olarak beslenir ve tüm katmanlarında tek boyutlu işlemler uygulanır. Bu modelde girdi verisi olarak hiperspektral görüntülerin spektral bantlarındaki  $1 \times 548$  boyutundaki spektral vektör direkt olarak kullanılmıştır. Bundan sonraki kısımlarda kolaylık açısından bu modelden ESA-1 olarak bahsedilecektir.

Geliştirilen ESA-1 mimarisi üç evrişim bloğu, bir tam bağlı katman ve bir çıktı katmanından oluşmaktadır. İlk iki evrişim bloğu sırasıyla evrişim katmanı, yığın normalizasyonu katmanı, aktivasyon katmanı ve havuzlama katmanından meydana gelmiştir. Son evrişim bloğunda bunlardan farklı olarak havuzlama katmanı bulunmamaktadır. Evrişim katmanları sırasıyla 32, 64 ve 128 filtre içermektedir. Bu filtrelerin hepsinin adım sayısı 1 ve boyutları da sırasıyla 21, 51, 101 olarak ayarlanmıştır. Tüm evrişim bloklarında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Havuzlama katmanında  $2 \times 1$  boyutlu 2 adımlı maksimum havuzlama uygulanmıştır. Evrişim bloklarının ardından 128 nöronlu bir tam bağlı katman gelmektedir. Bu katmandan sonra veriler softmax aktivasyon fonksiyonu ile sınıflandırılmak üzere sınıflandırma (çıkı) katmanına iletilmiştir. Geliştirilen ESA-1 mimarisi Şekil 5.1'de

görselleştirilmiştir. Şekildeki EK işlemi evrişim katmanını, YN işlemi yığın normalizasyonu katmanını, ReLU işlemi aktivasyon fonksiyonunu, MH işlemi maksimum havuzlama katmanını, TBK işlemi ise tam bağlı katmanı temsil etmektedir.



ŞEKİL 5.1: Tek boyutlu ESA mimarisindeki katmanların, her katmandaki veri boyutlarının ve temel katmanlar arasında yapılan işlemlerin gösterimi.

Kimyasal-1, Kimyasal-2, Kimyasal-3 ve Kimyasal-4 için geliştirilen modellerde öğrenme hızı parametresi sırasıyla 0.001, 0.01, 0.001 ve 0.005, yığın boyu parametresi sırasıyla 1, 1, 256 ve 64, eğitim tur sayısı parametresi sırasıyla 5, 3, 20 ve 20 olarak ayarlanmıştır. Kimyasal-1 ve Kimyasal-2 için geliştirilen modellerde optimizasyon yöntemi olarak SGD yöntemi kullanılırken, Kimyasal-3 ve Kimyasal-4 için geliştirilen modellerde Adam yöntemi kullanılmıştır. Tüm hedef tipleri için en uygun şekilde ayarlanmış olan hiperparametreler Tablo 5.1'de gösterilmiştir. En iyi hiperparametre kümeleri bulunurken eğitim sırasında azalan öğrenme hızı ve erken durdurma gibi yöntemlerden faydalanılmıştır. Azalan öğrenme hızı yöntemi eğitim sırasında belirli turlarda öğrenme oranını adaptif olarak azaltma tekniğidir. Azalan öğrenme hızı modelin sonuçlarına direkt bir etkide bulunmasa da en uygun öğrenme



hızının belirlenmesi için faydalı olmuştur. Erken durdurma yöntemi ise belirli bir tur sayısından sonra modelin kaybı azalmaya devam etmediğinde eğitimi durdurmaya yarayan bir uygulamadır. Erken durdurma yönteminin uygulanması nihai eğitim tur sayısı parametresi için önemli bir adım olmuştur.

TABLO 5.1: Tek boyutlu ESA mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri.


Model	Öğrenme Hızı	Yığın Boyu	Eğitim Tur Sayısı	Optimizasyon Yöntemi
Kimyasal-1	0.001	1	5	SGD
Kimyasal-2	0.01	1	3	SGD
Kimyasal-3	0.001	256	20	Adam
Kimyasal-4	0.005	64	20	Adam

## 5.2 İki Boyutlu Evrişimsel Sınır Ağı Modeli

İki boyutlu ESA modelinde girdi verisi ve kullanılan tüm katmanlar iki boyutlu haldedir. Geliştirilen iki boyutlu ESA modelinde girdi verisi olarak hiperspektral görüntülerin spektral bantlarındaki bilgi kullanılmıştır. ESA-1'den farklı olarak  $1 \times 548$ 'lik tek boyutlu spektral vektörler basit bir yeniden biçimlendirme işlemiyle iki boyutlu hale getirilmiştir. Tez çalışması süresince veriler çeşitli formlarda iki boyutlu hale getirilmiş ve performans açısından en uygun bulunan iki boyutlu form eğitim ve test aşamalarında kullanılmıştır. Bundan sonraki kısımlarda kolaylık açısından bu modelden ESA-2 olarak bahsedilecektir.

Verilerin iki boyutlu forma getirilmesi iki aşamada gerçekleştirilmiştir. Önce  $1 \times 548$  boyutlu spektral vektörün başına ve sonuna 14 tane sıfır eklenerek verinin boyutunun  $1 \times 576$  olması sağlanmıştır. Sonra elde edilen  $1 \times 576$  boyutundaki vektör,  $24 \times 24$  boyutunda bir matrisle dönüştürülmüştür. Spektral verinin başına ve sonuna sıfır eklenmesinin nedeni iki boyutlu modelin girdisinin kare formda olmasını sağlamaktır. 548'e en yakın değer 24'ün karesi olan 576 olduğu için bu değer seçilmiştir. Bu sayede evrişim ve havuzlama işlemleri daha kolay hesaplanabilir hale gelmiştir. Veriler iki boyutlu hale getirilirken  $1 \times 576$  boyutundaki

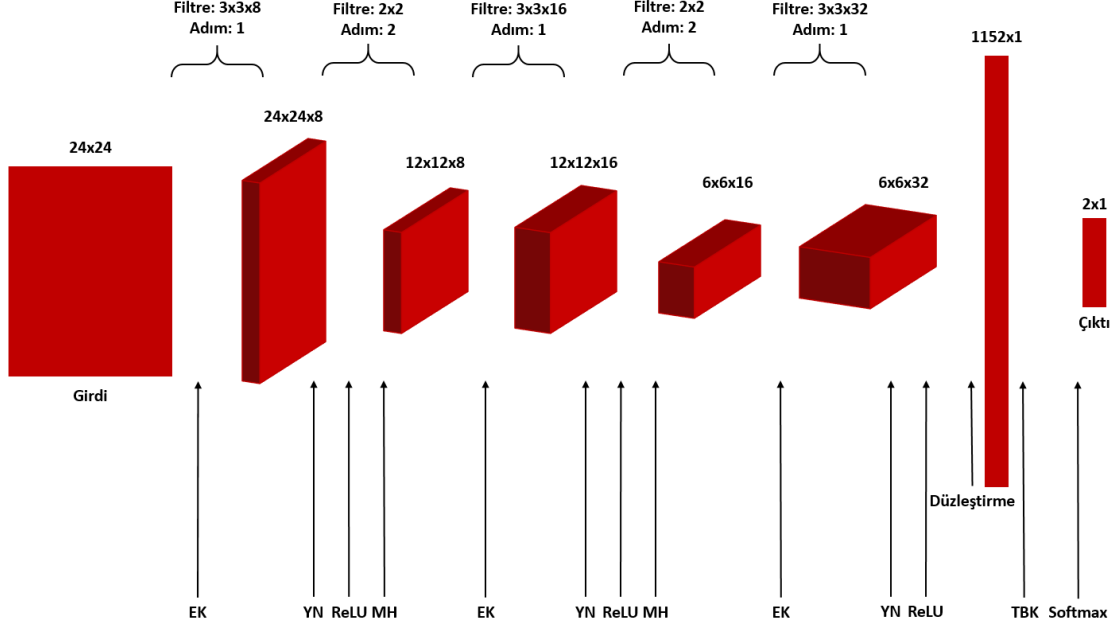
vektörün ilk 24 değeri matrisin ilk satırını, ikinci 24 değer matrisin ikinci satırını oluşturacak şekilde devam ettirilip 24 satır ve 24 sütundan oluşan iki boyutlu veri elde edilmiştir. Tek boyutlu spektral verinin iki boyutlu hale getirilme işlemi Şekil 5.2’de gösterilmiştir.



ŞEKİL 5.2: Bir pikselin spektral verisinin  $1 \times 548$  boyutlu vektörden  $24 \times 24$  boyutlu matrise dönüştürülme işlemi.

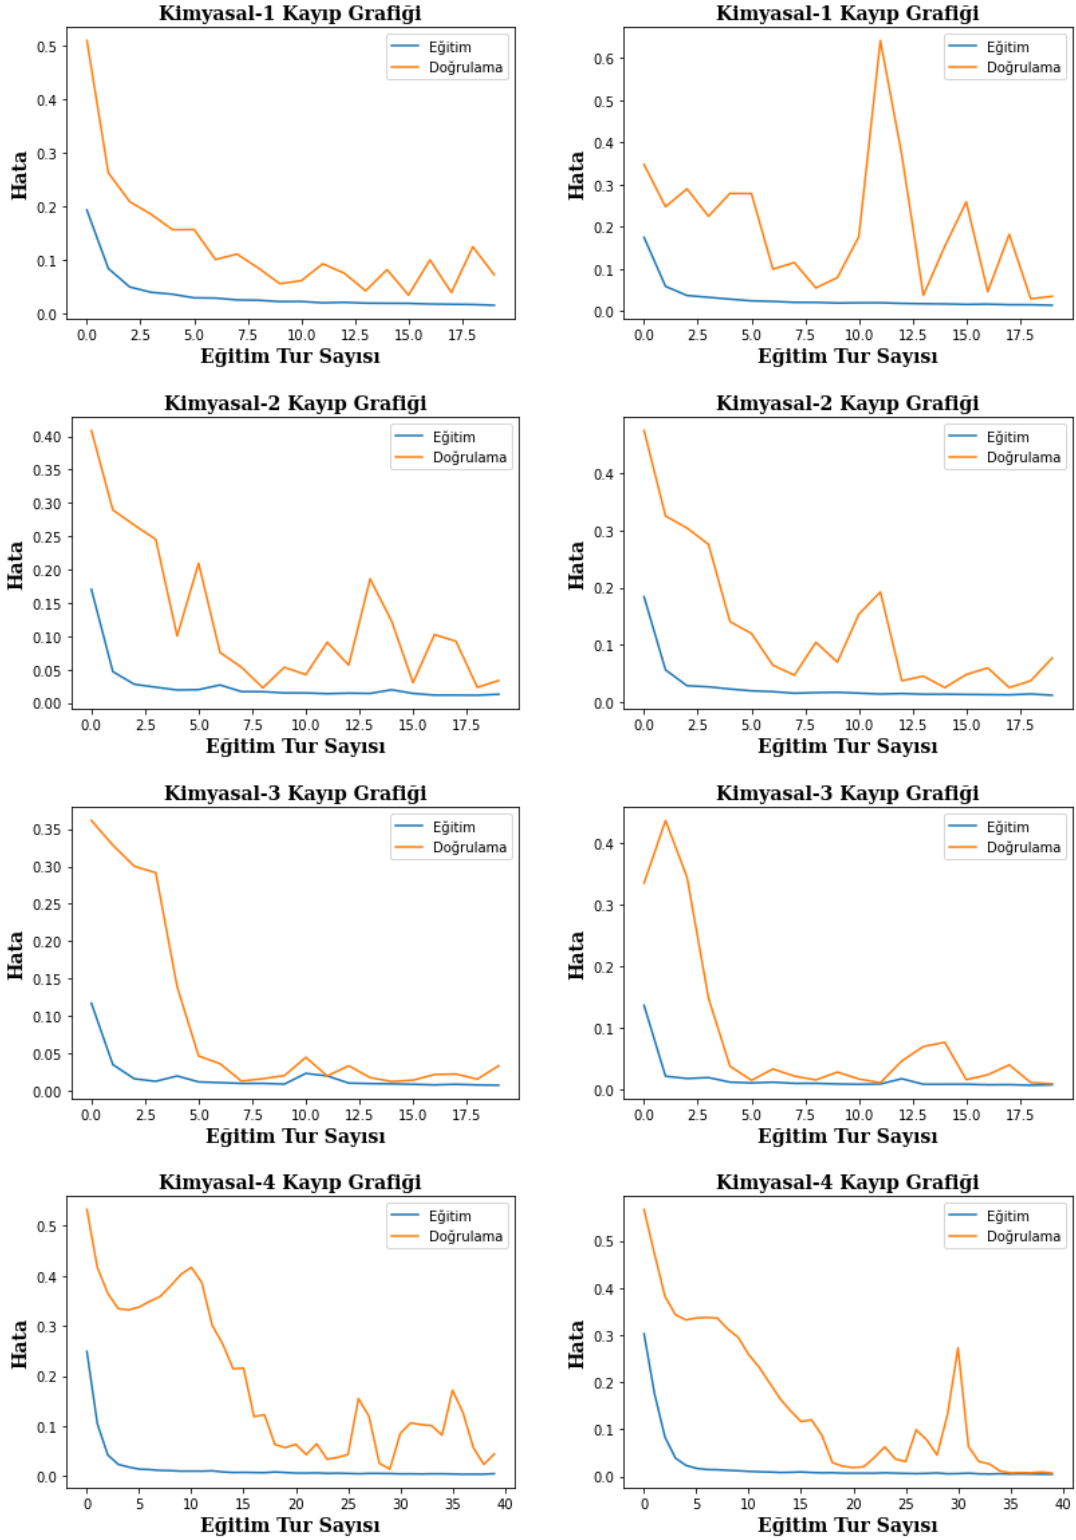
Geliştirilen ESA-2 mimarisi üç evrişim bloğu ve bir çıktı katmanından oluşmaktadır. Her evrişim bloğu ana katman olarak bir evrişim katmanı içermektedir. Evrişim katmanlarında sırasıyla 8, 16 ve 32 adet filtre bulunmaktadır. Tüm evrişim katmanlarındaki filtreler  $3 \times 3$  boyutundadır. Evrişim işlemi sırasında filtrelerin adım parametresi 1 olarak ayarlanmıştır. Her evrişim katmanından sonra sırasıyla yığın normalizasyonu ve aktivasyon katmanları kullanılmıştır. Aktivasyon katmanlarında ReLU aktivasyon fonksiyonu kullanılmıştır. İlk iki evrişim bloğunda bu katmanları maksimum havuzlama katmanı takip etmiştir. Havuzlama boyutu  $2 \times 2$  olarak, havuzun adım parametresi de 2 olarak ayarlanmıştır. Ancak üçüncü evrişim bloğundan sonra herhangi bir havuzlama katmanı bulunmamaktadır. Üç evrişim bloğundan sonra veri düzleştirilerek sınıflandırma (çıktı) katmanına iletilmiştir. Sınıflandırma

katmanında softmax aktivasyon fonksiyonu kullanılarak en yüksek olasılıklı sınıfa çıktı olarak karar verilmiştir. ESA-2 mimarisi Şekil 5.3'te görselleştirilmiştir. Şekilde kısaltmaları verilen işlemler Bölüm 5.1'de verilmiştir.



ŞEKİL 5.3: İki boyutlu ESA mimarisindeki katmanların, her katmandaki veri boyutlarının ve temel katmanlar arasında yapılan işlemlerin gösterimi.

Dört kimyasal için geliştirilen modellerin hiperparametre kümeleri Tablo 5.2'de gösterilmiştir. Bu tablodan da anlaşılacağı üzere ESA-1'deki karşılıklarına kıyasla, modellerin hiperparametrelerinin çoğu değiştirilmiştir. Bunun amacı ESA-2 mimarisin en uygun ve en iyi performansla sonuç üreten modellerin elde edilmek istenmesidir. ESA-2 modellerinde de eğitim sırasında en iyi hiperparametre kümeleri bulunurken azalan öğrenme hızı ve erken durdurma gibi yöntemlerden yararlanılmıştır. Şekil 5.4'te ESA-2'de geliştirilen dört kimyasal modelinin eğitim ve doğrulamaya kümeleri için kayıp fonksiyonlarının grafikleri gösterilmiştir. Bu şekilde her kimyasal modeli için iki kayıp grafiği olmasının sebebi kimyasal modellerinin eğitim sırasında gösterdiği tutarlı davranışı göstermektir. Erken durdurma ve azalan öğrenme hızı yöntemlerinin yanı sıra kayıp fonksiyonlarını gözlemlemekte en iyi hiperparametre kümesinin bulunmasında önemli rol oynamıştır.



ŞEKİL 5.4: ESA-2 mimarisinde dört kimyasal madde için geliştirilen modellerin eğitim ve doğrulama kümelerindeki kayıp fonksiyonlarının grafikleri.

TABLO 5.2: İki boyutlu ESA mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri.

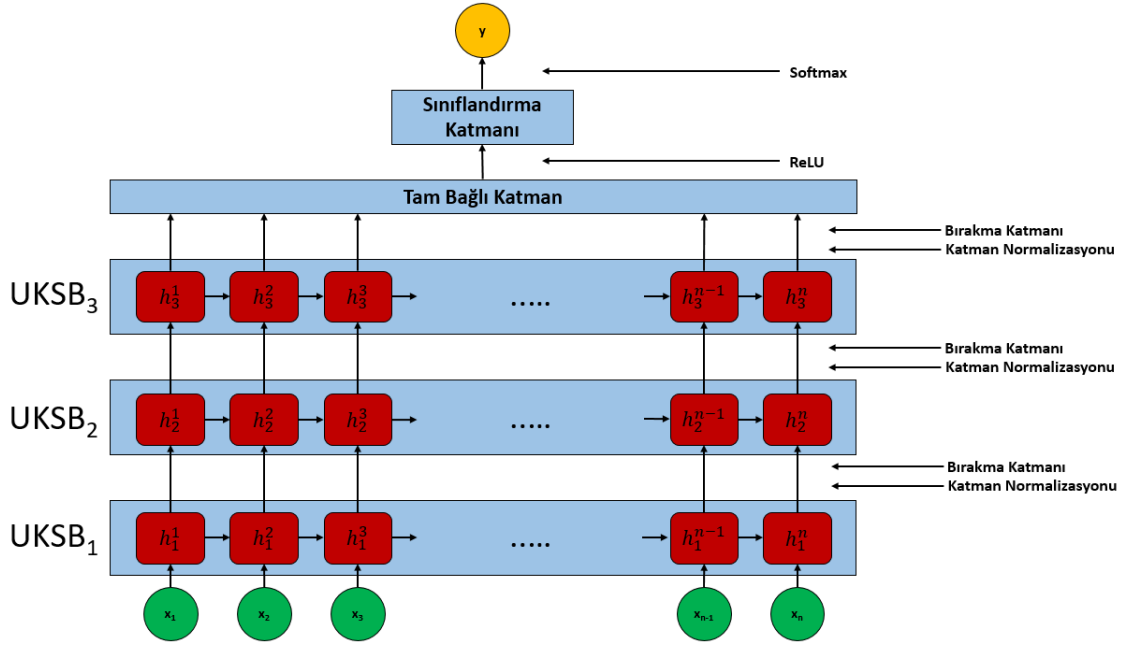
Model	Öğrenme Hızı	Yığın Boyu	Eğitim Tur Sayısı	Optimizasyon Yöntemi
Kimyasal-1	0.005	256	20	Adam
Kimyasal-2	0.001	256	20	Adam
Kimyasal-3	0.01	1	3	SGD
Kimyasal-4	0.001	1024	40	Adam

### 5.3 Uzun Kısa Süreli Bellek Modeli

UKSB modelinde de tıpkı ESA-1'deki gibi hiperspektral görüntülerin spektral bantlarındaki  $1 \times 548$ 'lik vektör verilerin sınıflandırılması için kullanılmıştır. Ancak UKSB modelinde diğer modellerden farklı olarak girdi verileri modele beslenirken minimum-maksimum normalizasyonu yapılmıştır.

Geliştirilen UKSB mimarisi temel olarak üç UKSB katmanı, bir tam bağlı katman ve sınıflandırıcı katmanından oluşmaktadır. Tüm UKSB katmanlarında 256 işlem birimi (nöron) bulunmaktadır. Her UKSB katmanından sonra "katman normalizasyonu" ve "bırakma katmanı" yöntemleri uygulanmıştır. Son UKSB katmanından çıkan veriler 512 işlem birimi içeren tam bağlı katmana iletilmiştir. Tam bağlı katmanda aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Son olarak veriler sınıflandırma katmanına iletilmiştir. Sınıflandırma katmanında softmax aktivasyon fonksiyonu ile tüm sınıflar için olasılıklar belirlenmiş ve ilgili veri için "hedef var" veya "hedef yok" kararı verilmiştir. Tasarlanan UKSB mimarisi Şekil 5.5'te ve bu UKSB mimarisinde dört kimyasal için geliştirilen modellerde kullanılan hiperparametre kümeleri Tablo 5.3'te gösterilmiştir.

ESA mimarilerinden farklı olarak UKSB mimarisinde kullanılan katman normalizasyonu ve bırakma katmanı yöntemleri modellerin performansını artırmak amacıyla belirli işlevleri yerine getirmektedir.



ŞEKİL 5.5: UKSB mimarisindeki katmanların ve katmanlar arasında yapılan işlemlerin gösterimi.

Bölüm 4.3.3'te anlatılan yığın normalizasyonu işleminde, mini-yığınlar kullanılarak yapılan eğitimin her turunda, bir nörona beslenen tüm girdi verileri kullanılarak ortalama ve varyans değerleri hesaplanır ve ilgili nörona beslenen tüm girdi verileri normalize edilir. Bu işlem modelin eğitim süresini önemli ölçüde kısaltıp, çıktı verilerinin daha stabil olmasını sağlasa da bazı dezavantajları vardır. Yığın normalizasyonu işleminin yığın boyuna bağlılığı olduğundan ve TSA modellerine nasıl uygulanacağı belli olmadığından, kullanım alanları sınırlıdır. Bunun üstesinden gelmek için [73]'te katman normalizasyonu yöntemi önerilmiştir. Bu yöntemde bir eğitim turunda bir katmandaki tüm nöronlara beslenen tüm girdi verileri kullanılarak ortalama ve varyans değerleri hesaplanmıştır. Bu yüzden katman normalizasyonu yöntemi değişken boyutlu girdi beslenen modeller, yığın boyu küçük olan modeller ve TSA modelleri için yığın normalizasyonuna göre daha iyidir.

Bırakma katmanında yapılan işlem, eğitim aşamasında rastgele işlem birimlerinin (nöronların) göz ardı edilmesidir. Göz ardı edilen nöronlar eğitimin ileri ve geri yayılımı sırasında kullanılmaz. Bu yüzden bu nöronların parametrelerinde herhangi bir güncelleme yapılmaz. İlk kez [54]'te tanımlanan bu yöntemdeki asıl amaç, çok fazla parametre içeren modellerin

aşırı uyum ihtimalini azaltmaktır. Nöronların eğitim sırasında rastgele bırakılması, nöronlar arasındaki uyumu azaltacağından aşırı uyum ihtimali de azalmış olur. Bu tezde oluşturulan UKSB mimarisi de çok fazla parametre içerdiğinden aşırı uyum durumuna yatkındır. Bunu engellemek adına her UKSB katmanından sonra nöronların %20'sinin her eğitim turunda göz ardı edilmesini sağlayacak bırakma katmanı mimariye eklenmiştir.

TABLO 5.3: UKSB mimarisinde dört kimyasal için hazırlanan modellerin hiperparametre kümeleri.

<b>Model</b>	<b>Öğrenme Hızı</b>	<b>Yığın Boyu</b>	<b>Eğitim Tur Sayısı</b>	<b>Optimizasyon Yöntemi</b>
<b>Kimyasal-1</b>	0.005	256	20	RMSProp
<b>Kimyasal-2</b>	0.001	256	20	Adam
<b>Kimyasal-3</b>	0.01	256	20	RMSProp
<b>Kimyasal-4</b>	0.001	1024	40	Adam

## 6. DENEYSEL SONUÇLAR

Her kimyasal madde üç farklı mimari için yüzlerce hiperparametre kümesiyle eğitilmiştir. En başarılı sonuçlar üreten hiperparametre kümeleri ile eğitilen modellerin tüm parametreleri test aşamasında kullanılmak amacıyla kaydedilmiştir. Geliştirilen tüm modeller girdi verisi olarak bir pikselin spektral bilgisini almış ve o pikselde hedef olup olmadığına karar vermiştir. Ancak bu tezdeki asıl amaç hiperspektral görüntü (imaj) bazında yapılan hedef tespitidir. Bu yüzden hiperspektral görüntülerin tüm pikselleri tek tek sınıflandırılmıştır. Eğer bir hiperspektral görüntünün tek bir pikselinde bile hedef tespit edildiyse görüntü “hedef var”, hiçbir pikselinde hedef tespit edilmediyse görüntü “hedef yok” olarak sınıflandırılmıştır.

Bu ikili sınıflandırma problemini değerlendirmek ve performansını ölçmek amacıyla test aşamasında hem piksel bazında hem de görüntü (imaj) bazında değerlendirme yapılmıştır. Üç mimarideki tüm modeller için daha detaylı olan piksel bazlı değerlendirme yapılmıştır. Ancak imaj bazlı değerlendirme sadece ESA-1 ve ESA-2 mimarisindeki modeller için ele alınmıştır. Bunun nedeni UKSB mimarisindeki modellerin imaj bazında mantıklı sonuçlar üretmemesidir. İmaj bazlı değerlendirmede hiperspektral görüntülerdeki hedef tespiti performansı ele alınmış, piksel bazlı değerlendirmede ise modellerin ne kadar güvenilir olduğu, hangi pikselleri sınıflandırmada zorlandığı ve hangi hedefleri daha rahat tespit edebildiği uygun performans ölçütleri ile ortaya koyulmuştur. Burada en önemli görevlerden biri, var olan hedeflerin tespit edilmesi olsa da, hedef içermeyen görüntülerde hedef bulmamak da bir o kadar önemli bir görevdir. Bu yüzden Doğru Pozitif ve Yanlış Pozitif örnek sayıları kritik biçimde önem arz etmektedir. Bu bağlamda bu değerler ile hesaplanan Kesinlik ve Duyarlılık ölçütleri ana değerlendirme ölçütleri olmuştur. İdeal durumda Kesinlik ve Duyarlılık değerleri %100 olarak hesaplanır. Başarılı bir model elde etmek için bu ölçütlerin ikisinin birden %100’e mümkün olduğunca yakın olması gerekir. Modelin başarısı imaj bazında bakılarak bu ölçütler ile değerlendirilebilir, ama piksel bazındaki sonuçlar imaj bazında farkedilmeyen, modelin başarılı veya başarısız yönlerini gösterebilir. Bu yüzden bir modelin ne kadar başarılı olduğuna önce imaj bazında Kesinlik ve Duyarlılık değerlerine

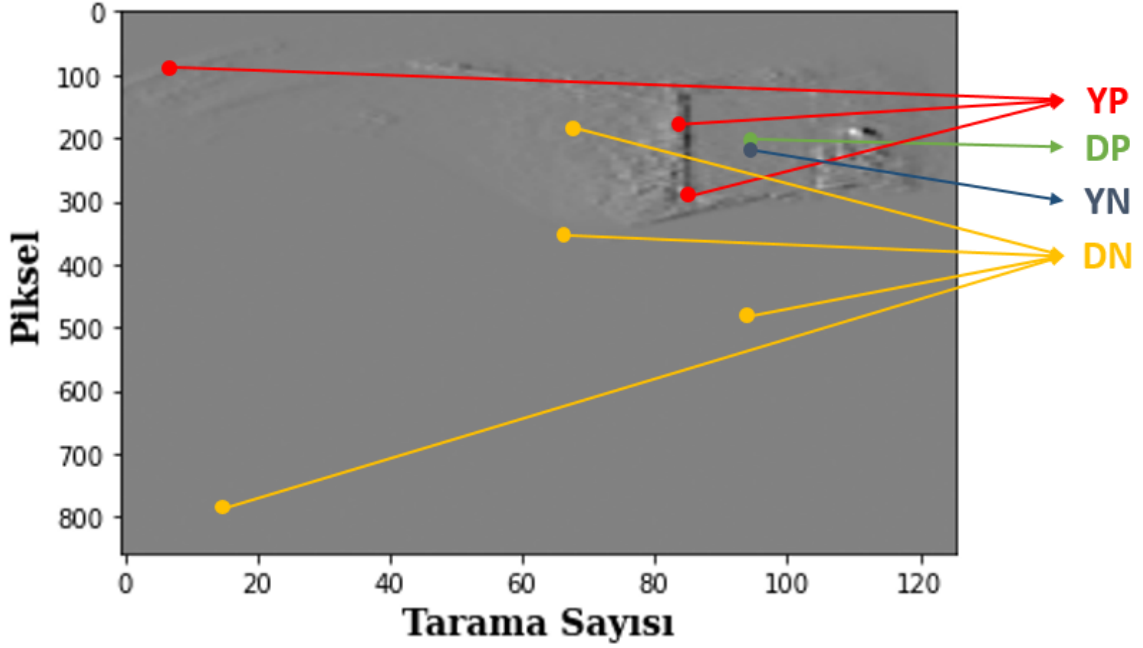


bakılarak, daha sonra da piksel bazında bu ölçütlere bakılarak karar verilmiştir. Tüm modeller için bu ölçütler piksel bazında hesaplanırken önce test edilen hiperspektral görüntüler için tek tek hesaplanmış, daha sonra tüm görüntülerdeki sonuçların ortalaması alınmıştır. Bu ölçütler imaj bazında hesaplanırken test edilen hiperspektral görüntüler değerlendirmeye direkt katkı yapmıştır.

Test aşamasında modellerin performansları ölçülürken her arka plan ve kimyasal kombinasyonu için 50 tane hedef içeren, 50 tane de hedef içermeyen hiperspektral görüntü kullanılmıştır. Hedef içeren görüntüler tablolarda “H+”, hedef içermeyen görüntüler ise “H-” olarak gösterilmiştir. Hedef içeren verilerden Doğru Pozitif ve Yanlış Negatif örneklerin sayıları elde edilirken, hedef içermeyen verilerden Doğru Negatif ve Yanlış Pozitif örneklerin sayıları elde edilmiştir. İmaj bazlı sonuçların gösterildiği tablolarda belirtilen Doğru Pozitif (DP) hedef içeren bir görüntünün “hedef var” olarak sınıflandırılmasına, Yanlış Negatif (YN) hedef içeren bir görüntünün “hedef yok” olarak sınıflandırılmasına, Doğru Negatif (DN) hedef içermeyen bir görüntünün “hedef yok” olarak sınıflandırılmasına ve Yanlış Pozitif (YP) ise hedef içermeyen bir görüntünün “hedef var” olarak sınıflandırılmasına karşılık gelmektedir. Bu terimlerin piksel bazındaki anlamları Şekil 6.1’de gösterilmiştir. Hedef içeren piksel doğru sınıflandırıldıysa DP, yanlış sınıflandırıldıysa YN, hedef içermeyen bir piksel doğru sınıflandırıldıysa DN, yanlış sınıflandırıldıysa YP olarak tanımlanmıştır.

## **6.1 ESA-1 ile Geliştirilen Modellerin Testleri ve Sonuçları**

Dört kimyasal için ESA-1 mimarisi kullanılarak geliştirilen modellerin performansları piksel ve imaj bazında oluşturulmuştur. Bunun sebebi imaj bazında değerlendirme ile kimyasal hedef tespitinde başarılı olan ve olmayan modelleri tespit etmek, piksel bazında değerlendirme ile de bu modellerin neden başarılı olup olmadıklarını incelemektir. Tablo 6.1 ESA-1 mimarisi kullanılarak dört kimyasal için geliştirilen modellerin tüm arka planlar üzerindeki imaj bazlı performansını Kesinlik ve Duryarlılık ölçütlerini ele alarak göstermektedir. Tablo 6.2 ise ESA-1 mimarisi kullanılarak geliştirilen tüm modeller için piksel bazlı değerlendirme sonuçlarını sunmaktadır.



ŞEKİL 6.1: Hiperpsektrel görüntüde tespit edilen DP, YP, DN ve YN piksel örneklerinin gösterimi.

Tablo 6.1'deki verilerden yola çıkarak, Kimyasal-1 için geliştirilen model için tüm arka planlarda Duyarlılık değeri %80'in üstünde de olsa, Kesinlik değeri maalesef hiçbir arka plan için %78'in üzerine çıkamamıştır. Buna rağmen bu model Arka Plan-2 haricindeki tüm arka planlarda nispeten fena olmayan sonuçlar üretmiştir. Arka Plan-2 üzerinde %100 oranında hedef tespiti yapılmış gibi gözükse de, Kesinlik değerinin %52 olarak hesaplanması aslında "hedef var" olarak sınıflandırılan her iki görüntüden birinin YP görüntü olduğunu göstermektedir. Tablo 6.2'deki piksel bazında sonuçlara bakıldığında da görüntülerde tespit edilen şeyin aslında gerçek hedefleri içeren pikseller olmadığı %55 Duyarlılık ve %60 Kesinlik değerleriyle anlaşılmaktadır. Hedef içeren ve içermeyen görüntülerde çok fazla YP piksel tespit edildiği için DP görüntüler tamamıyla güvenilir değildir. Bu görüntülerde "hedef var" olarak sınıflandırılan piksellerin çok büyük bir kısmı aslında YP pikselleridir.

Kimyasal-2 için geliştirilen modelde tüm arka planlarda belirli bir seviyenin üstünde Duyarlılık'la sonuçlar üretilmiştir. Özellikle Arka Plan-1 ve Arka Plan-3 üzerinde %80'in

TABLO 6.1: Dört kimyasal için ESA-1 mimarisi ile geliştirilen modellerin imaj bazlı performans sonuçları.

Arka Plan	İmaj Tipi	Ölçüt	Kimyasal-1 Modeli	Kimyasal-2 Modeli	Kimyasal-3 Modeli	Kimyasal-4 Modeli
Arka Plan-1	H+	DP	40	41	47	49
		YN	10	9	3	1
	H-	DN	39	46	48	35
		YP	11	4	2	15
	Kesinlik		0.78	0.91	0.94	0.76
	Duyarlılık		0.80	0.82	0.95	0.98
Arka Plan-2	H+	DP	50	45	45	48
		YN	0	5	5	2
	H-	DN	5	32	43	40
		YP	45	18	7	10
	Kesinlik		0.52	0.71	0.86	0.82
	Duyarlılık		1.00	0.90	0.90	0.96
Arka Plan-3	H+	DP	45	43	44	43
		YN	5	7	6	7
	H-	DN	36	42	46	39
		YP	14	8	4	11
	Kesinlik		0.76	0.84	0.91	0.79
	Duyarlılık		0.90	0.86	0.92	0.86
Arka Plan-4	H+	DP	41	39	48	48
		YN	9	11	2	2
	H-	DN	33	38	46	38
		YP	17	12	4	12
	Kesinlik		0.70	0.76	0.92	0.80
	Duyarlılık		0.82	0.78	0.96	0.96

üstünde Duyarlılık ve Kesinlik değeriyle sonuçlar elde edilmiştir. Tablo 6.2'den de anlaşılacağı gibi Arka Plan-1 ve Arka Plan-3'te tespit edilen hedefler daha güvenilirdir. Bu arka planlarda gerçek hedef piksellerin çok azı tespit edilse de, bu tespitlerin içerisinde YP piksel sayısı çok azdır. Ancak Arka Plan-2 ve Arka Plan-4 üzerinde %70'lerde Kesinlik değerleriyle diğerlerinden daha az başarı sağlandığı görülmüştür. Bu arka planlarda yapılan tespitler çok sayıda YP görüntü içermektedir. Piksel bazlı sonuçlar incelendiğinde bu arka planlarda hedef olarak tespit edilen piksellerin her dört tanesinden birinin YP piksel olduğu görülmüştür.

Kimyasal-3 için geliştirilen model, ESA-1 mimarisi kullanılarak geliştirilen en başarılı model

TABLO 6.2: Dört kimyasal için ESA-1 mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları.

Arka Plan	Ölçüt	Kimyasal-1 Modeli	Kimyasal-2 Modeli	Kimyasal-3 Modeli	Kimyasal-4 Modeli
Arka Plan-1	Kesinlik	0.85	0.89	0.97	0.71
	Duyarlılık	0.28	0.21	0.33	0.11
Arka Plan-2	Kesinlik	0.60	0.68	0.91	0.72
	Duyarlılık	0.55	0.46	0.38	0.10
Arka Plan-3	Kesinlik	0.77	0.76	0.95	0.75
	Duyarlılık	0.61	0.16	0.25	0.12
Arka Plan-4	Kesinlik	0.71	0.75	0.99	0.76
	Duyarlılık	0.59	0.38	0.31	0.19

olmuştur. Bu modelde tüm arka planlarda %90'ın üstünde Duyarlılık ve %86'nın üstünde Kesinlik değerleriyle sonuçlar üretilmiştir. Piksel bazlı sonuçlar da değerlendirildiğinde üretilen sonuçların oldukça güvenilir olduğu anlaşılmaktadır. Tüm arka planlarda %30 civarında elde edilen Duyarlılık, DP piksel sayısının YN piksel sayısından ciddi şekilde az olduğunu gösterebilir, %95 civarındaki Kesinlik değeri de, çok az sayıda YP piksel tespit edildiğini ortaya koymuştur. Bu da özellikle Kimyasal-3 modelinin neden başarılı olduğunu göstermektedir.

Kimyasal-3 modelinin Arka Plan-2 ve Arka Plan-4 üzerinde başarısının çok fazla düşmemesinin temel nedeni, Kimyasal-3'ün spektrumunun diğer spektrumlardan daha ayırt edici özelliklere sahip olmasından kaynaklanmaktadır. Kimyasal-3'ün soğurum kenarı çok düşük yansıma değerleri ile çok yüksek yansıma değerleri arasında bulunduğundan Arka Plan-2 ve Arka Plan-4 spektrumları Kimyasal-3'ün ayırt edici özelliklerini baskılamayı başaramamıştır. Bu yüzden eğitilen model Kimyasal-3'ün özelliklerini içeren pikselleri doğru tahmin etmeye devam etmiştir.

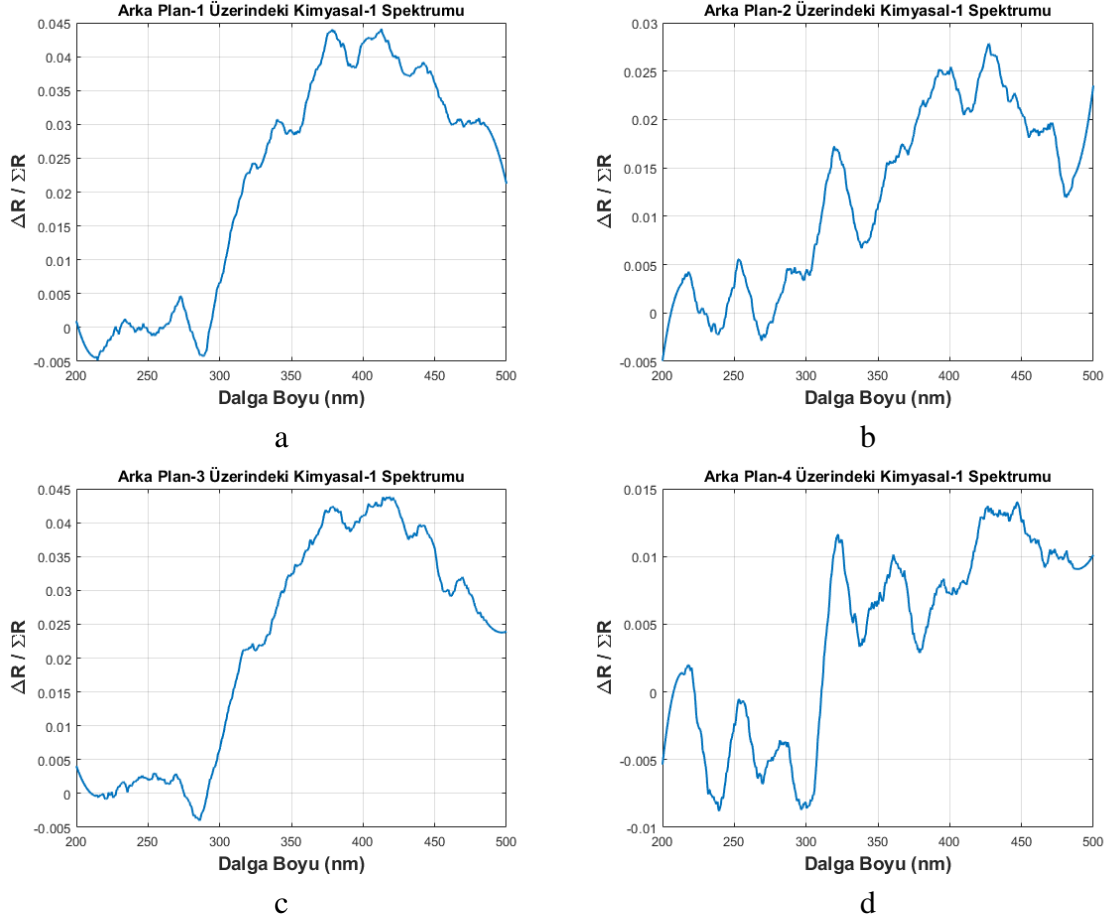
ESA-1 mimarisinde Kimyasal-3 modelinden sonra en başarılı olan Kimyasal-4 için geliştirilen model imaj bazında tüm arka planlarda çok yüksek Duyarlılık'la sonuçlar üretmiştir. Ancak Kesinlik değerlerine bakıldığında bir problem olduğu anlaşılmaktadır. Bu yüzden piksel bazlı sonuçların olduğu Tablo 6.2'den Kimyasal-4 için elde edilen Duyarlılık ve Kesinlik

değerleri incelenmiş ve bu problemin kaynağı görülmüştür. Tüm arka planlarda DP piksel sayısının YN piksel sayısına göre çok az olmasının yanı sıra, neredeyse her üç pikselden birinin “hedef var” olarak yanlış sınıflandırıldığı anlaşılmaktadır.

Kimyasal-4 gibi spektral imzası diğer kimyasallardan ciddi şekilde farklı olan bir madde için bu beklenmedik bir durumdur. Bu durumun Arka Plan-2 ve Arka Plan-4’e özel olmaması da başka bir sorun olduğunu göstermiştir. İncelemeler yapıldığında YP piksellerin çoğunlukla ayakkabının ön alt ucundaki kenar piksellerde tespit edildiği görülmüştür. Ayakkabının ön alt ucunda tespit edilen YP pikseller Şekil 6.6’daki örnek görüntülerde gösterilmiştir. Verilen örneklerde “hedef var” sınıflandırılması yapılan DP bir görüntü ve yine “hedef var” sınıflandırılması yapılan YP bir görüntü verilmiştir.

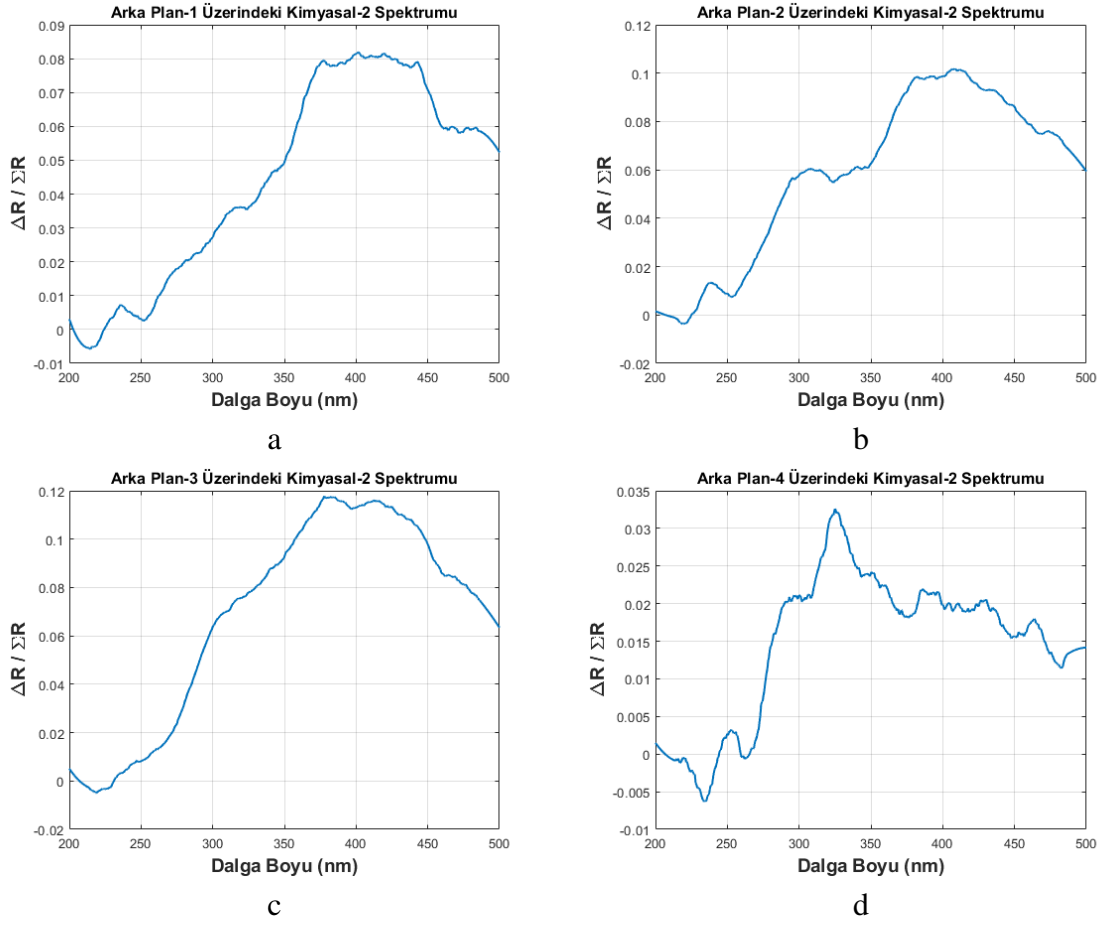
### **6.1.1 Arka Plan Materyalinin Sonuçlara Etkisi**

Hiperspektral Görüntüleme’de, kamera belirli bir çözünürlükte görüntü toplarken, topladığı görüntülerdeki pikseller birden fazla maddenin karışımından oluşabilir. Bu durumda o piksellerin spektrumları da, karışan maddelerin spektrumlarından meydana gelir. Bundan dolayı, eğer bir hedef ile başka bir madde bir piksel içinde karıştıysa, bu maddenin spektrumu hedefin spektrumunu bozabilir ve tespit edilmesini zorlaştırabilir. Bu tez kapsamında hazırlanan veri kümelerinde, hedef kimyasallar bir arka plan materyalinin de üzerinde olduğundan, bu piksellerdeki kimyasalların spektrumu arka plan materyallerinin spektrumları ile karışır. Bu nedenle arka plan materyallerinin spektrum karakteristiğine bağlı olarak, arka planların spektrumları kimyasalların spektrumlarının belirli ölçüde değişmesine neden olur. Arka Plan-1 ve Arka Plan-3 üzerindeki kimyasalların spektrumları çok fazla değişime uğramasa da, Arka Plan-2 ve Arka Plan-4 üzerindeki kimyasalların spektrumları zaman zaman ciddi değişimlere uğramıştır. Tespit işlemi sırasında, geliştirilen algoritma soğurum kenarı gibi öznitelikleri bulmaya çalıştığından, değişime uğrayan kimyasal madde spektrumlarındaki soğurum kenarları kaybolduğunda veya bozulduğunda kimyasal maddelerin tespiti zorlaşmaktadır.



ŞEKİL 6.2: Kimyasal-1'in tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-1 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-1 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-1 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-1 spektrumu.

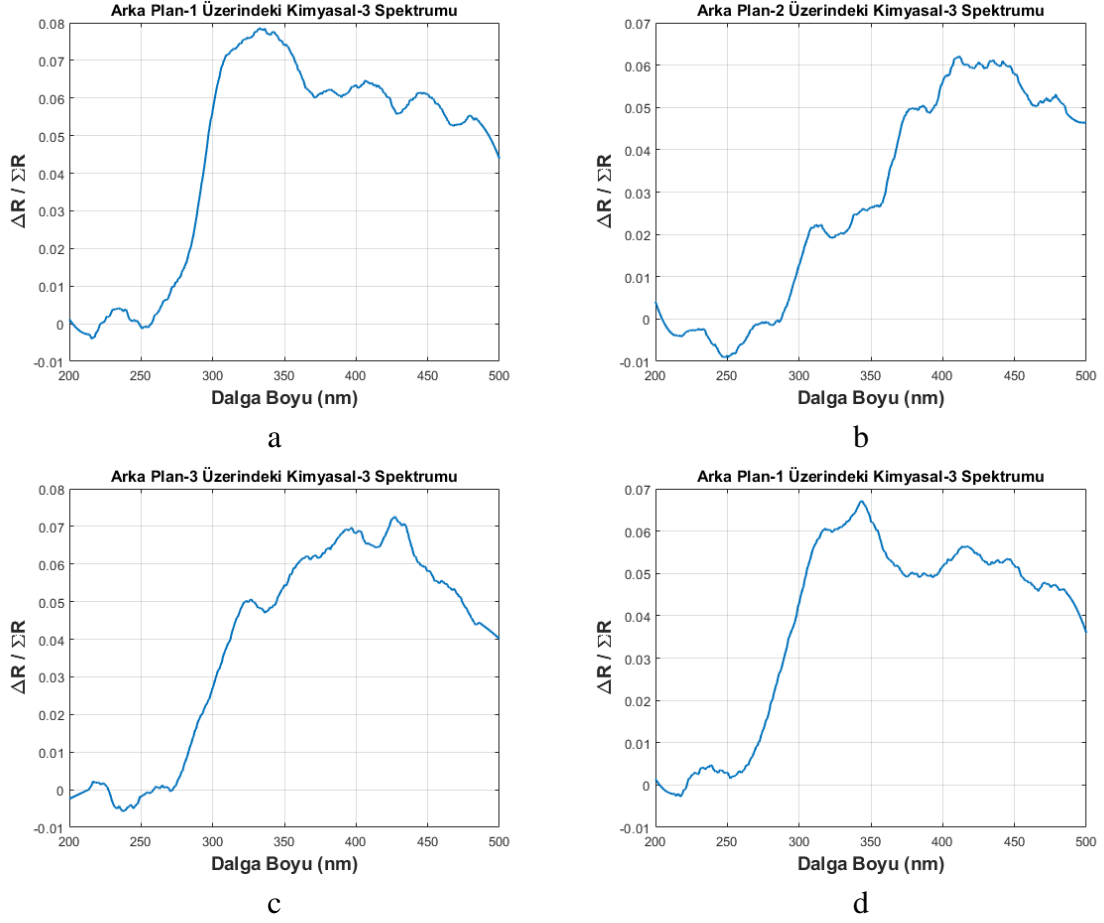
Özellikle Arka Plan-2 üzerinde oluşan kötü sonuçların sebebi bu arka plan için kullanılan materyalin spektral yansımalarıyla ilgilidir. Arka Plan-2, kullanılan hiperspektral kameranın çalıştığı dalga boylarında diğer arka planlara göre daha yüksek seviyelerde yansıma yapan bir materyaldir. Bu yüzden de spektrumu diğer arka planlara göre daha baskındır. Eğer bir piksel, Kimyasal-1 ve Kimyasal-2 gibi spektral imzası diğer kimyasallardan daha az ayırt edici olan hedeflerin ve Arka Plan-2 gibi baskın spektrumu olan bir maddenin karışımından oluşuyorsa, bu pikseli sınıflandırmak ciddi şekilde zorlaşmaktadır. Bunun nedeni zaten zayıf yansıma değerlerine sahip olan Kimyasal-1 ve Kimyasal-2'nin soğurum kenarlarının, Arka Plan-2 gibi bir materyal üzerinde bozulmasıdır. Benzer bir durum Arka Plan-4 içinde



ŞEKİL 6.3: Kimyasal-2'nin tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-2 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-2 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-2 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-2 spektrumu.

gerçekleşmiştir. Ancak Arka Plan-4'ün spektrumu daha az baskın özellikler taşıdığından, kimyasalların spektrumlarını daha az bozmuş ve daha az sorun oluşturmuştur. Buna rağmen Arka Plan-4 üzerinde de bazı kimyasal maddeler için ortalamanın altında sonuçlar elde edilmiştir.

Kimyasal-1'in tüm arka planlar üzerindeki spektrumları Şekil 6.2'de gösterilmiştir. Buradan da görüleceği üzere Kimyasal-1'in spektrumu Arka Plan-2 spektrumuyla birleşince daha farklı bir yapıya sahip olmuştur. Arka Plan-2 üzerindeki Kimyasal-1 spektrumunun soğurum kenarı belirsiz bir hal almıştır. Kimyasal-1 spektrumu Arka Plan-4 üzerinde biraz değişmiş



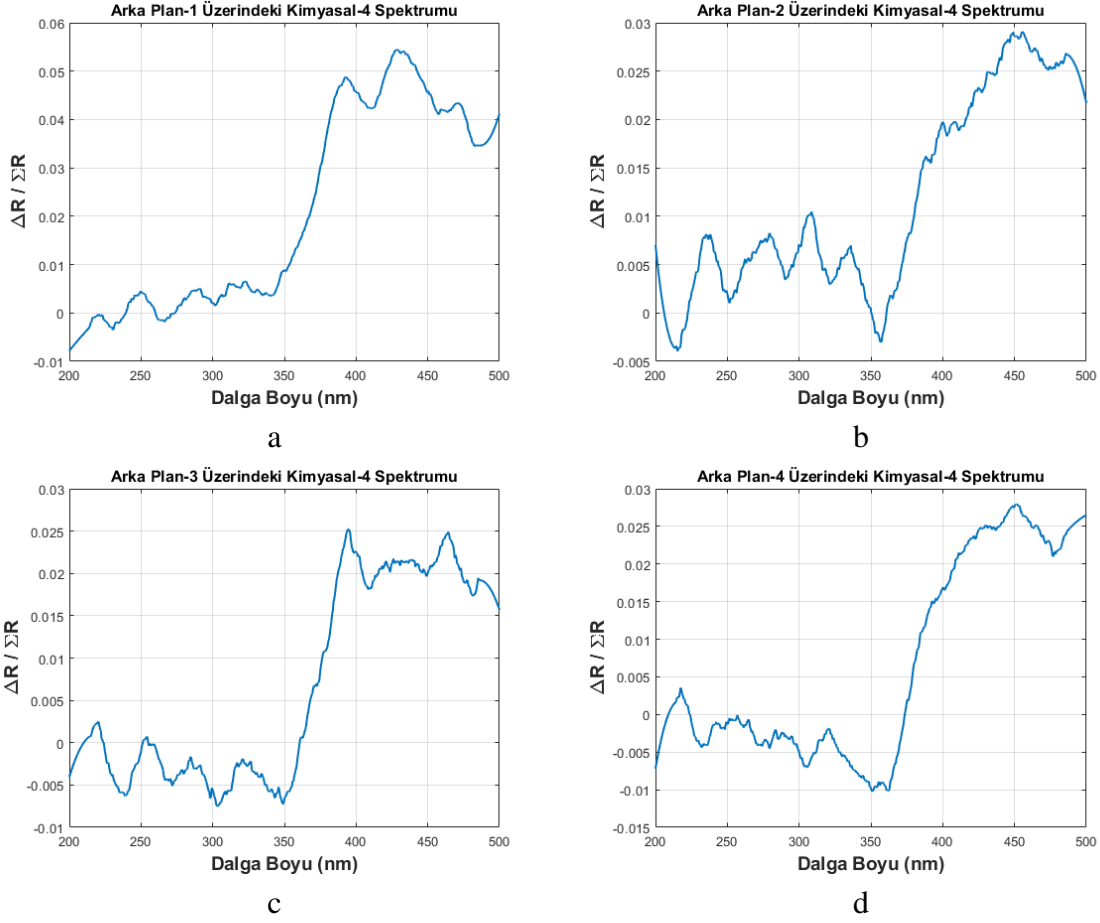
ŞEKİL 6.4: Kimyasal-3'ün tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-3 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-3 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-3 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-3 spektrumu.

olsa da, soğurum kenarı varlığını korumuştur. Diğer arka planlar üzerinde Kimyasal-1 spektrumu çok fazla değişmemiştir.

Şekil 6.3'te Kimyasal-2'nin tüm arka planlar üzerindeki spektrumları gösterilmiştir. Kimyasal-1'den farklı olarak Arka Plan-2 üzerinde Kimyasal-2'nin soğurum kenarında büyük bir değişim olmamıştır. Ancak Arka Plan-4 üzerinde Kimyasal-2'nin soğurum kenarında bozulma meydana gelmiştir.

Şekil 6.4 ve Şekil 6.5 sırasıyla Kimyasal-3 ve Kimyasal-4'ün tüm arka planlar üzerindeki






ŞEKİL 6.5: Kimyasal-4'ün tüm arka planlar üzerindeki spektrumları. a) Arka Plan-1 üzerindeki Kimyasal-4 spektrumu, b) Arka Plan-2 üzerindeki Kimyasal-4 spektrumu, c) Arka Plan-3 üzerindeki Kimyasal-4 spektrumu, d) Arka Plan-4 üzerindeki Kimyasal-4 spektrumu.

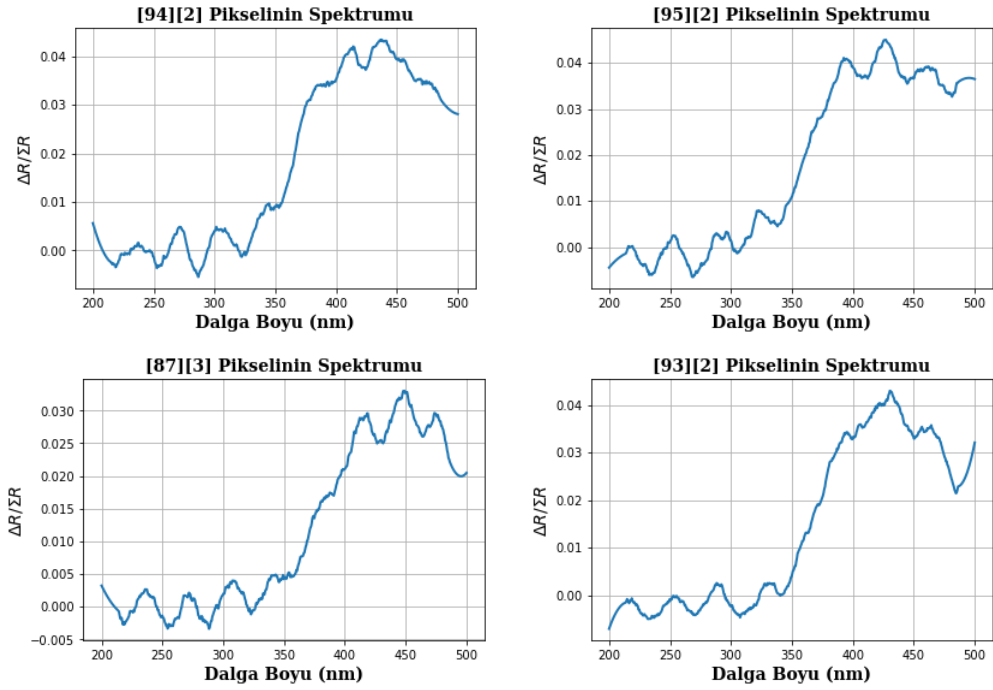
spektrumlarını göstermektedir. Spektrumlar ortak olarak Arka Plan-2 üzerinde küçük bozulmalara sahiptir. Ancak diğer üç arka plan materyalinde spektrumlarda hiçbir bozulma olmamıştır. Buradan da anlaşılacağı gibi Kimyasal-3 ve Kimyasal-4 ün spektrumları çok yüksek enerji ile soğurum yaptığından herhangi bir arka plan spektrumu tarafından baskılanamamıştır.

### 6.1.2 Kenar Piksellerde Tespit Edilen Yanlış Pozitif Piksellerin Sonuçlara Etkisi

Tez çalışmaları sırasında denenen her model için YP olarak tespit edilen piksellerin bazıları rastgele bir arka plan pikseli olsa da, çok büyük bir kısmının kenar piksel olduğu görülmüştür.

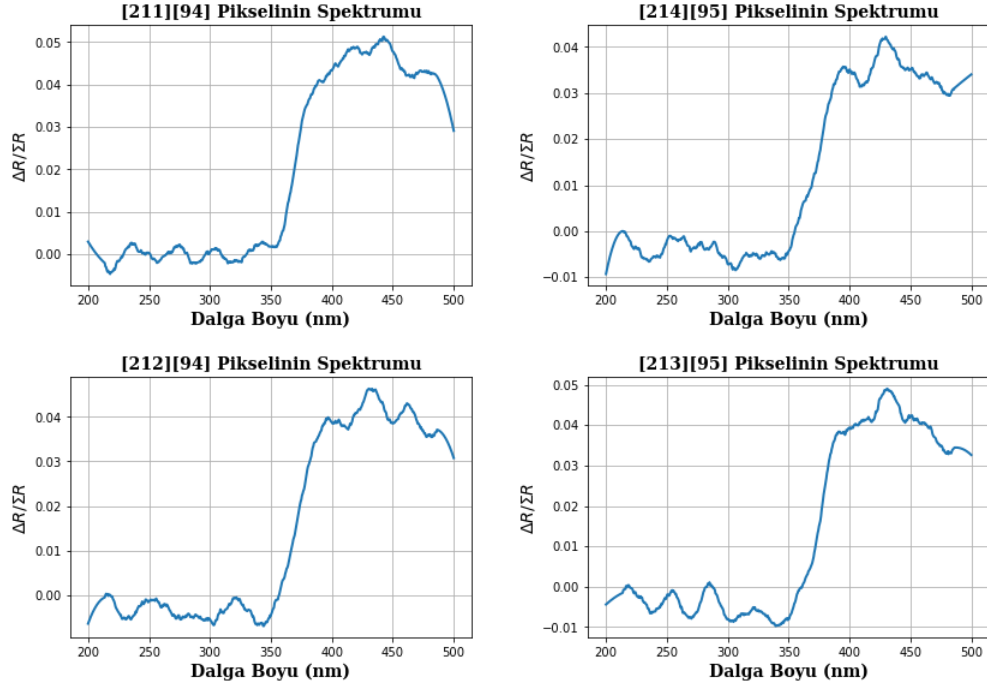


ŞEKİL 6.6: Hedef içeren ve içermeyen görüntüler üzerinde ayakkabının ön alt ucunda tespit edilen YP pikseller ve arka plan materyalinin ortasında tespit edilen DP piksellerin gösterimi. a) YP ve DP pikseller tespit edilen DP görüntü, b) Sadece YP pikseller tespit edilen YP görüntü.



ŞEKİL 6.7: Ayakkabının ön alt ucunda YP olarak tespit edilen ve arka plan materyalinin ortasında tespit edilen Kimyasal-4 spektrumlarına önemli ölçüde benzeyen dört adet YP pikselin spektrumları.

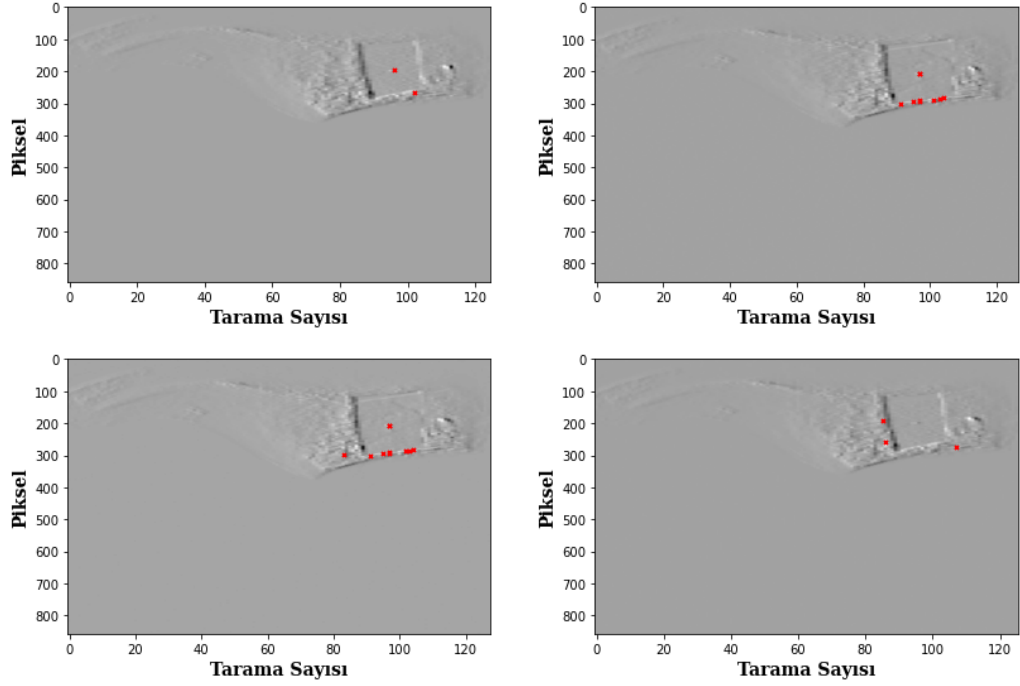
Bu pikseller görüntüdeki herhangi bir kenarda görülmektedir. En çok YP tespit edilen pikseller ayakkabının ön alt ucunda ve ayakkabının üstüne yerleştirilen dörtgen şeklindeki arka plan materyalinin kenarlarında bulunmaktadır.



ŞEKİL 6.8: Arka plan materyalinin ortasında DP olarak tespit edilen ve ayakkabının ön alt ucunda tespit edilen YP pıksellerının spektrumlarına önemli ölçüde benzeyen 2500 ng Kimyasal-4 içeren dört adet pıkselının spektrumları.

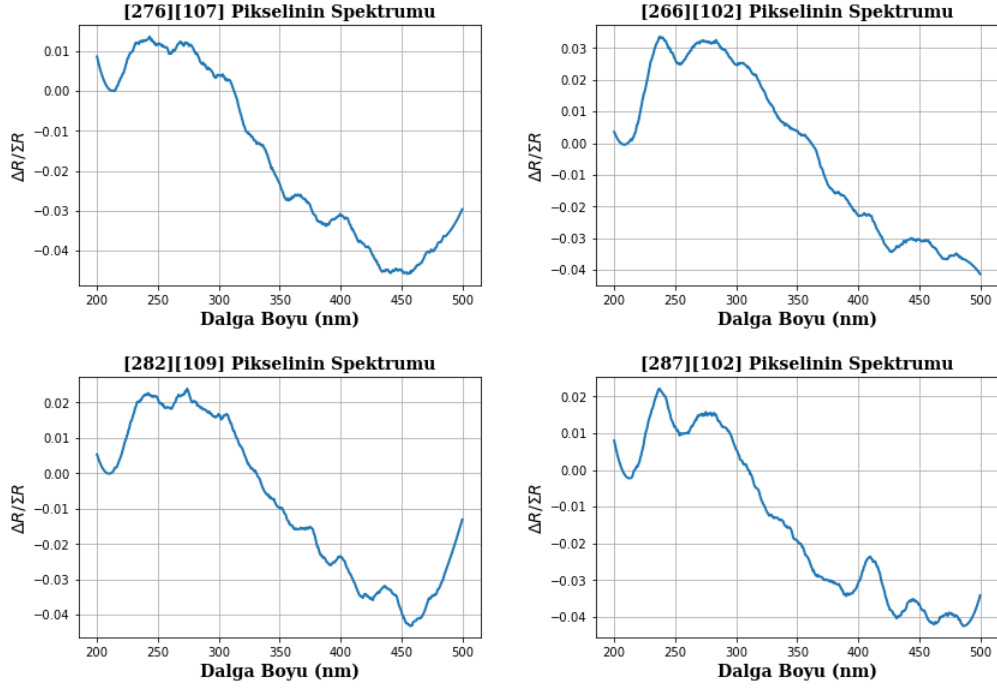
Bu kenar pıksellerının spektrumları hedef kimyasalların spektrumlarına çok benzer olabilmektedir. Bu da derin öğrenme algoritmasını yanıltıp, bu pıksellerının yanlış sınıflandırılmasına neden olmaktadır. Bunu engellemek amacıyla, Bölüm 3.2’de bahsedildiği gibi veri kümesine çok sayıda kenar pıksel seçilerek eklenmiştir. Özellikle ayakkabının kenarında ve arka plan materyalinin kenarında sorun çıkaran pıksellerının buldukları bölgelerden, çok sayıda rastgele pıksel seçilip veri kümesine eklenmiştir. Bunun da yeterli olmadığı görülüp eğitim sırasında YP tespiti yapılan kenar pıkseller bir sonraki eğitimde veri kümesine eklenecek şekilde, belirli bir aşamaya kadar veri kümesi güncellenmiştir. Buna rağmen bazı kenar pıksellerının spektrumları ve hedef kimyasalların spektrumları arasındaki büyük benzerlikler yanlış sınıflandırmaların devam etmesine neden olmuştur.

Kimyasal-1 ve Kimyasal-2’nin spektrumlarının karakteristik özellikleri daha az belirgin olduğu için ve arka plan materyallerinin spektrumuyla da birleşince bozulmaya daha müsait oldukları için kenar pıksellerla kıyaslama için bir kıstas oluşturmamışlardır. Bu yüzden



ŞEKİL 6.9: Hedef içeren ve içermeyen görüntüler üzerinde arka plan materyalinin kenarlarında tespit edilen YP piksellerin ve arka plan materyalinin ortasında tespit edilen DP piksellerin gösterimi.

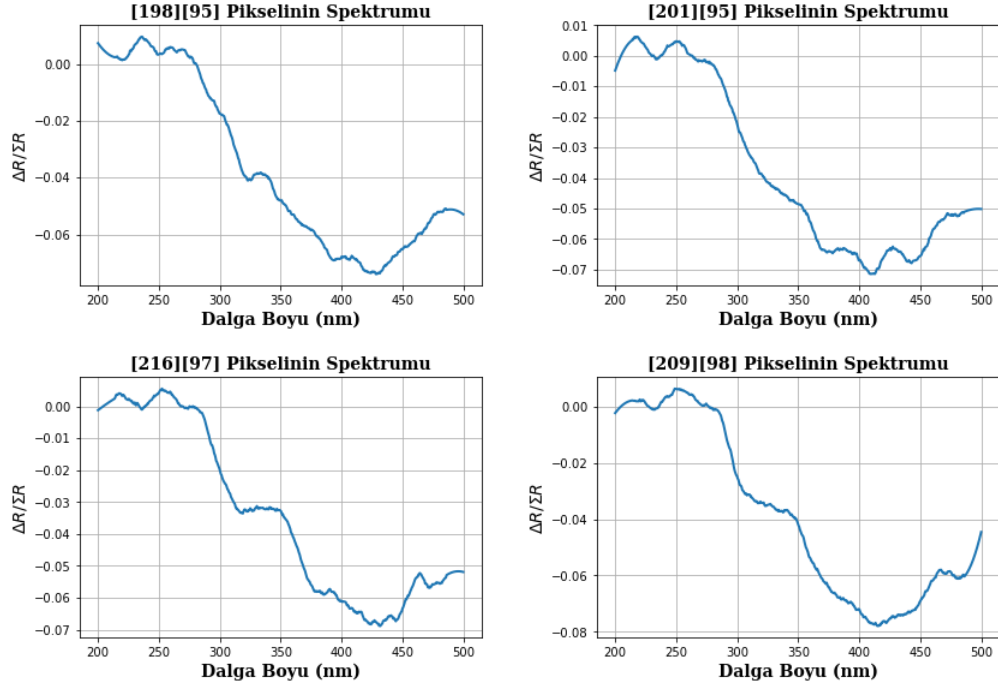
spektrumlarındaki karakteristik özellikleri daha belirgin olan Kimyasal-3 ve Kimyasal-4'ün spektrumlarıyla karşılaştırmalar yapılmıştır. Şekil 6.6'da Kimyasal-4 içeren bir görüntüde ve hiçbir hedef içermeyen bir görüntüde ayakkabının ön alt ucunda tespit edilen YP pikseller gösterilmektedir. Bu görüntülerdeki hedef içermeyen ve YP olarak tespit edilen piksellerin rastgele dört tanesinin spektrumu Şekil 6.7'de ve Kimyasal-4 içeren ve DP olarak tespit edilen piksellerin rastgele dört tanesinin spektrumu Şekil 6.8'de gösterilmiştir. Bu şekillerden de görüleceği üzere ayakkabının ucundaki hedef içermeyen piksellerin spektrumları ile hedef Kimyasal-4 spektrumları birbirlerine ciddi benzerlikler göstermiştir. Kimyasal-4'ün spektrumunda 350-400 nm dalga boyunda bulunan soğurum kenarının aynısı ayakkabının ucundaki piksellerin spektrumlarında da gözlenmiştir. Bundan dolayı geliştirilen derin öğrenme modelleri bu pikselleri sınıflandırmada zorlanmıştır. Kimyasal-3 içeren pikseller ve arka plan materyalinin kenarlarındaki bazı pikseller arasında da benzer bir durum oluşmuştur. Şekil 6.9'da Kimyasal-3 içeren ve içermeyen görüntülerde arka plan materyalinin farklı kenarlarında tespit edilen YP pikseller gösterilmiştir. Arka plan materyalinin



ŞEKİL 6.10: Arka plan materyalinin kenarlarında YP olarak tespit edilen ve arka plan materyalinin ortasında tespit edilen Kimyasal-3 spektrumlarına önemli ölçüde benzeyen dört adet YP pikselin spektrumları.

kenarlarında hedef içermeyen ve YP olarak tespit edilen piksellerden bazılarının spektrumları Şekil 6.10'da, arka plan materyalinin ortasında Kimyasal-3 içeren ve DP olarak tespit edilen bazı piksellerin spektrumları da 6.11'de gösterilmiştir. Bu grafiklerden de görüleceği gibi arka plan materyalinin kenarlarında tespit edilen piksellerin spektrumları neredeyse Kimyasal-3 içeren piksellerin spektrumlarıyla aynıdır. Bu da sınıflandırıcının hata yapma ihtimalini arttırmaktadır. Bundan dolayı geliştirilen tüm modellerde kenar piksellerde YP hedef tespiti sorunları görülmüştür.


Kenar piksellerde yaşanan bu sorunların nedenlerinden biri ön işleme aşamasında uygulanan Diferansiyel Reflektometri yöntemidir. Bu yöntem aslında kimyasal maddelerin spektrumlarını (soğurum kenarlarını) daha belirgin hale getirmek için kullanılsa da, maalesef uyguladığı türev işlemi ile görüntüdeki kenar piksellerin spektrumlarını da belirginleştirmektedir. Ancak bu durumun yararı, zararından fazla olduğu için bu yöntem kullanılmaya devam edilmiş ve kenar piksellerdeki problemlere başka çözümlerin bulunması amaçlanmıştır.




ŞEKİL 6.11: Arka plan materyalinin ortasında DP olarak tespit edilen ve arka plan materyalinin kenarlarında tespit edilen YP piksellerin spektrumlarına önemli ölçüde benzeyen 2500 ng Kimyasal-3 içeren dört adet pikselin spektrumları.

### 6.1.3 Kimyasal Madde Miktarının Sonuçlara Etkisi


Arka plan materyallerinin sonuçlara etkisi görüntü bazlı tablo incelenerek, kenar piksellerin sonuçlara etkisi ise piksel bazlı tablo incelenerek anlaşılmıştır. Ancak direkt görünen bu problemlerin yanı sıra, aslında pek belli olmayan, detay testler sonucu ortaya çıkan ve modellerin performansını ciddi biçimde etkileyen başka bir etmen daha tespit edilmiştir. Hiper-spektral görüntünün elde edildiği yüzeyde tespit edilmek istenen kimyasal madde miktarının önemli bir tespit parametresi olduğu görülmüştür. Test aşamasında hem düşük gramajda hem de yüksek gramajda kimyasal hedef içeren hiperspektral görüntüler için hedef tespiti yapılmıştır. Tablo 6.3'te test aşamasında kullanılan görüntülerin içerdiği kimyasal madde miktarları yüksek ve düşük gramajda gösterilmiştir. Kimyasal-1'in gramajlarının diğerlerinden farklı olmasının sebebi önceki bölümlerde anlatıldığı gibi spektrumunun daha az ayırt edici olması ve arka plan tarafından daha kolay baskılanabilmesidir. Kimyasal-1'in tespitinin diğer kimyasallara göre çok daha zor olduğu bilindiğinden, tespit edilmesi için nesnenin




a) 2500 ng Kimyasal-1 Spektrumu




b) 5000 ng Kimyasal-1 Spektrumu




c) 2000 ng Kimyasal-2 Spektrumu



d) 2500 ng Kimyasal-2 Spektrumu




e) 1000 ng Kimyasal-3 Spektrumu



f) 2500 ng Kimyasal-3 Spektrumu



g) 2000 ng Kimyasal-4 Spektrumu



h) 2500 ng Kimyasal-4 Spektrumu

ŞEKİL 6.12: Dört kimyasalın Arka-Plan-1 üzerindeki düşük ve yüksek gramajdaki örnek spektrumlarının gösterimi.

yüzeyinde daha yüksek miktarlarda bulunması gerektiği düşünülmüştür. Bu da Kimyasal-1 için toplanan verilerin gramajlarının diğerlerinden fazla olmasının nedeni olmuştur.

TABLO 6.3: Test aşamasında kullanılan görüntülerin içerdiği kimyasalların yüksek ve düşük gramajdaki miktarları.

<b>Kimyasal Madde</b>	<b>Gramaj</b>	<b>Arka Plan-1</b>	<b>Arka Plan-2</b>	<b>Arka Plan-3</b>	<b>Arka Plan-4</b>
<b>Kimyasal-1</b>	Yüksek	5000 ng	7500 ng	5000 ng	10000 ng
	Düşük	2500 ng	5000 ng	2500 ng	7500 ng
<b>Kimyasal-2</b>	Yüksek	2500 ng	2500 ng	2500 ng	2500 ng
	Düşük	2000 ng	2000 ng	2000 ng	2000 ng
<b>Kimyasal-3</b>	Yüksek	2500 ng	2500 ng	2500 ng	2500 ng
	Düşük	1000 ng	1000 ng	1000 ng	1000 ng
<b>Kimyasal-4</b>	Yüksek	2500 ng	2500 ng	2500 ng	2500 ng
	Düşük	2000 ng	2000 ng	1000 ng	2000 ng

Test aşamasında beklenildiği gibi yüksek gramajda kimyasal hedef içeren görüntülerde kimyasalların tespit performansı daha yüksek olmuştur. Bunun sebebi, düşük gramajda kimyasal kullanıldığında, bir piksel içerisine düşen kimyasal miktarının azalması ve bu yüzden kimyasalın spektrumdaki baskınlığının kaybolması olmuştur. Bu durumda bir pikselin yansıma spektrumu arka plan materyalinin özelliklerini kimyasalın özelliklerinden daha fazla göstermiştir. Bu da pikselin spektrumuna bakılarak kimyasalın tespit edilmesini ciddi şekilde zorlaştırmıştır. Şekil 6.12’de gösterildiği gibi, tüm kimyasalların yüksek gramajdaki spektrumları daha az gürültü içermektedir. Bu yüzden de kimyasalların soğurum kenarları açıkça belli olmaktadır. Kimyasalın miktarı ne kadar fazla ise sinyal-gürültü oranı o kadar büyük olduğundan, spektrumda daha belirgin gözüküştür. Ancak düşük gramajdaki spektrumlarda durum böyle değildir. Çünkü, arka plan materyalinin spektrumlarına daha fazla etki etmesiyle kimyasalların soğurum kenarlarının belirginliği azalmış ve spektrumdaki gürültü miktarı artmıştır. Buradan kimyasalların yüzeydeki miktarının önemi anlaşılmıştır.



## 6.2 ESA-2 ile Geliştirilen Modellerin Testleri ve Sonuçları

ESA-2 mimarisi, ESA-1 mimarisinde geliştirilen modellerin yeterince başarılı olmadığı görül-  
dükten sonra oluşturulmuştur. ESA-2 üzerinde uzun süre çalışıldıktan sonra ESA-1 model-  
lerinin performanslarından daha iyi performanslar elde edilmiştir. Bu çalışmalar yapılırken  
çeşitli mimariler denenmiştir. Sonuçta stabil hale gelen mimaride, ESA-1'den farklı olarak  
çıkıtı katmanından önceki tam bağlı katman mimariden çıkarılmıştır. ESA-1'den farklı olan  
başka bir temel unursa evrişim katmanlarında kullanılan filtre sayıları ve filtre boyutlarıdır.  
Ancak performansın iyileştirilmesine yapılan en büyük katkı modelin iki boyutlu girdi verisi  
alıp, iki boyutlu katmanlarda işlenmesiyle sağlanmıştır.

Tıpkı ESA-1'deki gibi ESA-2 ile geliştirilen tüm modellerin performansları hem imaj bazlı  
hem de piksel bazlı sonuçlarla hesaplanmıştır. İmaj bazlı sonuçlar Tablo 6.4'te, piksel bazlı  
sonuçlar ise Tablo 6.5'te gösterilmiştir. Bu tablolar ESA-1 modellerinin sonuçlarını içeren  
tablolarla kıyaslandığında, ESA-2 modellerinin karşılığı olan tüm ESA-1 modellerinden  
genellikle daha başarılı sonuçlar ürettiği görülmüştür.

Tablo 6.4 incelendiğinde genel olarak Kesinlik ve Duyarlılık değerlerinin tüm kimyasal  
modelleri için %90 civarlarında olduğu görülmektedir. Buradaki tek istisna Arka Plan-2  
üzerindeki Kimyasal-1 sonuçlarıdır. Maalesef Bölüm 6.1.1'de anlatılan problemler burada  
da devam etmiştir. Diğer arka planlar üzerinde hiçbir model için bu problem bu kadar be-  
lirgin değildir. Ancak Arka Plan-2 üzerinde, özellikle arka plan materyalinin kenarlarında  
tespit edilen YP pikseller Kimyasal-1 modelinin bu arka plan için başarısız olmasına se-  
bep olmuştur. Bu durum dışında ESA-2'de geliştirilen tüm modellerde başarılı sınıflandırma  
sonuçları elde edilmiştir. Özellikle Kimyasal-3 ve Kimyasal-4 için geliştirilen modeller ön  
plana çıkmıştır. Bu iki modelde genellikle %90'ın üzerinde çıkan Kesinlik ve Duyarlılık  
değerleri, çok az sayıda hedef içeren görüntünün tespit edilemediğini ve çok az sayıda yanlış  
tespit edilen görüntü olduğunu göstermektedir. Bu modellerden sonra gelen Kimyasal-2  
modeli, Arka Plan-2 üzerinde biraz sendelemiş gibi gözükse de, sonuçlar Kimyasal-1'deki

kadar olumsuz değildir. Kimyasal-1'in sonuçları da Arka Plan-2'den ayrı değerlendirildiğinde sonuçların iyi olduğu görülmektedir. Tablo 6.5 ile Tablo 6.2 karşılaştırıldığında, genellikle Kesinlik değerlerinin arttığı ancak Duyarlılık değerlerinin bazı durumlarda arttığı bazı durumlarda azaldığı görülmüştür. Kesinlik değerlerinin tutarlı olarak artmasındaki temel neden, iki boyutlu modelin sağladığı iyileştirme sayesinde daha az YP piksel tespit etmesidir. Duyarlılık değerlerindeki değişimin sebebi ise YP piksellerin tespitini azaltmak amacıyla yapılan işlemlerin YN piksellerin sayısını arttırmasıdır. Burada hedef içeren bazı pikselleri tespit edememek uğruna, birçok YP pikselin tespitinden de kurtulunmuştur. Bu durum, bir görüntüde tespit edilen DP piksel sayısını düşürse de, YP piksellerin sayısını daha çok düşürdüğünden, hedef içermeyen görüntülerin yanlış sınıflandırılma ihtimalini çok aza indirmiştir. Ancak bunlardan ayrı olarak, yine de bazı modellerde az bazı modellerde fazla YP piksel tespit edilmeye devam etmiştir. Bu pikseller incelendiğinde Bölüm 6.1.2'de anlatılan, kenar piksellerde YP piksel tespit etme probleminin indirgenmiş bir şekilde devam ettiği görülmüştür. Arka Plan-1, Arka Plan-3 ve Arka Plan-4 üzerindeki DP görüntülerde çok nadiren tespit edilen YP piksel sayısı 1-2 olurken, YP görüntülerde de bu sayı 3-4 pikseli geçmemiştir. Bu pikseller Şekil 6.9'daki görsellere benzer bir şekilde arka plan materyallerinin kenarlarında tespit edilmiştir. Arka Plan-2 üzerindeki tüm görüntülerde ise YP piksel sayısı diğerlerinden daha fazladır. Bunun sebebi Arka Plan-2 materyalinin baskın spektral karakteristiği ve kenar piksel problemlerinin birleşmesidir.

### **6.2.1 İki Boyutlu Girdinin ve Mimarinin Sonuçlara Etkisi**

Bölüm 5.2'de anlatılan tek boyutlu spektral vektörlerin iki boyutlu matrislere dönüştürülmesi işlemi bu tez kapsamında önemli ilerlemeler sağlanmasında büyük rol oynamıştır. Veriler ilk kez iki boyutlu hale getirilirken  $25 \times 20$  boyutunda bir matrise dönüştürülmüştür. Bu dönüştürme işlemi yapılırken  $1 \times 548$  boyutundaki spektral vektörün başındaki 24 bandın ve sonundaki 24 bandın spektral bilgileri kırılarak,  $1 \times 500$  boyutunda bir vektör elde edilmiştir. Daha sonra bu vektörün  $25 \times 20$  boyutundaki matrise dönüştürülmesi işlemi Bölüm 5.2'deki

TABLO 6.4: Dört kimyasal için ESA-2 mimarisi ile geliştirilen modellerin imaj bazlı performans sonuçları.

Arkaplan	İmaj Tipi	Ölçüt	Kimyasal-1 Modeli	Kimyasal-2 Modeli	Kimyasal-3 Modeli	Kimyasal-4 Modeli
Arkaplan-1	H+	DP	45	43	48	46
		YN	5	7	2	4
	H-	DN	48	47	48	42
		YP	2	3	2	8
	Kesinlik		0.95	0.93	0.96	0.85
	Duyarlılık		0.90	0.86	0.96	0.92
Arkaplan-2	H+	DP	50	44	45	46
		YN	0	6	5	4
	H-	DN	13	39	44	45
		YP	37	11	6	5
	Kesinlik		0.57	0.80	0.88	0.92
	Duyarlılık		1.00	0.88	0.90	0.90
Arkaplan-3	H+	DP	42	44	47	44
		YN	8	6	3	6
	H-	DN	44	45	46	48
		YP	6	5	4	2
	Kesinlik		0.87	0.89	0.92	0.95
	Duyarlılık		0.84	0.88	0.94	0.88
Arkaplan-4	H+	DP	45	45	49	45
		YN	5	5	1	5
	H-	DN	43	44	48	46
		YP	7	6	2	4
	Kesinlik		0.86	0.88	0.96	0.91
	Duyarlılık		0.90	0.90	0.98	0.90

gibi yapılmıştır. Vektörün ilk 20 elemanı matrisin ilk satırını, ikinci 20 elemanı ise matrisin ikinci satırını oluşturacak şekilde 25 satır ve 20 sütundan oluşan iki boyutlu veri elde edilmiştir.

Tez çalışmalarının büyük bir bölümünde  $25 \times 20$  boyutundaki verilerle çalışılmıştır. Veriler iki boyutlu hale getirildiği andan itibaren modellerin sonuçlarında pozitif yönde ciddi değişimler meydana gelmiştir. Bu iyileştirmenin altında yatan neden verilerin ESA-2 mimarisindeki işleniş yöntemiyle ilgilidir. ESA-1 mimarisindeki evrişim katmanlarında kullanılan filtrelerin boyları sırasıyla 21, 51 ve 101 olarak ayarlanmıştır. Bu filtre boyları evrişim

TABLO 6.5: Dört kimyasal için ESA-2 mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları.

Arka Plan	Ölçüt	Kimyasal-1 Modeli	Kimyasal-2 Modeli	Kimyasal-3 Modeli	Kimyasal-4 Modeli
Arka Plan-1	Kesinlik	0.88	0.92	1.00	0.93
	Duyarlılık	0.31	0.41	0.35	0.15
Arka Plan-2	Kesinlik	0.54	0.71	0.96	0.70
	Duyarlılık	0.75	0.52	0.45	0.17
Arka Plan-3	Kesinlik	0.78	0.83	0.98	0.95
	Duyarlılık	0.80	0.32	0.42	0.12
Arka Plan-4	Kesinlik	0.84	0.87	1.00	0.97
	Duyarlılık	0.67	0.20	0.33	0.21

işlemi sırasında veriler arasındaki korelasyon hesaplanırken kullanılır. Bir nokta için filtreleme yapılacağı zaman filtrenin ortası bu noktaya denk gelecek şekilde ayarlanır. Bu durumda ilgili noktanın filtre içine düşen tüm noktalarla korelasyonu hesaplanmış olur. Yani bu durumda filtre boyu küçükse yakın noktalar arasındaki korelasyonlar, filtre boyu büyükse uzak noktalar arasındaki korelasyonlar hesaplanır. Bu yüzden filtre boyu ESA'lar için çok önemli bir parametredir. Çok küçük olması veride var olan korelasyonların anlaşılmasına, çok büyük olması da gereksiz korelasyonların hesaplanmasına yol açabilir. Uzun çalışmalar sonucunda en başarılı ESA-1 performanslarını sağlayan filtre boyları 21, 51 ve 100 olarak ayarlanmıştır. Bu değerlerin çok fazla büyütülmesi veya küçültülmesi ESA-1 performanslarını olumsuz şekilde etkilemiştir. Ancak ESA-2'de geliştirilen mimariyle dolaylı yoldan verideki uzak noktalar arasında korelasyon kurulmasını sağlamıştır. Bu korelasyon  $25 \times 20$  boyutundaki verilere uygulanan  $3 \times 3$  boyutlu filtreler ile sağlanmıştır. Bu filtreler ile daha uzak noktalar arasında ilişki kurulurken, aynı zamanda ilgili noktanın yakın komşuluğundaki noktalara daha çok önem verilmiştir. Bu sayede verinin spektral bilgisindeki özellikler daha kolay ayırt edilmiş ve yapılan sınıflandırmalar daha başarılı olmuştur.

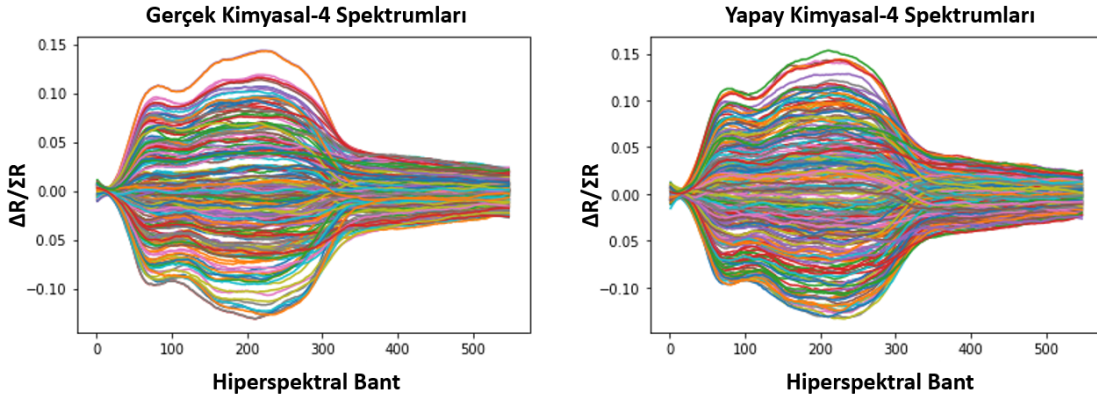
Verilerin ve mimarinin iki boyutlu hale getirilmesi sonuçları önemli ölçüde iyileştirmiştir. Bunun yanı sıra tez çalışmalarının devamında verilerin farklı bir iki boyutlu forma dönüştürülmesi düşünülmüştür.  $25 \times 20$  boyutundaki veriler hazırlanırken verinin başından ve sonundan atılan 24'er elemanın sınıflandırma için faydalı olabileceği öngörülerek verilerin başka bir

forma dönüştürülmesi amaçlanmıştır. Bu yüzden son olarak veriler Bölüm 5.2’de anlatıldığı gibi  $24 \times 24$  boyutuna dönüştürülmüştür. Tüm bantlardaki spektral bilginin kullanılmasını sağlayan bu dönüşüm sayesinde her kimyasalın tespitinde az da olsa bir iyileşme olmuştur. Ancak Kimyasal-2’nin tespiti için bu işlem diğerlerinden daha faydalı olmuştur. Bunun nedeni Kimyasal-2’nin spektrumunun başında ve sonunda bazı karakteristik davranışlar olmasıdır. Diğer kimyasallar için spektrumun bu bölgeleri genellikle gürültü benzeri bir davranış gösterse de, Kimyasal-2 için bu bölgeler sınıflandırma için anlamlı bilgiler içermektedir. ESA-2’de Kimyasal-2 için geliştirilen modelin ESA-1’deki modelden daha başarılı olmasının nedenlerinden biri de bu durumdur.

### **6.2.2 Azınlık Sınıfın Örnek Sayısının Arttırılmasının Sonuçlara Etkisi**

Tez çalışması süresince ESA-2 modellerinin performanslarını arttırmak amacıyla birçok yöntem denenmiştir. Bunların bir kısmı eğitimden önce ön işleme aşamasında uygulanan, bir kısmı eğitim aşamasında uygulanan, başka bir kısmı ise sınıflandırma sonrası uygulanan yöntemlerdir. Denenen ilk yöntemlerden biri veri kümesindeki azınlık sınıftan daha çok veri elde etmeye yarayan SMOTE yöntemidir [74]. Bu yöntem ile veri kümesindeki azınlık sınıfının (hedef kimyasal sınıfının) veri sayısı arttırılmıştır. SMOTE yönteminde “k-en yakın komşuluk” algoritması kullanılarak, veri kümesindeki gerçek verilerin çok boyutlu uzayda buldukları konumlara göre yapay veriler üretilir. Şekil 6.13’te üst üste çizilen birçok gerçek Kimyasal-4 spektrumu ve SMOTE ile üretilen yapay Kimyasal-4 spektrumu gösterilmiştir. Bu görsellerden görüleceği üzere gerçek veriler ile yapay veriler arasında neredeyse hiçbir fark yoktur. Bu da eğitim aşamasında bu verilen kullanılabilir olduğunu göstermektedir. Ancak bu veriler eğitim aşamasında kullanıldığında sonuçlar beklenildiği gibi iyileşmemiştir. Yapay verilerin veri kümesine eklenmesi tespit edilen DP piksel sayısını ciddi şekilde arttırsa da, bununla beraber YP piksel sayısında da artışa sebep olmuştur. Bu da hem piksel bazında hem görüntü bazında performansın düşmesine neden olmuştur. YP piksel sayısındaki

artışın sebebi üretilen yapay verilerin kenar piksellerde tespit edilen YP piksellere de benzesinden kaynaklanmaktadır. Bu yüzden SMOTE ile veri kümesindeki azınlık verileri çoğaltma işlemi tezin devamında kullanılmamıştır.



ŞEKİL 6.13: Gerçek Kimyasal-4 spektrumları ile SMOTE kullanılarak üretilmiş yapay Kimyasal-4 spektrumlarının karşılaştırılması.

### 6.2.3 Bağlı Bileşenler Yöntemi ile Tespit Elemenin Sonuçlara Etkisi


En uygun mimari ve hiperparametre kümesiyle eğitilen modeller elde edildikten sonra modellerin performansını iyileştirmek amacıyla ilk olarak “Bağlı Bileşenler” yöntemi değerlendirilmiştir. Bu yöntemde tespit kümesindeki her piksel için bir piksel çevre komşuluğundaki piksellerde hedef tespit edilip edilmediğine bakılmıştır. Eğer ilgili pikselin çevresindeki 8 pikselden en az bir tanesinde hedef varsa (en az bir piksel tespit kümesi içindeyse), o piksel tespit kümesinde kalmaya devam etmiştir. Çevredeki 8 pikselin hiçbirinde hedef tespit edilmemişse (hiçbir piksel tespit kümesi içinde değilse) ilgili pikselin bağlı bir bileşeni olmadığı için tespit kümesinden çıkarılmıştır. Bu yöntem test aşamasından sonra verilere uygulandığında YP görüntü sayısını ciddi oranda azaltmıştır. Çünkü Arka Plan-2 haricindeki tüm arka planlar üzerinde tespit edilen YP piksellerin sayısı 1-2 taneyi geçmemiştir. Bu sayının az olmasının yanı sıra YP tespit edilen pikseller genellikle ayırık bölgelerde tespit edilmiştir. Bu yüzden çoğunun tespit kümesinde bağlı bir bileşeni yoktur. Bu da Bağlı Bileşenler yöntemi sayesinde tespit edilen YP piksel sayısını ve dolaylı olarak YP görüntü sayısını önemli ölçüde

azaltmıştır. Arka Plan-2’de genellikle tespit edilen piksel sayısı diğerlerinden fazla olduğu için buradaki YP pikseller bazen bağlı bileşen durumunda olmaktadır. Bu yüzden Arka Plan-2 üzerindeki iyileştirme sınırlı kalmıştır. Ancak tüm bu olumlu etkilere rağmen Bağlı Bileşenler yönteminin olumsuz ve kullanılmamasını gerektiren bir yan etkisi söz konusu olmuştur. Bazı kimyasal maddelerde tespit edilen DP pikseller de tıpkı YP pikseller gibi az sayıda ve ayrıık olarak bulunabilmektedir. Özellikle Kimyasal-2 ve Kimyasal-4’te bu durum daha sık olmaktadır. Bu kimyasallarda sıklıkla tespit edilen DP piksel sayısı bir adet gelmektedir. DP sayısının bir olmadığı durumda da tespit edilen pikseller ayrıık bulunabilmektedir. Bundan dolayı bu piksellere Bağlı Bileşenler yöntemi uygulandığında bu piksellerin tespit kümesinden çıkarılması gerekmektedir. Bu da test aşamasından sonra Kimyasal-2 ve Kimyasal-4 için tespit edilen DP görüntülerin sayısını düşereceğinden Bağlı Bileşenler yöntemi tezin devam eden aşamalarında kullanılmamıştır.

#### **6.2.4 Sınıflandırma Olasılıkları Üzerinden Eşikleme Yapmanın Sonuçlara Etkisi**

Eğitim aşamasından sonra modellerin performanslarını arttırmak amacıyla uygulanan başka bir yöntem ise sınıflandırma katmanındaki softmax fonksiyonu ile hesaplanan olasılık değerleri üzerinden eşikleme yapmaktır. Bölüm 4.3.6’da anlatıldığı gibi softmax aktivasyon fonksiyonu veri kümesindeki tüm sınıflar için bir olasılık sonucu üretir ve beslenen girdi verisinin en yüksek olasılıklı sınıfa ait olduğu kararı verilir. Bu son işleme adımında softmax fonksiyonunda hesaplanan en yüksek olasılıklı sınıfın olasılık değeri üzerinden bir eşikleme yapılması amaçlanmıştır. Burada bir eşik limiti belirlenerek bu eşiğin altındaki olasılık değerleri tespit kümesinden çıkarılmış, eşiğin üstündeki değerler ise tespit kümesinde tutulmaya devam edilmiştir. Bu yöntemin denenmesinin temel nedeni görüntülerde tespit edilen YP piksellerin ve DP piksellerin olasılıkları arasında bariz bir fark olabileceği düşüncesidir. Bu yüzden test aşamasında her görüntüde tespit edilen tüm pikseller için olasılık değerleri kontrol edilmiştir. Kimyasal-3 ve Kimyasal-4 modelleri için tespit edilen DP piksellerin çoğunda olasılık değerlerinin %90’dan daha yüksek, tespit edilen YP piksellerin çoğunun olasılık değeri ise %60’ın olduğu görülmüştür. Şekil 6.14’teki histogramlar test kümesi verileri

kullanılarak elde edilmiştir. Şekildeki mavi histogram Kimyasal-1 modelinin tespit ettiği DP piksellerin olasılık dağılımını gösterirken, kırmızı histogram ise Kimyasal-1 modelinin tespit ettiği YP piksellerin olasılık dağılımını göstermektedir. Bu histogramlara bakıldığında Kimyasal-3 modelinin beklendiği gibi DP pikselleri yüksek olasılıklar ile, YP pikselleri ise düşük olasılıklar ile tespit ettiği görülmüştür. Ancak, Kimyasal-3 ve Kimyasal-4 modelleri için zaten sınıflandırma performansları diğerlerine göre çok daha iyi olduğu için bir eşikleme yapılması gerekmemiştir.




ŞEKİL 6.14: Kimyasal-3 modelinin test kümesi verileri üzerinde tespit ettiği DP ve YP piksellerin olasılık dağılımlarını gösteren histogramlar. a) Kimyasal-3 modelinin tespit ettiği DP piksellerin olasılık dağılımını gösteren histogram, b) Kimyasal-3 modelinin tespit ettiği YP piksellerin olasılık dağılımını gösteren histogram.

Geliştirilen modellerin performansı kıyaslandığında asıl önemli olan Kimyasal-1 ve Kimyasal-2 için elde edilen olasılık değerleridir. Bu kimyasallar için tespit edilen piksellerin olasılık değerleri incelendiğinde kullanılacak hiçbir eşik değerinin sağlıklı bir şekilde YP pikselleri eleyip, DP pikselleri koruyacağı görülmemiştir. Bunun sebebi tespit edilen Kimyasal-1 ve Kimyasal-2 piksellerinin olasılıklarının çok çeşitli değerler göstermesidir. Örneğin, Kimyasal-1 modelinde tespit edilen YP bir pikselin olasılığı %96, DP bir pikselin olasılığı ise %55 olabilmektedir. Bu durum bir istisna olmayıp, sık sık yaşandığı için bir sorun oluşturmaktadır. Kimyasal-1 modelinin test kümesi verilerinde tespit ettiği DP ve YP piksellerin olasılık dağılımları Şekil 6.15'teki histogramlarda gösterilmiştir. Bu durumda eşiklerin düşük (%60), orta (%75) veya yüksek (%90) seviyelerde olması bir şeyi değiştirmemiştir. Çünkü tüm eşik seviyelerinde ya çok fazla YP ve DP piksel birlikte tespit kümesinde kalmış,



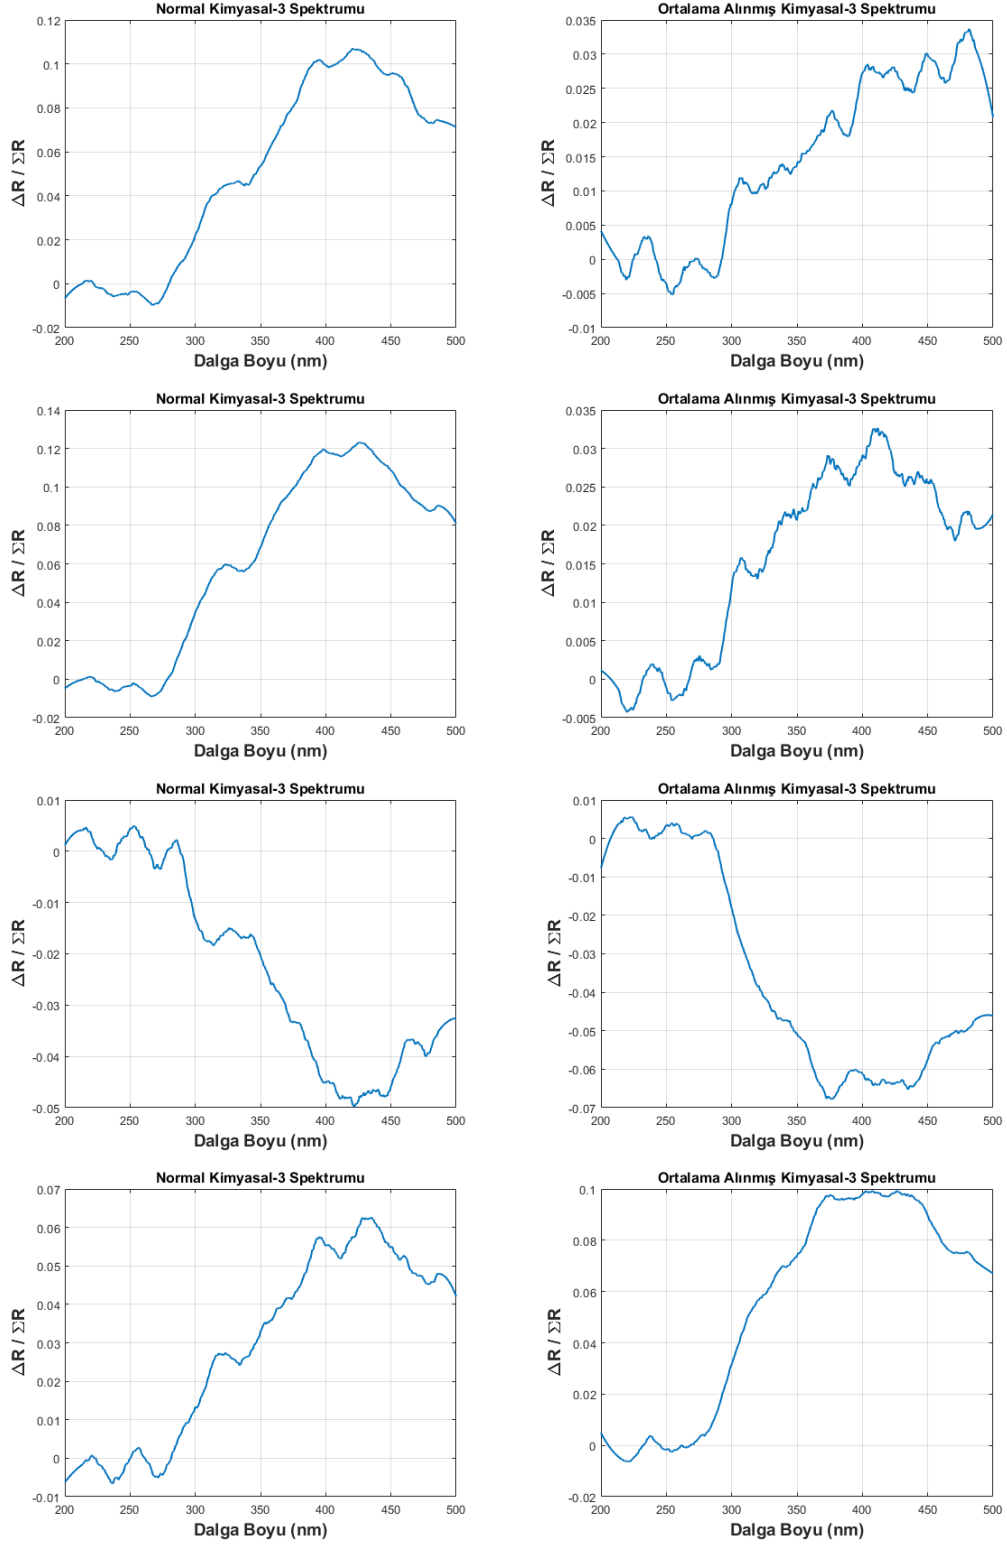
ya da çok fazla YP ve DP piksel birlikte tespit kümesinden elenmiştir. Bunun ana sebepleri Bölüm 6.1.1’de ve Bölüm 6.1.2’de anlatılan problemlerdir. YP piksellerin ve DP piksellerin spektrumlarındaki benzerlikler nedeniyle algoritma öğrendiği öznelilikler üzerinden sınıflandırma yaparken olasılıksal olarak yeterince güvenilir olmayan sonuçlar da çıkabilmektedir. Sonuçta, Kimyasal-1 ve Kimyasal-2 modelleri için eşikleme yöntemi YP verileri elerken, duruma göre çok fazla DP verinin de kaybolmasına neden olabileceğinden kullanımı tercih edilmemiştir.



ŞEKİL 6.15: Kimyasal-1 modelinin test kümesi verileri üzerinde tespit ettiği DP ve YP piksellerin olasılık dağılımlarını gösteren histogramlar. a) Kimyasal-1 modelinin tespit ettiği DP piksellerin olasılık dağılımını gösteren histogram, b) Kimyasal-1 modelinin tespit ettiği YP piksellerin olasılık dağılımını gösteren histogram.

## 6.2.5 Çevre Piksellerin Spektrumlarının Ortalamasının Sonuçlara Etkisi

Uygulanan tüm iyileştirme yöntemlerinin yanı sıra derin öğrenme modellerine beslenecek verilerin içeriği değiştirilerek daha iyi sonuçlar üreten modeller elde edilmek istenmiştir. Bu amaçla [17]’deki yaklaşım ele alınmıştır. Burada uygulanan yöntemin amacı spektral ve uzamsal bilgiyi istatistiksel bir yöntem ile birleştirmektir. Uygulanan yöntemde modele yine  $24 \times 24$  boyutunda veriler beslenmiştir. Ancak beslenen veriler direkt olarak bir pikselin spektrumunu içermemektedir. Bu yöntemde beslenecek verileri elde etmek amacıyla veri kümesindeki her örnek piksel için buldukları hiperspektral görüntü üzerinde, ilgili piksel ortada olacak şekilde  $3 \times 3$  boyutunda bir pencere oluşturulmuştur. Bu penceredeki 9 pikselin

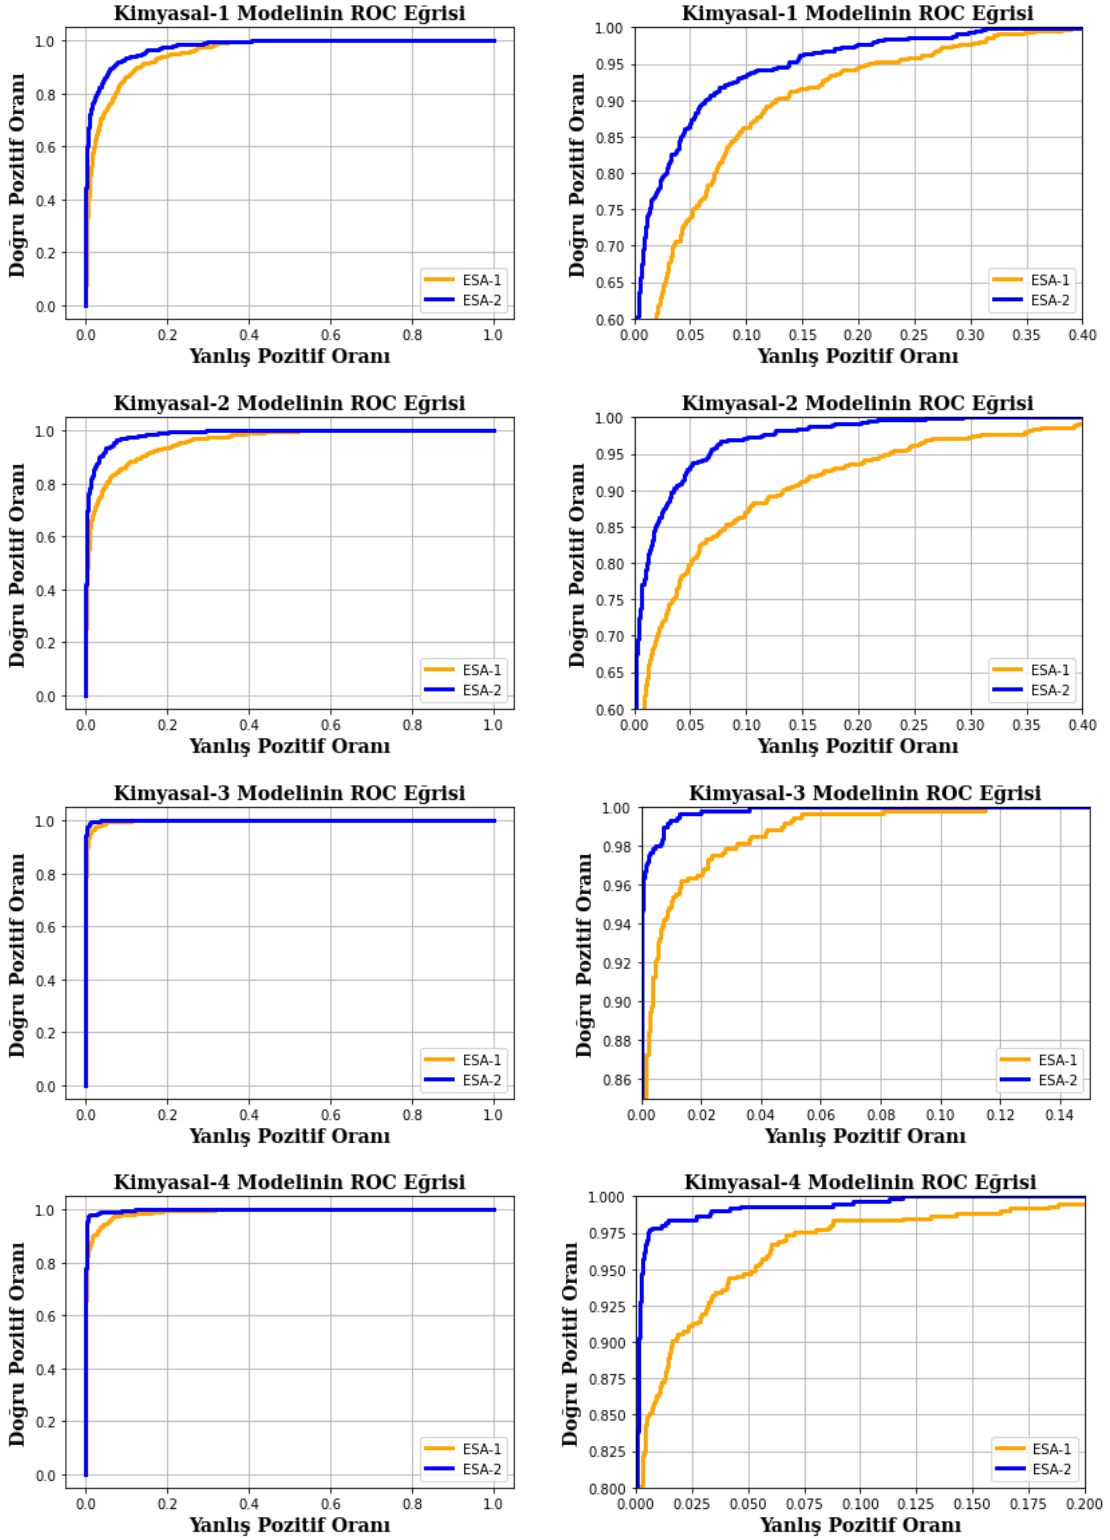


ŞEKİL 6.16: Kimyasal-3 içeren piksellerin normal spektrumları ile çevre piksellerin spektral bilgilerinin ortalaması alınarak elde edilen spektrumlarının kıyaslanması.

tüm spektral bantlardaki değerlerinin ortalaması alınmış ve bu ortalama ilgili pikselin spektrumu olarak modele beslenmiştir. Bu işlem ile bir pikselin spektrumu çevresindeki pikseller ile ilişkilendirilmiştir. Bu yöntem ile yakın piksellerde bir arada bulunan hedef kimyasalların tespitinin daha kolay yapılacağı düşünülmüştür. Ana veri kümesindeki tüm pikseller için bu işlem uygulanmış ve ortalama spektrumlar oluşturulmuştur. Daha sonra model bu verilerle eğitilmiştir. Test aşamasında bir hiperspektral görüntüdeki tüm pikseller için bu ortalama hesaplama işi çok uzun süreceğinden, sonuçlar için her arka plandan birkaç hiperspektral görüntü değerlendirilmiştir. Ancak hiçbir kimyasal modeli için sonuçlarda bir gelişme olmamıştır. Hatta bazı modeller eskisinden bile kötü tespit performansı sergilemiştir. Bunun sebebi ortalama işleminin her piksel için olumlu sonuç vermemesidir. Özellikle birçok hedefin toplu olarak bulunduğu durumlarda ortalama alınca bu topluluğun dış çeperine yakın pikseller için spektrumlar daha iyi olsa da, iç taraftaki piksellerin spektrumu ciddi şekilde bozulmuştur. Şekil 6.16'daki grafiklerin ilk dört tanesinde Kimyasal-3 spektrumunun ortalama alındığında bozulduğu, son dört tanesinde de ortalama alındığında spektrumun daha düzgün olduğu gösterilmiştir. Bu grafiklerden de görüleceği üzere spektral bilgideki bozulmalar kimyasalların ayırt edici özelliklerini yitirmesine ve tespit edilememesine neden olmuştur. Bu durum göz önüne alınarak alogritmaya ortalama alınarak elde edilen spektrumların beslenmesi uygun bulunmamıştır.

### **6.3 ESA-1 ve ESA-2 Modellerinin ROC ve PR Eğrilerinin Karşılaştırılması**

Alıcı İşletim Karakteristiği (ROC) eğrisi çeşitli eşik seviyeleri için doğru pozitif oranı (DPO) ve yanlış pozitif oranı (YPO) kullanılarak çizilen eğridir. Kesinlik-Duyarlılık (PR) eğrisi ise çeşitli eşik seviyelerinde Kesinlik ve Duyarlılık değerleri kullanılarak çizilen eğridir. Bu eğriler ikili sınıflandırma problemlerinde performansı değerlendirmek için sıklıkla kullanılır. ROC eğrisi çoğu ikili sınıflandırma probleminde kullanılsa da, PR eğrisi özellikle dengesiz veri kümelerinin mevcut olduğu durumlarda en çok kullanılan değerlendirme yöntemidir. Bu tez çalışmasında da benzer bir dengesiz veri kümesi durumu olduğu için ESA-1 ve ESA-2 modellerinin performanslarını değerlendirmek amacıyla ROC ve PR eğrileri gözlemlenmiştir.

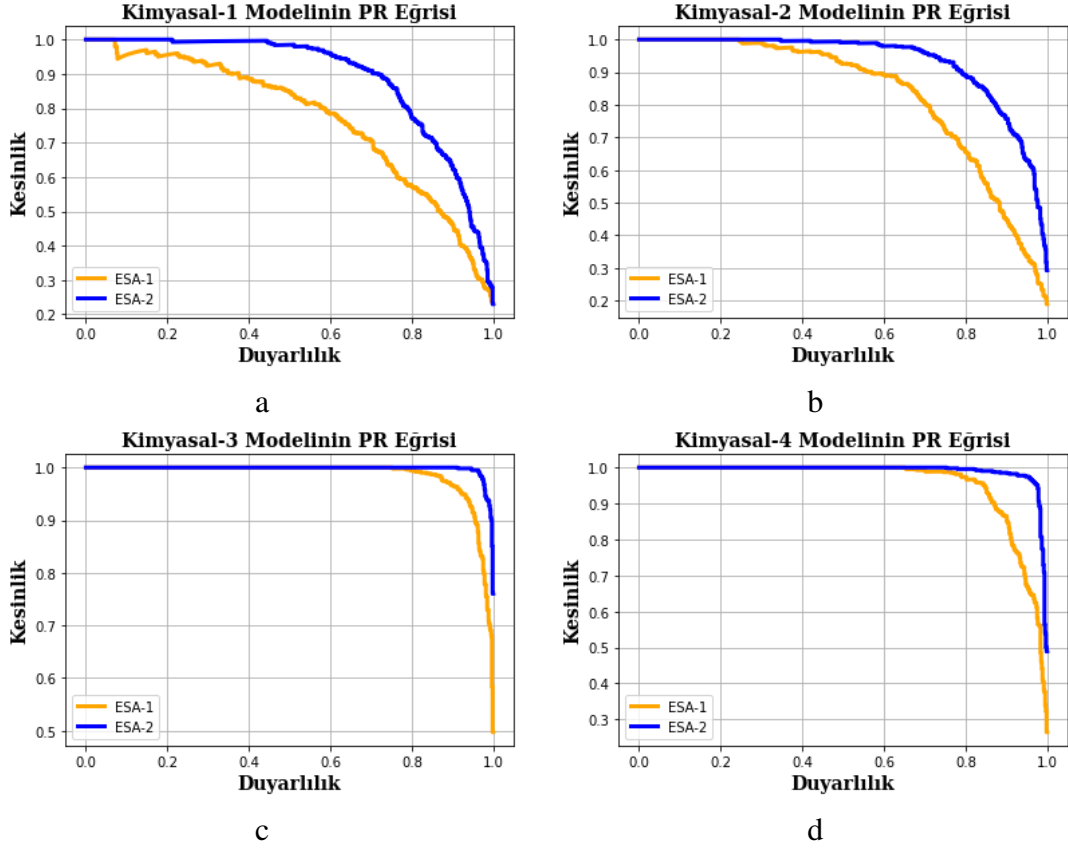


ŞEKİL 6.17: ESA-1’de ve ESA-2’de geliştirilen dört kimyasal modelinin ROC eğrilerinin geniş biçimde ve sol üst bölgeye yakınlaştırılmış biçimde gösterimleri.

ROC ve PR eğrileri çizdirilirken Bölüm 6.1’de ve Bölüm 6.2’de Kesinlik ve Duyarlılık değerleri hesaplanırken ele alınan test görüntüleri kullanılmamıştır. Bunun yerine, bu eğriler elde edilmeden önce Tablo 3.1’deki veri kümesinin %80’i eğitim kümesi, %20’si test kümesi olacak şekilde ayrılmıştır. Veri kümesinin %20’sini oluşturan test kümesi üzerinden ROC ve PR eğrileri hesaplanmıştır. Tablo 6.6’da tüm kimyasallar modelleri için ROC ve PR eğrilerini elde etmek amacıyla veri kümesinin %20’si ayrılarak elde edilen test kümelerinin boyutları verilmiştir. Bu test kümesi ile elde edilen ROC eğrileri Şekil 6.17’de gösterilmiştir. Şeklin sol tarafındaki grafikler ESA-1 ve ESA-2’deki tüm modellerin ROC eğrilerini geniş bir şekilde gösterirken, sağ taraftaki grafikler ise ROC eğrilerinin önemli bölgesi olan sol üst bölgeye yakınlaştırılmış bir biçimde eğrileri göstermektedir. Şekil 6.18 ise bu tez için daha önemli bir değerlendirme ölçütü olan PR eğrilerini göstermektedir. Burada dikkat edilmesi gereken husus, Bölüm 6.1’de ve Bölüm 6.2’de piksel bazlı tablolarda verilen değerler ile bu bölümde çizilen ROC ve PR eğrileri farklı veri kümeleri kullanılarak elde edilmiştir. Bölüm 6.1’de ve Bölüm 6.2’de hesaplamalar yapılırken kullanılan test verileri imaj bazında etiketlenmiştir. Bu imajlardaki her pikselin etiketi ayrı ayrı bilinmediğinden, piksel bazlı tablolardaki Kesinlik ve Duyarlılık değerleri hesaplanırken bir varsayım yapılmıştır. Bu varsayım yapılırken veri kümesindeki her kimyasal ve arka plan kombinasyonu için etiketli eğitim verileri incelenmiştir. Veri toplama işlemi hep aynı şekilde yapıldığından, eğitim verilerindeki etiketlenmiş hedef piksellerin sayılarının ve pozisyonlarının test verileri ile benzer sayılarda ve pozisyonlarda olacağı düşünülmüştür. Her kimyasal ve arka plan kombinasyonundan birkaç test imajında belirli pozisyonlardaki piksellerin spektrumları incelendikten sonra bu durumun düşünüldüğü gibi olduğu görülmüştür. Böylece her kimyasal ve arka plan kombinasyonu için otomatik etiketleme benzeri bir işlem yapılmıştır. Bundan dolayı piksel bazlı tablolardaki Duyarlılık değerleri en kötü koşul için değerlendirilmiştir. Sonuç olarak, test kümesindeki imajların içerdiği pikseller etiketli olmadığı için bu bölümdeki PR eğrileri ile önceki bölümlerdeki Kesinlik ve Duyarlılık değerlerini doğrudan ilişkilendirmek doğru değildir.

TABLO 6.6: Dört kimyasal madde için veri kümelerinin %20'si ayrılarak elde edilen test kümelerinin boyutları.

Kimyasal Madde	Arka Plan Pksel	Hedef Pksel	Toplam Pksel
Kimyasal-1	5336	412	5748
Kimyasal-2	5336	489	5825
Kimyasal-3	5336	593	5929
Kimyasal-4	5336	633	5969



ŞEKİL 6.18: ESA-1'de ve ESA-2'de geliştirilen dört kimyasal modelinin PR eğrilerinin gösterimi. a) Kimyasal-1 modelinin ESA-1'deki ve ESA-2'deki PR eğrisi, b) Kimyasal-2 modelinin ESA-1'deki ve ESA-2'deki PR eğrisi, c) Kimyasal-3 modelinin ESA-1'deki ve ESA-2'deki PR eğrisi, d) Kimyasal-4 modelinin ESA-1'deki ve ESA-2'deki PR eğrisi.

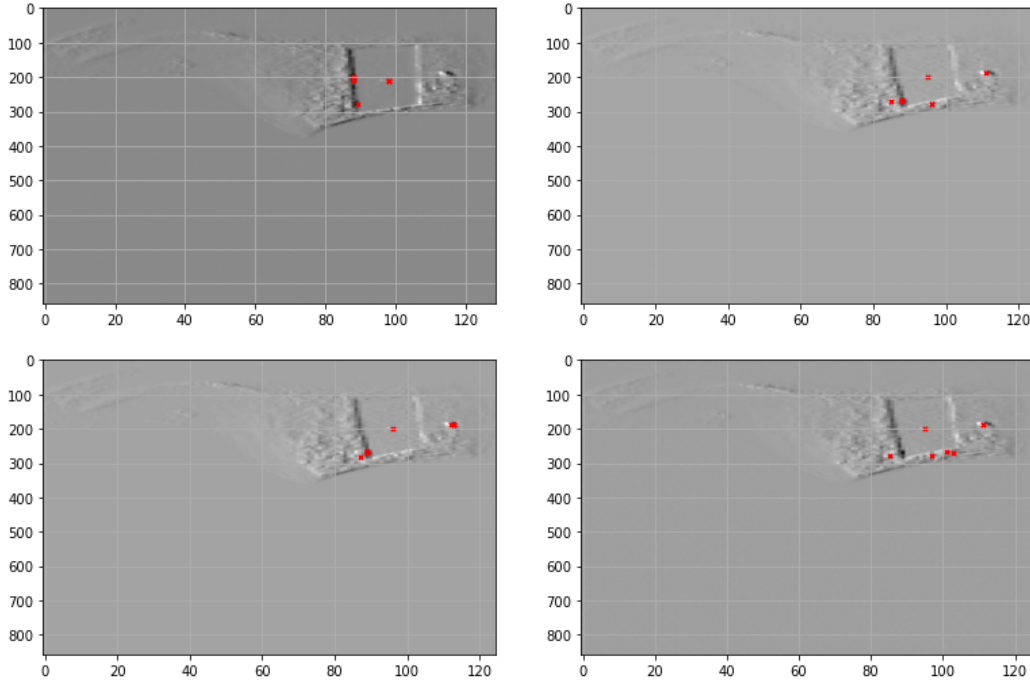
#### 6.4 UKSB ile Geliştirilen Modellerin Testleri ve Sonuçları

ESA-1'den ESA-2'ye geçerken uzak ve yakın korelasyonları aynı anda değerlendirmenin üstünde çalışılan problem için faydalı olduğu görülmüştür. ESA-2 mimarisinde spektral bilgi iki boyutlu hale getirilmiş ve uygulanan  $3 \times 3$  filtreler ile verideki uzak ve yakın komşuluktaki elemanlar arasında korelasyonlar sağlanmıştır. Bu yaklaşımdan yola çıkarak genellikle ses ve metin gibi tek boyutlu verilerin işlenmesinde kullanılan UKSB modeli ele alınmıştır. UKSB modeli uzun süreli hafızaya sahip olduğu için girdi verisindeki birbirinden uzak noktaları birlikte değerlendirme yeteneğine sahiptir. Bu da ESA-2'deki gibi uzak noktalar arasında korelasyon kurulmasını sağlamaktadır. Bu modelin kullanımındaki asıl amaç spektral veriler arasındaki bağlantıyı ESA-2'den daha iyi modelleyen bir yapı elde etmektir. Bu yüzden çeşitli UKSB mimarileri, birçok parametre kümesiyle denenerek hiperspektral görüntülerdeki piksellerin sınıflandırılması amaçlanmıştır. Ancak bu tez kapsamında üretilen en iyi UKSB modeli beklendiği gibi sonuçlar üretmemiştir. UKSB modelleri hedef içeren ve içermeyen tüm görüntülerde tespit edilen YP birçok piksel nedeniyle "hedef var" olarak sınıflandırma yaptığından, imaj bazlı değerlendirme bu modeller için anlamsız hale gelmiştir. Bu yüzden sadece piksel bazlı sonuçlar Tablo 6.7'de verilmiştir. Bu tablodan da görüleceği üzere Duyarlılık değerleri genellikle yüksek hesaplanmıştır. Bunun nedeni geliştirilen modellerin neredeyse tüm hedef içeren pikselleri doğru tahmin etmesidir. Ancak bunun yanında Kesinlik değerleri de çok düşük hesaplanmıştır. Bunun nedeni de çok fazla YP piksel tespit edilmesidir. Bu yüzden UKSB modelleri kimyasal hedef tespiti görevini beklendiği gibi yapamamıştır. UKSB'den beklenen spektral bilgideki yakın ve uzak noktaları bağdaştırmak olsa da, evrişim benzeri bir yapı kullanılmadığından spektral bilgideki karakteristik özellikler yakalanamamıştır. Bu yüzden de özellikle ayakkabı üzerinde ve arka plan materyalinin üzerinde birçok YP piksel tespit edilmiştir.

Şekil 6.19'da UKSB mimarisinde geliştirilen kimyasal modellerinin genellikle tespit ettiği YP pikseller gösterilmiştir. YP piksellerin genellikle kenar piksellerden farklı yerlerde tespit edilmesi de, eğitilen UKSB modellerinin hedef kimyasalların karakteristik spektral bilgilerini iyi bir şekilde öğrenemediğini göstermektedir.

TABLO 6.7: Dört kimyasal için UKSB mimarisi ile geliştirilen modellerin piksel bazlı performans sonuçları.

Arka Plan	Ölçüt	Kimyasal-1 Modeli	Kimyasal-2 Modeli	Kimyasal-3 Modeli	Kimyasal-4 Modeli
Arka Plan-1	Kesinlik	0.39	0.32	0.47	0.42
	Duyarlılık	0.83	0.87	0.94	0.80
Arka Plan-2	Kesinlik	0.22	0.29	0.39	0.33
	Duyarlılık	0.69	0.77	0.85	0.78
Arka Plan-3	Kesinlik	0.31	0.32	0.45	0.38
	Duyarlılık	0.78	0.81	0.92	0.81
Arka Plan-4	Kesinlik	0.34	0.34	0.52	0.44
	Duyarlılık	0.81	0.85	0.96	0.86

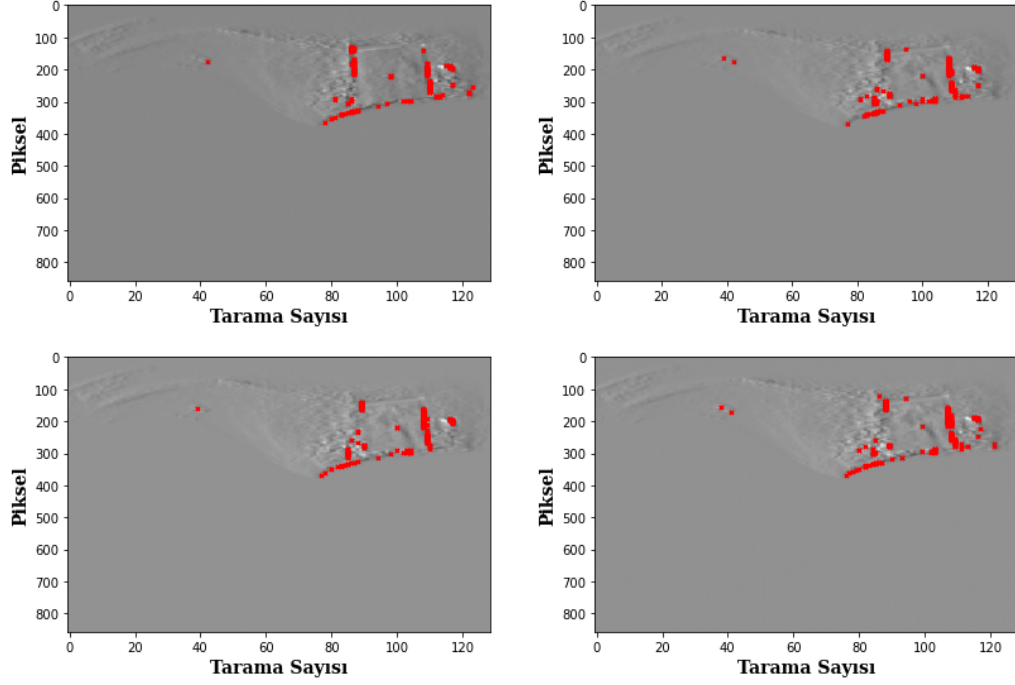


ŞEKİL 6.19: Tüm katmanlardaki nöron sayıları 256 olduğu durumda UKSB modellerindeki hedef tespiti örnekleri.

Ayrıca bu tez çalışmasında yapılan testlerde en uygun nöron sayısının 256 olduğunu göstermek için ikinin 8 ile 2048 arasındaki tüm kuvvetleri için UKSB modelinin tüm katmanlarındaki nöron sayıları değiştirilerek eğitim süreci tekrarlanmıştır. Nöron sayısı 512'nin üstüne çıktığında aşırı uyum durumu olduğundan görüntülerde hiçbir tespit yapılamamıştır. Nöron sayısının



8 olduğu durumda ise tespit edilen pikseller Şekil 6.20’de gösterilmiştir. Nöron sayısının 8 ile 256 arasındaki tüm değerleri için benzer sonuçlar üretilse de, sonuçlar nöron sayısı 256’ya yaklaştıkça iyileşmektedir.



ŞEKİL 6.20: Tüm katmanlardaki nöron sayıları 8 olduğu durumda UKSB modellerindeki hedef tespiti örnekleri.

## 6.5 Uygulamada Kullanılan Yazılımlar ve Donanımlar

Bu tez kapsamında kullanılan eğitim kümesindeki ham verilere uygulanan Diferansiyel Reflektometri ve Savitzky-Golay filtreleme işlemleri MATLAB’da kodlanmıştır. Bu işlemler MATLAB ortamında yapıldıktan sonra derin öğrenme modellerinde kullanılmak amacıyla kaydedilmiştir. Geliştirilen tüm derin öğrenme modelleri Python programlama dilinde Keras kütüphaneleri kullanılarak gerçekleştirilmiştir. Derin öğrenme modelinin dışarda veri okuma ve yazma, veri kümesinin ayrıştırılması ve karıştırılması, yardımcı matematiksel işlemlerin yapılması, verilerin ve sonuçların görselleştirilmesi gibi işlemler için Numpy, Scikit-Learn,

Pandas ve Matplotlib paketleri kullanılmıştır. Derin öğrenme modellerinin eğitiminde paralelleştirmeyi ve eğitim hızını arttırmak amacıyla NVIDIA GEFORCE GTX 1650 grafik işlemcisi (GPU) kullanılmıştır. Yığın boyu küçük ve SGD yöntemi kullanılan modellerin eğitimi ortalama 30 dakika sürerken, yığın boyu büyük ve Adam yöntemi kullanılan modellerin eğitimi ortalama 20 dakika sürmüştür. Test aşaması için belirli bir klasördeki girdi verisi dosyasını okuyup Diferansiyel Reflektometri ve Savitzky-Golay filtreleme işlemlerini uyguladıktan sonra sınıflandırma için modele besleyen ve sınıflandırma çıktısını bir dosyaya yazan bir Python kodu hazırlanmıştır. Daha sonra bu Python kodu PyInstaller adlı paket ile çalıştırılabilir (exe) bir uygulamaya dönüştürülmüştür.

## 7. SONUÇLAR VE DEĞERLENDİRME

Bu tez kapsamında, çeşitli derin öğrenme modelleri ile hiperspektral görüntülerde kimyasal hedeflerin tespiti için yapılan çalışmaların amaçlarıdır. Bu amaç doğrultusunda bir düzenek yardımıyla kimyasal hedef içeren ve içermeyen hiperspektral görüntülerden belirli yöntemlerle pikseller seçilmiş ve bu piksellerin spektral boyutundaki bilgiler veri kümesi olarak kullanılmıştır. Dört kimyasal madde için dört farklı veri kümesi oluşturulmuştur. Tüm kimyasallar için ilgili veri kümesini kullanan farklı modeller oluşturulmuştur. Veri kümesindeki veriler derin öğrenme modellerine beslenmeden önce iki ön işleme aşamasından geçirilmiştir. İlk aşamada kimyasal maddelerin spektrumlarındaki soğurum kenarlarını belirginleştirmek ve spektrumları daha ayırt edici yapmak amacıyla Diferansiyel Reflektometri kullanılmıştır. İkinci aşamada ise piksellerin spektrumlarını daha düzgün ve gürültüsüz yapmak amacıyla Savitzky-Golay filtrelemesi yapılmıştır. Ön işlemeden geçen veriler derin öğrenme modellerine beslenmiştir.

Bu çalışmada hiperspektral görüntülerdeki kimyasal maddelerin tespiti için üç farklı derin öğrenme mimarisi üzerinde durulmuştur. İlk olarak geliştirilen ESA-1 mimarisinde, girdi verileri ve modeldeki tüm katmanlar tek boyutlu olarak tasarlanmıştır. ESA-1 hiperspektral görüntüdeki piksellerin  $1 \times 548$  boyutlu spektrumlarını almış ve bu piksellerde hedef bulunup bulunmadığının kararını vermiştir. Bu mimaride dört kimyasal için geliştirilen modellerin sonuçları incelenmiştir. Bu sonuçlardan bazı arka planlarda kimyasal maddelerin tespit başarımının oldukça düşük olduğu görülmüştür. Bunun sebebinin bazı arka planların yansıma spektrumlarının kimyasalların spektrumundaki karakteristik özellikleri bozması olduğu anlaşılmıştır. ESA-1 sonuçlarında görünen başka bir durum ise görüntülerdeki şekil ve nesnelerin kenarlarında YP piksellerin tespit edilmesidir. Her model için tekrarlanan bu davranış incelendiğinde, bunun sebebinin kenar piksellerin spektrumlarının hedef spektrumlarına çok benzemesi olduğu ve bu yüzden de sınıflandırıcının hata yaptığı tespit edilmiştir. ESA-1 performansını etkileyen son etmenin ise hiperspektral görüntü toplanan yüzeydeki kimyasal madde miktarı olduğu görülmüştür. Kimyasal madde miktarının az olması direkt olarak tespit performansının düşmesine neden olmuştur. Bu dezavantajlar göz

önüne alınarak ESA-1'in performansı yeterli görülmemiş ve farklı bir yapıya sahip ESA-2 mimarisi tasarlanmıştır. ESA-2'nin ESA-1'den temel farkı iki boyutlu girdi verilerini alıp iki boyutlu katmanlarda iki boyutlu işlemler yapmasıdır. ESA-2 mimarisinde geliştirilen dört modelin performansı incelendiğinde, ESA-1 sonuçlarına göre önemli performans gelişmeleri olduğu görülmüştür. Bunun en büyük sebebi verilerin iki boyutlu halde modellere beslenmesi olmuştur. Verilerin iki boyutlu hale getirilmesi ve iki boyutlu evrimsel filtrelerden geçirilmesi verideki uzak ve yakın noktalar arasındaki korelasyona odaklandığından kimyasalların spektrumlarındaki karakteristik özelliklerin ayırt edilmesini kolaylaştırmıştır. ESA-1'deki arka plan ve kenar piksel problemleri ara ara ESA-2 modellerinde de fark edilse de, genellikle ESA-2'deki tüm modellerin kimyasal tespit performansları önemli başarılar göstermiştir. ESA-2'deki modellerin performansları genel olarak başarılı olsa da, bazı arka planlarda ve özellikle bazı belirli kenar piksellerde karşılaşılan YP piksel problemini çözmek için çeşitli yöntemler denenmiştir. Bu yöntemlerde ESA-2 modellerinin performansının kusursuza yaklaştırmak adına azınlık sınıfın örnek sayısının artırılması, çevre piksellerinde tespit bulunmayan piksellerin tespit kümesinden çıkarılması, sınıflandırma olasılıkları üzerinden eşikleme yapılması ve çevre piksellerin spektrumlarının ortalamalarının girdi olarak modellere beslenmesi gibi teknikler denenmiştir. Ancak bu tekniklerin çoğunda YP piksellerin sayısı azalırken, DP piksellerin de sayısı azalmış, bazılarında ise tespit edilen piksellerde fark edilir hiçbir değişiklik olmamıştır. Son olarak, geliştirilen ESA-2 yapısının uzak ve yakın noktalar arasındaki korelasyonlara önem vermesi göz önüne alınmış ve uzak noktalar arasındaki bilgi paylaşımı için en çok kullanılan derin öğrenme modellerinden biri olan UKSB mimarisi tasarlanmıştır. UKSB'nin uzun süreli hafıza yapısının performansı iyileştireceği düşünülmüştür. Ancak geliştirilen UKSB'nin kimyasal hedeflerdeki tespit performansları incelendiğinde beklenen sonuçların elde edilmediği görülmüştür. UKSB modelleri spektrumdaki uzak noktalar arasındaki korelasyonları sağlamaya çalışsa da, evrim benzeri bir yapı içermediğinden kimyasalların spektrumlarındaki ayırt edici özellikleri tespit edememiştir. Bu yüzden de ESA-1 ve ESA-2'ye göre çok fazla YP piksel tespit etmiştir.

Sonuçta, bu tez çalışmasında geliştirilen ESA modelleri ile tehlikeli kimyasal maddelerin birçok arka plan üzerinde başarılı bir şekilde tespit edilebildiği literatüre kazandırılmıştır.

Özellikle tek boyutlu ESA-1 mimarisinden iki boyutlu ESA-2 mimarisine geçişin ve girdi verilerinin iki boyutlu forma dönüştürülmesinin tehlikeli kimyasalların tespitindeki önemi bu tezde vurgulanmıştır. Veri kümesi boyutunun artırılmasıyla, kenar piksel ve arka plan problemlerinin nokta atışı yöntemlerle daha fazla iyileştirilmesiyle kimyasalların tespit performansının ciddi şekilde artırılacağı gösterilmiştir. UKSB modellerinin üzerinde yapılacak detaylı çalışmalar ile tehlikeli kimyasal hedeflerin tespitinde gelecek vaat eden bir yöntem olduğu belirtilmiştir.

## KAYNAKLAR

- [1] J Sarah Caygill, Frank Davis, and Seamus PJ Higson. Current trends in explosive detection techniques. *Talanta*, 88:14–29, **2012**.
- [2] Seniha Esen Yuksel, Thierry Dubroca, Rolf E Hummel, and Paul D Gader. An automatic detection software for differential reflection spectroscopy. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XVIII*, volume 8390, page 83900B. International Society for Optics and Photonics, **2012**.
- [3] Dimitris Manolakis, David Marden, Gary A Shaw, et al. Hyperspectral image processing for automatic target detection applications. *Lincoln laboratory journal*, 14(1):79–116, **2003**.
- [4] Dimitris Manolakis and Gary Shaw. Detection algorithms for hyperspectral imaging applications. *IEEE signal processing magazine*, 19(1):29–43, **2002**.
- [5] Nasser M Nasrabadi. Hyperspectral target detection: An overview of current and future challenges. *IEEE Signal Processing Magazine*, 31(1):34–44, **2013**.
- [6] Xiaoying Jin, Scott Paswaters, and Harold Cline. A comparative study of target detection algorithms for hyperspectral imagery. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV*, volume 7334, page 73341W. International Society for Optics and Photonics, **2009**.
- [7] Utsav B Gewali, Sildomar T Monteiro, and Eli Saber. Machine learning based hyperspectral image analysis: a survey. *arXiv preprint arXiv:1802.08701*, **2018**.
- [8] Russell E Warren and David B Cohn. Chemical detection on surfaces by hyperspectral imaging. *Journal of Applied Remote Sensing*, 11(1):015013, **2017**.
- [9] Thierry Dubroca and Rolf E Hummel. Detection of explosives by hyper-spectral differential reflectometry. *MRS Online Proceedings Library Archive*, 1405, **2012**.

- [10] Thierry Dubroca, Gregory Brown, and Rolf E Hummel. Detection of explosives by differential hyperspectral imaging. *Optical Engineering*, 53(2):021112, **2014**.
- [11] Liangpei Zhang, Lefei Zhang, and Bo Du. Deep learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2):22–40, **2016**.
- [12] Xiao Xiang Zhu, Devis Tuia, Lichao Mou, Gui-Song Xia, Liangpei Zhang, Feng Xu, and Friedrich Fraundorfer. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4):8–36, **2017**.
- [13] Alberto Signoroni, Mattia Savardi, Annalisa Baronio, and Sergio Benini. Deep learning meets hyperspectral image analysis: a multidisciplinary review. *Journal of Imaging*, 5(5):52, **2019**.
- [14] John E Ball, Derek T Anderson, and Chee Seng Chan. Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community. *Journal of Applied Remote Sensing*, 11(4):042609, **2017**.
- [15] Lichao Mou, Pedram Ghamisi, and Xiao Xiang Zhu. Deep recurrent neural networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(7):3639–3655, **2017**.
- [16] Wei Hu, Yangyu Huang, Li Wei, Fan Zhang, and Hengchao Li. Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015, **2015**.
- [17] Shaohui Mei, Jingyu Ji, Qianqian Bi, Junhui Hou, Qian Du, and Wei Li. Integrating spectral and spatial information into deep convolutional neural networks for hyperspectral classification. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 5067–5070. IEEE, **2016**.

- [18] Nanjun He, Mercedes E Paoletti, Juan Mario Haut, Leyuan Fang, Shutao Li, Antonio Plaza, and Javier Plaza. Feature extraction with multiscale covariance maps for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(2):755–769, **2018**.
- [19] Jinming Du, Zhiyong Li, and Hao Sun. Cnn-based target detection in hyperspectral imagery. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*, pages 2761–2764. IEEE, **2018**.
- [20] Wei Li, Guodong Wu, and Qian Du. Transferred deep learning for hyperspectral target detection. In *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 5177–5180. IEEE, **2017**.
- [21] Wei Li, Guodong Wu, Fan Zhang, and Qian Du. Hyperspectral image classification using deep pixel-pair features. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2):844–853, **2016**.
- [22] Hyungtae Lee and Heesung Kwon. Contextual deep cnn based hyperspectral classification. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 3322–3325. IEEE, **2016**.
- [23] Shiqi Yu, Sen Jia, and Chunyan Xu. Convolutional neural networks for hyperspectral image classification. *Neurocomputing*, 219:88–98, **2017**.
- [24] Zilong Zhong, Jonathan Li, Lingfei Ma, Han Jiang, and He Zhao. Deep residual networks for hyperspectral image classification. In *2017 IEEE international geoscience and remote sensing symposium (IGARSS)*, pages 1824–1827. IEEE, **2017**.
- [25] Jingxiang Yang, Yongqiang Zhao, Jonathan Cheung-Wai Chan, and Chen Yi. Hyperspectral image classification using two-channel deep convolutional neural network. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 5079–5082. IEEE, **2016**.



- [26] T Jiang and XJ Wang. Hyperspectral images classification based on fusion features derived from 1d and 2d convolutional neural network. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42:335–341, **2020**.
- [27] Yushi Chen, Zhouhan Lin, Xing Zhao, Gang Wang, and Yanfeng Gu. Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected topics in applied earth observations and remote sensing*, 7(6):2094–2107, **2014**.
- [28] Yushi Chen, Xing Zhao, and Xiuping Jia. Spectral–spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6):2381–2392, **2015**.
- [29] Feng Zhou, Renlong Hang, Qingshan Liu, and Xiaotong Yuan. Hyperspectral image classification using spectral-spatial lstms. *Neurocomputing*, 328:39–47, **2019**.
- [30] Yonghao Xu, Liangpei Zhang, Bo Du, and Fan Zhang. Spectral–spatial unified networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(10):5893–5909, **2018**.
- [31] Haibo He and Edwardo A Garcia. Learning from imbalanced data. *IEEE Transactions on knowledge and data engineering*, 21(9):1263–1284, **2009**.
- [32] Guo Haixiang, Li Yijing, Jennifer Shang, Gu Mingyun, Huang Yuanyue, and Gong Bing. Learning from class-imbalanced data: Review of methods and applications. *Expert Systems with Applications*, 73:220–239, **2017**.
- [33] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. *Introduction to data mining*. Pearson Education India, **2016**.
- [34] RE Hummel, DB Dove, and J Alfaro Holbrook. Optical reflectivity measurements on alloys by compositional modulation. *Physical Review Letters*, 25(5):290, **1970**.

- [35] Thierry Dubroca, Karthik Vishwanathan, and Rolf E Hummel. The limit of detection for explosives in spectroscopic differential reflectometry. In *Chemical, Biological, Radiological, Nuclear, and Explosives (CBRNE) Sensing XII*, volume 8018, page 80181L. International Society for Optics and Photonics, **2011**.
- [36] Abraham Savitzky and Marcel JE Golay. Smoothing and differentiation of data by simplified least squares procedures. *Analytical chemistry*, 36(8):1627–1639, **1964**.
- [37] Ronald W Schafer. What is a savitzky-golay filter? *IEEE Signal processing magazine*, 28(4):111–117, **2011**.
- [38] Fırat Gürbüz. *Diferansiyel Hiperspektral Görüntüleme Tekniği ile Kimyasal Madde Tespit Yöntemlerinin İncelenmesi*. Master's thesis, Fen Bilimleri Enstitüsü, **2019**.
- [39] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, **1943**.
- [40] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, **1958**.
- [41] Marvin Minsky and Seymour A Papert. *Perceptrons: An introduction to computational geometry*. MIT press, **2017**.
- [42] James L McClelland, David E Rumelhart, PDP Research Group, et al. Parallel distributed processing. *Explorations in the Microstructure of Cognition*, 2:216–271, **1986**.
- [43] Laurene Fausett. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice-Hall, Inc., USA, **1994**. ISBN 0133341860.
- [44] Howard B Demuth, Mark H Beale, Orlando De Jess, and Martin T Hagan. *Neural network design*. Martin Hagan, **2014**.

- [45] Ilya Sutskever, James Martens, George Dahl, and Geoffrey Hinton. On the importance of initialization and momentum in deep learning. In *International conference on machine learning*, pages 1139–1147. **2013**.
- [46] Tijmen Tieleman and Geoffrey Hinton. Rmsprop: Divide the gradient by a running average of its recent magnitude. coursera: Neural networks for machine learning. *COURSERA Neural Networks Mach. Learn*, **2012**.
- [47] Matthew D Zeiler. Adadelta: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*, **2012**.
- [48] John Duchi, Elad Hazan, and Yoram Singer. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7), **2011**.
- [49] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, **2014**.
- [50] Ian Goodfellow, Yoshua Bengio, Aaron Courville, and Yoshua Bengio. *Deep learning*, volume 1. MIT press Cambridge, **2016**.
- [51] Agnieszka Mikołajczyk and Michał Grochowski. Data augmentation for improving deep learning in image classification problem. In *2018 international interdisciplinary PhD workshop (IIPhDW)*, pages 117–122. IEEE, **2018**.
- [52] Connor Shorten and Taghi M Khoshgoftaar. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1):60, **2019**.
- [53] Ekin D Cubuk, Barret Zoph, Dandelion Mane, Vijay Vasudevan, and Quoc V Le. Autoaugment: Learning augmentation policies from data. *arXiv preprint arXiv:1805.09501*, **2018**.
- [54] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1):1929–1958, **2014**.

- [55] Sidharth Mishra, Uttam Sarkar, Subhash Taraphder, Sanjoy Datta, Devi Swain, Reshma Saikhom, Sasmita Panda, and Menalsh Laishram. Principal component analysis. *International Journal of Livestock Research*, page 1, **2017**. doi:10.5455/ijlr.20170415115235.
- [56] Jacob Goldberger, Sam Roweis, Geoff Hinton, and Ruslan Salakhutdinov. Neighbourhood components analysis. In *Proceedings of the 17th International Conference on Neural Information Processing Systems*, NIPS'04, page 513–520. MIT Press, Cambridge, MA, USA, **2004**.
- [57] Yann LeCun, Léon Bottou, Yoshua Bengio, and Patrick Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, **1998**.
- [58] Matthew D Zeiler and Rob Fergus. Visualizing and understanding convolutional networks. In *European conference on computer vision*, pages 818–833. Springer, **2014**.
- [59] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9. **2015**.
- [60] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, **2014**.
- [61] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778. **2016**.
- [62] Fei-Fei Li, Andrej Karpathy, and Justin Johnson. Cs231n: Convolutional neural networks for visual recognition, **2016**.

- [63] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc., **2012**.
- [64] Y. Bengio, P. Simard, and P. Frasconi. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2):157–166, **1994**.
- [65] Andrew L Maas, Awni Y Hannun, and Andrew Y Ng. Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml*, volume 30, page 3. **2013**.
- [66] K. Jarrett, K. Kavukcuoglu, M. Ranzato, and Y. LeCun. What is the best multi-stage architecture for object recognition? In *2009 IEEE 12th International Conference on Computer Vision*, pages 2146–2153. **2009**.
- [67] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted boltzmann machines. In *ICML*. **2010**.
- [68] Xavier Glorot, Antoine Bordes, and Yoshua Bengio. Deep sparse rectifier neural networks. In *AISTATS*. **2011**.
- [69] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*, **2015**.
- [70] SH Shabbeer Basha, Shiv Ram Dubey, Viswanath Pulabaigari, and Snehasis Mukherjee. Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378:112–119, **2020**.
- [71] David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, 323(6088):533–536, **1986**.
- [72] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, **1997**.

- [73] Jimmy Lei Ba, Jamie Ryan Kiros, and Geoffrey E Hinton. Layer normalization. *arXiv preprint arXiv:1607.06450*, **2016**.
- [74] Nitesh V Chawla, Kevin W Bowyer, Lawrence O Hall, and W Philip Kegelmeyer. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16:321–357, **2002**.