T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

EVRİŞİMLİ SİNİR AĞLARI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRILMASI

Ali GÜNDÜZ

DANIŞMAN
Prof. Dr. Zeynep ORMAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Haziran, 2023

TEZ KABUL VE ONAYI

Ali GÜNDÜZ tarafından, **Prof. Dr. Zeynep ORMAN** danışmanlığında hazırlanan **"EVRİŞİMLİ SİNİR AĞLARI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRILMASI"** başlıklı bu çalışma, jürimiz tarafından **22/06/2023** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Prof. Dr. Zeynep ORMAN İstanbul Üniversitesi - Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Rüya ŞAMLI İstanbul Üniversitesi - Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Can EYÜPOĞLU Milli Savunma Üniversitesi Hava Harp Okulu Bilgisayar Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret

Aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

EVRİŞİMLİ SİNİR AĞLARI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRILMASI

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Tez sürecinde bana yol gösteren çok kıymetli Hocam sayın Prof.Dr. Zeynep ORMAN'a en içten duygularımla teşekkür ederim.

Haziran 2023 Ali GÜNDÜZ

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiii**
ABSTRACT ..... **xv**

1. GİRİŞ **1**
1.1. Araştırmanın Konusu 4
2. KAVRAMSAL ÇERÇEVE **6**
2.1. Boyut Azaltma Teknikleri 6
2.2. Derin Öğrenme 8
2.2.1. Evrişimli Sinir Ağları 11
2.2.2. Tekrarlayan Sinir Ağları 14
2.2.3. Dikkat Mekanizması 16
2.3. LİTERATÜR ÇALIŞMALARI 18
2.4. Literatür Analizi 22
3. YÖNTEM **23**
3.1. Veri Kümeleri 23
3.2. Önerilen Model 30
3.3. Veri Ön İşleme 31
3.4. Spektral Modülün İşlenmesi 33
3.5. Mekansal Modülün İşlenmesi 35
3.6. Spektral ve Mekansal Modülün Birleştirilmesi 37

4. BULGULAR 39
4.1. Değerlendirme Metrikleri 39
4.1.1. F1 Puanı 39
4.1.2. Genel Doğruluk (OA) 40
4.1.3. Ortalama Doğruluk (AA) 40
4.1.4. Kappa Katsayısı 41
4.2. Performans Analizi 41
5. TARTIŞMA 52
6. SONUÇ VE ÖNERİLER 53

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Bir Evrişimli Sinir Ağı Örneği..……13
Şekil 3.1: Indian Pines veri kümesi..……28
Şekil 3.2: Salinas veri kümesi..……29
Şekil 3.3: Pavia Üniversitesi veri kümesi..……29
Şekil 3.4 Kennedy Uzay Merkezi veri kümesi……30
Şekil 3.5: Geliştirilen modelin genel yapısı..……31
Şekil 4.1: IP veri kümesi için epoklara göre hata ve doğ..……46
Şekil 4.2: PU veri kümesi için epoklara göre hata ve doğruluk grafikleri..……47
Şekil 4.3: KSC veri kümesi için epoklara göre hata ve doğruluk grafikleri..……49
Şekil 4.4: SA veri kümesi için epoklara göre hata ve doğruluk grafikleri..……51

TABLO LİSTESİ

Sayfa No

Tablo 3.1: IP, SA, PU, KSC veri kümelerinin özellikleri……..….24

Tablo 3.2: Indian Pines veri kümelerinin arazi örtüsü sınıfları…….25

Tablo 3.3: Pavia Üniversitesi veri kümesinin arazi örtüsü sınıfları……..……25

Tablo 3.4: Salinas veri kümesinin arazi örtüsü sınıfları..……..……...26

Tablo 3.5: Kennedy Space Center veri kümesinin arazi örtüsü sınıfları……27

Tablo 4.1: Indian Pines veri kümesi için %5 eğitim oranıyla elde edilen sonuçlar…….……42

Tablo 4.2: Pavia Üniversitesi veri kümesi için %1 ve %5'lik eğitim oranlarıyla alınan sonuçlar…….43

Tablo 4.3: KSC veri kümesi için %1 ve %5'lik eğitim oranlarıyla alınan sonuçlar…….…44

Tablo 4.4: Indian Pines veri kümesi için önerilen modelin karşılaştırılması…….……45

Tablo 4.5: Pavia Üniversitesi veri kümesi için önerilen modelin karşılaştırılması……47

Tablo 4.6: KSC veri kümesi için önerilen modelin karşılaştırılması..……..……48

Tablo 4.7: Salinas veri kümesi için önerilen modelin karşılaştırılması..……..……50

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
HSI	: Hyperspectral Image (Hiperspektral Görüntü)
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağları)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağları)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
KNN	: K-Nearest Neighbourgh (K En Yakın Komşu)
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
HSIC	: Hyperspectral Image Classification (Hiperspektral Görüntü Sınıflandırma)
GRU	: Gated Recurrent Units (Kapılı Tekrarlayan Birimler)
NMF	: Non-negative Matrix Factorization (Negatif Olmayan Matrix Faktorizasyonu)
LLE	: Locally Linear Embedding (Yerel Doğrusal Gömme)
LSTM	: Long-Short Term Memory (Uzun Kısa Vadeli Bellek)
MSE	: Mean Squared Error (Ortalama Kare Hatası)
DCNN	: Deep Convolutional Neural Network (Derin Evrişimli Sinir Ağları)
FE	: Feature Extraction (Özellik Çıkarımı)
FC	: Fully Connected (Tam Bağlantılı)
CONV	: Convolutional (Evrişimli)
PC	: Principal Component (Temel Bileşen)
ReLU	: Rectified Linear Unit (Doğrultulmuş Lineer Birim)
Bi-RNN	: Bidirectional Recurrent Neural Network (Çift Yönlü Tekrarlayan Sinir Ağları)
ICA	: Independent Component Analysis (Bağımsız Bileşen Analizi)
IP	: Indian Pines
PU	: Pavia University (Pavia Üniversitesi)
SA	: Salinas
KSC	: Kennedy Space Center (Kennedy Uzay Merkezi)
OA	: Overall Accuracy (Genel Doğruluk)
AA	: Average Accuracy (Ortalama Doğruluk)

RF : Random Forest (Rastgele Orman)

NLP : Natural Language Processing (Doğal Dil İşleme)

FCN : Fully Convolutional Network (Tam Evrişimli Ağ)

ÖZET

YÜKSEK LİSANS TEZİ

EVRİŞİMLİ SİNİR AĞLARI KULLANILARAK HİPERSPEKTRAL GÖRÜNTÜLERİN SINIFLANDIRILMASI

Ali GÜNDÜZ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Danışman : Prof. Dr. Zeynep ORMAN

Hiperspektral görüntüleme, görünür ve kısa dalga kızılötesi spektrumları arasında yer alan geniş bir spektral aralığı boyunca detaylı ve sürekli bir spektral görüntü sağlar. Hiperspektral görüntüler, binlerce spektral bant içerebilen, nesnelerin veya arazinin derinlemesine bir görüntüsünü barındırır. Bu yüzden, gözle görülemeyen karmaşık detayları içerir ve dolayısıyla, bu görüntülerin analizi maden keşfi, tarım, çevresel izleme ve askeri istihbarat gibi çeşitli sektörlerde pek çok uygulama alanında son derece önemlidir. Hiperspektral görüntülerin etkin bir şekilde kullanılabilmesi için, bu tür görüntülerin dikkatli bir şekilde sınıflandırılması gereklidir. Sınıflandırma, bir görüntünün her bir pikselini önceden belirlenmiş sınıflara veya kategorilere atama sürecidir. Hiperspektral görüntülerin sınıflandırılması, derin bir uzmanlık ve özen gerektiren karmaşık bir süreçtir. Hiperspektral görüntüler, büyüklük ve boyut açısından geniş bir alanı kaplar ve her bir piksel, yüzlerce hatta binlerce spektral bant içerebilir. Dolayısıyla, bu bollukta bilgi, sınıflandırma ve analiz için devasa bir veri hacmi oluşturur. Hiperspektral görüntülerin doğru bir şekilde sınıflandırılması, genellikle spektral ve mekansal bilgilerin uzmanlıkla birleştirilmesini gerektirir. Spektral bilgi, her bir pikselin elektromanyetik spektrum boyunca ne kadar ışığı yansıttığını ve emdiğini ifade eder. Diğer yandan, mekansal bilgi, piksellerin bir görüntü içindeki yerleşimini ve birbiriyle olan ilişkilerini açığa çıkarır. Bu iki bilgi türünün bir araya getirilmesi, hiperspektral görüntülerin tam ve doğru bir şekilde sınıflandırılmasında kritik bir rol oynar. Bunun için, hem spektral hem de mekansal bilgiyi kapsayan ve bu bilgileri etkili bir şekilde entegre eden bir yöntemin kullanılması gerekmektedir. Hiperspektral Görüntülerin tam ve doğru bir şekilde sınıflandırılması genellikle, güçlü

modelleme ve öğrenme yetenekleri sayesinde bu süreci yönetebilen makine öğrenmesi veya derin öğrenme teknikleri ile gerçekleştirilir. Hiperspektral görüntülerin sınıflandırılması, veriye gömülü zengin bilgilerin ortaya çıkarılmasına yardımcı olur ve bu sayede daha bilinçli ve doğru kararlar alabilmemize olanak sağlar.

Bu tez çalışması, hiperspektral görüntü sınıflandırması için evrişimli sinir ağları kullanan bir yaklaşım önermektedir. Bu amaçla, ilk olarak, hiperspektral görüntülerin karakteristikleri ve bu görüntülerin sınıflandırılmasıyla ilgili mevcut teknikler ve literatürde bu alanda yapılmış çalışmalar incelenmiştir. Bu kapsamlı literatür taraması, hiperspektral görüntü sınıflandırma sürecinde karşılaşılan zorlukları ve potansiyel araştırma fırsatlarını ortaya koymaktadır. İkinci aşamada, hem spektral hem de mekansal özelliklerin derinlemesine analizine odaklanan yenilikçi bir model önerilmiştir. Önerilen bu model, evrişimli sinir ağları (Convolutional Neural Networks - CNN) ve tekrarlayan sinir ağları (Recurrent Neural Networks - RNN) teknolojilerinin birleşimini kullanmaktadır. Bu iki güçlü ağ yapısının hibritleştirilmesi, hiperspektral görüntülerin karmaşıklığını yönetme ve daha etkili bir sınıflandırma gerçekleştirme yeteneği sunmuştur. Çalışmanın devamında ise, hiperspektral görüntü sınıflandırma alanında kullanılan çeşitli veri kümeleri araştırılmıştır. Tez çalışması kapsamında oluşturulan modelin ilgili veri kümeleri üzerinde uygulanmasıyla elde edilen sonuçlar, literatürde son yıllarda gerçekleştirilen çalışmalarda önerilen başarılı modeller ile elde edilen sonuçlarla karşılaştırılmıştır. Son olarak, önerilen modelin genel başarısı ve diğer modellere kıyasla artı ve eksi yönleri irdelenmiştir.

Haziran 2023 , 79 sayfa.

Anahtar kelimeler: Hiperspektral Görüntü, Hiperspektral Görüntü Sınıflandırması, Evrişimli Sinir Ağları, Tekrarlayan Sinir Ağları, Dikkat Mekanizması, Uzaktan Algılama

ABSTRACT

M.Sc. THESIS

CLASSIFICATION OF HYPERSPECTRAL IMAGES USING CONVOLUTIONAL NEURAL NETWORK

Ali GÜNDÜZ

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Computer Engineering

Computer Engineering

Supervisor : Prof. Dr. Zeynep ORMAN

Hyperspectral imaging provides a detailed and continuous spectral image across a wide spectral range located between visible and short-wave infrared spectrums. Hyperspectral images offer an in-depth view of objects or terrain, extending beyond thousands of spectral bands. Hence, it contains intricate details that are invisible to the naked eye, the analysis of these images is extremely important in many applications in various industries such as mineral exploration, agriculture, environmental monitoring and military intelligence. For these hyperspectral images to be utilized effectively, it is necessary to meticulously classify such images. Classification is the process of assigning each pixel of an image to predetermined classes or categories. This classification process is critical in determining, particularly in agricultural applications, when a particular area needs irrigation, which regions are damaged, or which crops are showing the best growth. Classification of hyperspectral images is indeed a complex process that requires deep expertise and care. Hyperspectral images cover a vast area in terms of size and dimension, and each pixel can contain hundreds, even thousands of spectral bands. Consequently, this abundance of information creates a colossal data volume for classification and analysis. Correct classification of hyperspectral images typically requires the expert combination of spectral and

spatial information. Spectral information refers to how much light each pixel reflects and absorbs along the electromagnetic spectrum. On the other hand, spatial information reveals the location and interrelationships of pixels within an image.

The combination of these two types of information plays a critical role in fully and accurately classifying hyperspectral images. For this, a method that encompasses both spectral and spatial information and integrates this information effectively needs to be used. The complete and accurate classification of Hyperspectral Images is often achieved through deep learning or machine learning techniques that can manage this process thanks to their powerful modeling and learning capabilities. The classification of hyperspectral images helps to reveal the rich information embedded in the data and thereby enables us to make more informed and accurate decisions.

This thesis proposes an approach using convolutional neural networks for hyperspectral image classification. Initially, the characteristics of hyperspectral images and the existing techniques and literature related to their classification have been examined. This comprehensive literature review reveals the difficulties encountered in the process of hyperspectral image classification and potential research opportunities. In the second stage, an innovative model focusing on the in-depth analysis of both spectral and spatial features is proposed. This model utilizes the combination of Convolutional Neural Networks (CNN) and Recurrent Neural Networks (RNN) technologies. The hybridization of these two powerful network structures offers the ability to manage the complexity of hyperspectral images and perform more effective classification. Following this, data sets used in the field of hyperspectral image classification have been researched. The results obtained using the created model have been compared with successful models implemented in recent years. Finally, the overall success of the created model and its pros and cons compared to other models have been examined.

June 2023, 79 pages.

Keywords: Hyperspectral Image, HSI, Hyperspectral Image Classification, Convolutional Neural Networks, Recurrent Neural Networks, Attention Mechanism, Remote Sensing

1. GİRİŞ

Hiperspektral görüntüleme, modern çağın en ileri ve etkileyici uzaktan algılama teknolojilerinden bir tanesidir. Bu teknoloji, geniş bir elektromanyetik spektrum aralığından yüzlerce hatta binlerce spektral bandı içeren piksellerle görüntüler üretebilme kapasitesine sahiptir. Bu sayede, hiperspektral görüntüler, nesnelerin ve malzemelerin özelliklerini daha derinlemesine analiz edebilme potansiyeli barındırmaktadır [1].

Hiperspektral görüntüler genellikle uzaktan algılama (Remote Sensing) uygulamalarında kullanılır ve bu görüntülerin alınması çeşitli sensörler ve cihazlar kullanılarak gerçekleştirilir. Bu sensörler genellikle uydular, insansız hava araçları veya hava taşıtları gibi platformlarda bulunur. Gelişmiş optik ve algılama teknolojileri kullanılarak sensörler, yeryüzünün geniş bir elektromanyetik spektrumda detaylı görüntülerini çeker. Bu görüntüler, yüzlerce hatta binlerce spektral bant içerebilir, böylece çeşitli malzemelerin ve nesnelerin spektral özelliklerini ayrıntılı bir şekilde karakterize eder. Bununla birlikte, hiperspektral görüntü veri kümelerinin oluşturulması ve kullanılması, çeşitli zorlukları ve sınırlılıkları beraberinde getirir. İlk olarak, bu tür veri kümelerinin oluşturulması genellikle pahalı ve zaman alıcıdır. Hiperspektral sensörlerin maliyeti, onları hem hükümet hem de özel sektör için büyük bir yatırım haline getirir ve bu verilerin verimli bir şekilde işlenmesinin önemini arttırır.

Hiperspektral görüntüleme, geniş bir spektral bant yelpazesinde detaylı bilgi sağladığı için çok çeşitli kullanım alanlarına sahiptir. Hiperspektral görüntülerin bazı kullanım alanları şu şekildedir:

Tarım: Hiperspektral görüntüleme, bitki sağlığı ve verim tahminleri gibi tarımsal uygulamalarda oldukça yoğun bir şekilde kullanılır. Bitkilerin spektral özellikleri, bitki türlerini ayırt etmek, hastalıklarını belirlemek ve besin eksikliklerini tespit etmek için kullanılır.

Çevresel İzleme: Hiperspektral görüntüler, su kalitesi, hava kirliliği, bitki örtüsü ve habitat değişiklikleri gibi çevresel faktörlerin izlenmesi için kullanılır.

Jeoloji ve Madencilik: Hiperspektral görüntüler, maden yataklarının keşfedilmesi ve jeolojik özelliklerin haritalandırılması için kullanılır. Her mineralin kendine özgü bir spektral özelliği vardır, bu nedenle bu görüntüler mineral tespiti ve sınıflandırılması için son derece önemlidir.

Askeri ve Savunma: Hiperspektral görüntüleme, kamuflajı tespit etmek, hedefleri belirlemek, izlemek ve tehditleri saptamak için askeri uygulamalarda kullanılır.

Sınıflandırma, genellikle makine öğrenmesi ve veri analizi bağlamında kullanılan bir terimdir ve bilgiyi önceden belirlenmiş bir dizi kategoriye veya sınıfa ayırma sürecini ifade eder. Hiperspektral görüntülerde sınıflandırma, hiperspektral görüntülerin spektral ve mekansal özellikleri kullanılarak, her bir pikselin hangi sınıfa ait olduğunu belirleme sürecidir. Jeoloji ve madencilik alanında, her mineralin kendine özgü spektral özelliği kullanılarak, maden yataklarının yerini tespit etmekte kullanılabilir. Çevresel izleme alanında, belirli kirleticilerin spektral imzaları tespit edilerek, havada ne kadar yoğun olarak bulunduklarını ölçmek için kullanılabilir. Bu örnekler gibi, hiperspektral görüntü sınıflandırması birçok gerçek dünya probleminde kullanılabilir.

Hiperspektral görüntü sınıflandırması, bu teknolojinin evriminin başlangıcından beri merkezi bir araştırma odak noktası olmuştur. 2000'li yılların başlarına kadar, hiperspektral görüntülerin sınıflandırılması ve analizi önemli bir zorluk olarak kalmıştır. Bu zorlukların üstesinden gelmek için, araştırmacılar, hiperspektral görüntüleri analiz etmek ve anlamlı bilgiler elde etmek için çeşitli teknikler ve yaklaşımlar geliştirmiştir.

Başlangıçta, pikselleri sınıflandırmak için istatistiksel ve spektral özellik tabanlı yaklaşımlar kullanılmıştır. Spektral özellik tabanlı yaklaşımlar, hiperspektral görüntülerin analizinde kullanılan bir metodolojidir. Bu yaklaşım, her bir pikselin spektral imzasını, yani farklı dalga boylarında ışığı nasıl emdiği veya yansıttığı üzerine dayanır. Her tür nesne veya materyal, kendi benzersiz spektral imzasına sahip olduğundan, bu özelliklerin analizi, görüntülerdeki pikselleri birbirinden ayırmak için kullanılabilir. Bunlar içerisinde, en çok bilinen ve uygulanan yöntemler maksimum olabilirlik (Maximum Likelihood) ve minimum uzaklık (Minimum Distance) sınıflandırıcılarıdır [2]. Bu metodolojiler genellikle, önceden belirlenmiş bir eğitim kümesi üzerinde çalışırak her bir sınıfın dağılımını modeller.

Maksimum Olabilirlik yöntemi, bir pikselin belirli bir sınıfa ait olma olasılığını hesaplar. Bu yöntem, her sınıfın istatistiksel dağılımını modelleyerek, her bir pikselin bu dağılımlarla ne kadar uyumlu olduğunu değerlendirir. Maksimum Olabilirlik sınıflandırıcısı, bir pikselin bir sınıfa ait olma olasılığını maksimize eden sınıfı seçer.

Minimum Uzaklık yöntemi ise, bir pikselin belirli bir sınıfa ne kadar 'yakın' olduğunu belirlemek için kullanılır. Bu yöntem, genellikle her sınıfın ortalama spektral vektörünü hesaplar ve her pikselin bu ortalama spektral vektörlere olan uzaklığını belirler. Minimum Uzaklık sınıflandırıcısı, bir pikselin bir sınıfa ait olma olasılığını maksimize eden, yani pikselin ortalama spektral vektörüne en yakın olan sınıfı seçer.

Bu klasik yaklaşımlar, hiperspektral görüntü analizinde önemli bir adımı temsil ederek yüksek boyutlu verinin karmaşıklığını işlemek için önemli bir temel oluşturmuştur. Bu alanda gerçekleştirilen ilk sınıflandırma çalışmaları, süregelen araştırma ve geliştirmenin temelini atmıştır.

Ancak, istatistiksel yaklaşımlar, hiperspektral veri kümelerinin yüksek boyutlu karmaşıklığı ve iç içe geçmiş sınıfların varlığı gibi zorluklarla baş etmekte yetersiz kalmıştır. 2000'li yılların başlarından itibaren, makine öğrenmesi algoritmaları, özellikle destek vektör makineleri (Support Vector Machines - SVM) ve yapay sinir ağları (Artificial Neural Networks - ANN) hiperspektral görüntü sınıflandırmasında yaygın olarak kullanılmaya başlanmıştır. Bu yöntemler, daha karmaşık ve yüksek boyutlu veri kümelerinin sınıflandırılması konusunda önemli bir ilerleme sağlamıştır. Bu algoritmalar, model karmaşıklığı ve genelleştirme kapasitesi konusunda, veri kümelerinin sınıflandırılmasında daha etkili bir yaklaşım sunar.

Derin öğrenme, bilgisayarların karmaşık problemleri çözmesine yardımcı olan bir tür yapay zeka türüdür. Derin öğrenme, özellikle büyük miktarda veriyle çalışıldığında etkilidir ve bir insan beyninin sinir ağlarına benzer bir yapı kullanır. Bu sinir ağları, veriyi analiz eder ve belirli görevleri gerçekleştirmek için neyin önemli olduğunu öğrenir. Derin öğrenme, bilgisayarların resimleri, sesleri ve metinleri anlamasından, tıbbi görüntülerden hastalıkları tanımasına kadar birçok alanda kullanılmaktadır.

Son yıllarda, derin öğrenme tekniklerinin hiperspektral görüntü sınıflandırması alanında kullanılması büyük bir ilgi görmüştür. Bu teknikler, çok katmanlı yapay sinir ağları kullanarak karmaşık özellik hiyerarşilerini öğrenme yeteneği ile ön plana çıkmaktadır. Bu, hiperspektral

veri kümelerinin karmaşıklığını ve yüksek boyutluluğunu daha iyi işlemek için bir potansiyel sunmaktadır. Bununla birlikte, derin öğrenme modellerinin eğitilmesi, genellikle büyük miktarda veri ve hesaplama kaynağı gerektirir, bu da mevcut zorluklardan biridir. Sonuç olarak, hiperspektral görüntü sınıflandırması, özellikle son 10 yılda önemli teknolojik gelişmelere sahne olmuştur ve bu gelişmeler, karmaşık ve yüksek boyutlu hiperspektral veri kümelerini daha iyi işleyebilmemize olanak vermiştir. Ancak, bu alan hala aktif bir araştırma konusudur.

1.1. Araştırmanın Konusu

Hiperspektral görüntü sınıflandırması, yer bilimleri, çevresel izleme, askeri istihbarat ve daha birçok alanda ele alınan problemleri çözmek açısından önemli bir rol oynamaktadır. Diğer yandan, hiperspektral görüntü sınıflandırması, çok boyutlu veri analizi gerektirir ve bu nedenle bir dizi zorluk ve sorunu da beraberinde getirir:

- Hiperspektral görüntü verisi yüksek boyutlulukta bir veri kümesidir. Yüksek boyutluluk, genellikle büyük miktarda verinin işlenmesi ve saklanması gerektiği anlamına gelir.

- Hiperspektral görüntülerin yüksek korelasyonu, verilerdeki çok boyutluluk laneti (curse of dimensionality) problemini oluşturur. Bu terim 1959 yılında Richard Bellman tarafından ortaya atılmıştır [3]. Genellikle veri bilimi ve makine öğrenmesi alanında, verinin boyutunun (öznitelik sayısının) artmasıyla ortaya çıkan bir dizi zorlukları tanımlar. Çok boyutluluk laneti, verinin boyutu arttıkça, mevcut veri noktalarının mekânsal dağılımının giderek daha seyrek hale gelmesi sorununu ifade eder. Yani, verinin boyutu arttıkça, tüm olası kombinasyonları kapsayacak şekilde verinin kapsamlı bir örneklemini almak için gereken veri miktarı geometrik olarak artar. Ayrıca, bu durum, modelin aşırı öğrenme (overfitting) yapma riskini de artırır. Çünkü eğitim kümesinde yer almayan birçok potansiyel veri kombinasyonu vardır ve model, bu gözlemlenmemiş durumlar için iyi genelleme yapamayabilir. Bu durum, hiperspektral görüntü sınıflandırması gibi yüksek boyutlu veri kümelerini içeren konularda özellikle sorun oluşturur.

- Görüntülerde bulunan sınıfların karmaşıklığı ve genellikle eşit olmayan örnek dağılımı, özellikle sınıfların dengesiz olduğu durumlarda sınıflandırma işlemini zorlaştırır.

Hiperspektral görüntü sınıflandırmasında ortaya çıkabilecek tüm bu zorluklara rağmen, günümüzde etkili bir şekilde sınıflandırma yapabilen çok çeşitli gelişmiş yöntemlerin öne sürüldüğü görülmektedir. Derin öğrenme yöntemleri, özellikle evrişimli sinir ağları ve tekrarlayan sinir ağları uygulamaları, bu alanda büyük ilerlemeler kaydedilmesine imkan vermektedir. CNN kullanımı, bu ağların çok boyutlu verilerin analizinde etkili olmaları ve otomatik özellik çıkarımı sağlamaları nedeniyle bu alanda genellikle tercih edilmelerine sebep olmaktadır. Bu özellik çıkarımı, aşırı öğrenme problemini hafifletmekte ve hiperspektral görüntülerdeki farklı sınıfları daha iyi ayırt etmeyi sağlamaktadır.

Öte yandan, RNN'ler, veri içindeki uzamsal ve spektral korelasyonları modellemek için kullanılır. Özellikle, uzun kısa vadeli bellek (Long-Short Term Memory - LSTM) ve kapılı tekrarlayan birimler (Gated Recurrent Units - GRU) gibi gelişmiş RNN yapıları, verideki uzun vadeli bağımlılıkları yakalamak için tercih edilir.

Bu yaklaşımların yanı sıra, çeşitli boyut indirgeme teknikleri ve çeşitli örnek dengesizliğini düzeltme yöntemleri de uygulanmıştır. Bu teknikler, verinin daha verimli bir şekilde işlenmesini ve daha doğru sınıflandırma sonuçları elde edilmesini sağlar. Ancak, bu alanda hala bazı zorluklar ve sınırlamalar bulunmaktadır.

Hiperspektral görüntü sınıflandırılmasında kullanılan veri kümeleri zorlu koşullar altında elde edilen veri kümeleridir. Bundan dolayı, diğer görüntü sınıflandırma alanlarının aksine, deneysel amaçlı çok sayıda veri kümesi bulunamamaktadır. Indian Pines, Pavia Üniversitesi, Kenney Uzay Merkezi ve Salinas bu alanda genelde araştırmacıların kullandığı bazı veri kümeleridir. Ancak, araştırma amacıyla topluma açık kısıtlı veri kümeleri üzerinde, bu konu ile alakalı geliştirmeler yapılmaya devam edilmektedir.

Bu zorluklar ve sınırlamalar göz önünde bulundurularak bu tez çalışmasında, hiperspektral görüntü sınıflandırma alanında son yıllarda yapılmış çalışmalar, bu çalışmalarda ele alınan problemler ve önerilen çözümler irdelenmiştir. Literatürde son yıllarda yapılan çalışmalarda kullanılan yöntemler, önerilen modeller ve elde edilen sonuçlar araştırılmıştır. Bu çalışmalardan yola çıkılarak, tez çalışmasında hiperspektral görüntülerin yüksek boyutluluğu ve etiketli veri kümelerinin azlığı dikkate alınarak, hem mekânsal hem de spektral bilgileri etkin ve verimli bir şekilde işleyebilen RNN ve CNN'in hibrit olarak kullanıldığı bir hiperspektral görüntü sınıflandırma modeli önerilmiştir. Sonuç olarak, çalışmada kullanılan veri kümeleri,

önerilen modelin ayrıntıları, alınan sonuçların karşılaştırılması ve değerlendirilmesi; aynı zamanda gelecekte bu alanda meydana gelebilecek gelişmelerden bahsedilmiştir.

2. KAVRAMSAL ÇERÇEVE

Bu bölümde, boyut azaltma teknikleri, derin öğrenme kavramı ve hiperspektral görüntü sınıflandırma alanında son yıllarda kullanılan derin öğrenme yöntemleri incelenmiştir. Ayrıca, son yıllarda bu konuda yapılan literatüre katkıda bulunmuş çalışmalara değinilmiştir.

2.1. Boyut Azaltma Teknikleri

Boyut azaltma teknikleri, yüksek boyutlu veri kümelerindeki karmaşıklığı azaltarak veri analizi, görselleştirme ve makine öğrenmesi gibi uygulamalarda kullanılır. Hiperspektral görüntülerdeki yüksek boyutluluk, hiperspektral görüntü sınıflandırma problemlerini zorlaştırır ve boyut azaltma teknikleri bu bağlamda büyük öneme sahiptir. Hiperspektral görüntü sınıflandırma problemlerinde boyut azaltma, veri kümesinin yönetimini, özellik çıkarma sürecini, gürültü azaltmayı ve görselleştirme kolaylığını sağlamak için önemli bir adımdır. Bu yöntemler, sınıflandırma performansını artırırken hesaplama yükünü azaltır. Hiperspektral görüntü sınıflandırmada kullanılan bazı boyut azaltma teknikleri aşağıda sıralanmıştır:

Temel Bileşen Analizi (Principal Component Analysis - PCA): Hiperspektral görüntülerde boyut azaltma için yaygın olarak kullanılan bir tekniktir. PCA, veri kümesindeki en fazla varyansı açıklayan temel bileşenleri belirleyerek veriyi daha düşük boyutlu bir kümeye dönüştürür. Elde edilen temel bileşenler, sınıfları daha iyi temsil eden öznitelikler bulundurur. PCA çok boyutlu bir veri kümesini daha az boyutlu bir veri kümesine indirgeme prosedürüdür ve bir dizi matematiksel adım içerir:

- Standartlılaştırma: Verinin her bir özelliğinin ortalaması alınarak veri kümesi standartlaştırılır. Bu işlem, veri kümesinin ortasını orijine taşır. Bu işlemin formülü 2.1'deki denklemde verilmiştir.

$$X' = \frac{(X - \mu)}{\sigma} \tag{2.1}$$

2.1'deki formülde X, bir özellik vektörüdür; μ, özellik vektörünün ortalaması; ve σ, özellik vektörünün standart sapmasıdır.

- Daha sonra, özellikler arasındaki kovaryans matrisi hesaplanır. Kovaryans matrisi, farklı özelliklerin birbiriyle nasıl varyans paylaştığını gösterir. Kovaryans matrisinin formülü 2.2'de verilmiştir.

$$\Sigma = \frac{1}{n} * X'^{T} * X' \tag{2.2}$$

2.2'deki formülde, n örnek sayısını X'ise standartlaştırılmış özellik matrisini ifade eder. Σise kovaryans matrisini ifade etmektedir.

- Kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanır. Özvektörler, ana bileşenlere (yeni özelliklere) karşılık gelmektedir ve özdeğerler, bu ana bileşenlerin veri kümesindeki varyansın ne kadarını açıkladığını göstermektedir.
- Özdeğerlere göre özvektörler (ana bileşenler) sıralanır. En büyük özdeğerli özvektör, en fazla varyansı açıklayan ve bu nedenle ilk ana bileşen olan özvektördür.

Bağımsız Bileşen Analizi (Independent Component Analysis - ICA): Hiperspektral görüntülerde bağımsız bileşenleri belirlemek için kullanılan bir boyut azaltma tekniğidir. ICA, veri kümesini istatistiksel olarak bağımsız bileşenlere ayırır. Bu bileşenler, farklı nesne türlerini veya materyalleri temsil eder ve sınıflandırma için kullanılır.

Negatif Olmayan Matris Faktorizasyonu (Non-negative Matrix Factorization - NMF): NMF, hiperspektral görüntü sınıflandırmada yaygın olarak kullanılan bir boyut azaltma tekniğidir. Bu yöntem, hiperspektral veri kümesini pozitif bileşenlerin bir kombinasyonu olarak ifade eder.

Elde edilen bileşenler, farklı nesne türlerini veya materyalleri temsil eder ve sınıflandırmaya yardımcı olur.

Yerel Doğrusal Gömme (Locally Linear Embedding - LLE): LLE, hiperspektral veri setlerinde yerel bağlantıları koruyarak boyut azaltma yapmak için kullanılan bir yöntemdir. LLE, veri kümesini yerel ve lineer olarak en iyi temsil eden bir düşük boyutlu uzay oluşturur. Bu yöntem, veri kümesindeki yapıyı koruyarak sınıflandırma performansını arttırır.

Bu teknikler, hiperspektral görüntü sınıflandırmada boyut azaltma için kullanılan yaygın yaklaşımlardan sadece birkaçıdır. Veri kümesinin özelliklerine ve analiz amacına bağlı olarak farklı tekniklerin tercih edilmesi gerekebilir. Ayrıca, bu tekniklerin bazı kombinasyonları veya özelleştirmeleri de kullanılabilir.

2.2. Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt dalıdır ve yapay sinir ağlarının karmaşık yapılarına dayanır. Genellikle çok sayıda katmanı (derinlik) olan sinir ağları kullanılır, bu nedenle *'derin öğrenme'* olarak adlandırılır.

Bir derin öğrenme modeli, genellikle bir giriş katmanı, bir çıktı katmanı ve aralarında bir dizi gizli katmandan oluşan bir yapay sinir ağıdır. Gizli katmanlardaki her bir düğüm (nöron) ağırlıklar ve aktivasyon eşiği gibi öğrenilebilir parametreler kullanarak gelen veriyi işler. Burada *'aktivasyon eşiği'*, bir nöronun aktif hale gelmesi için gereken toplam giriş sinyalinin minimum değerini ifade eder. Model eğitildikçe, bu parametreler giriş verileri ve hedef çıktılar arasındaki ilişkiyi daha iyi öğrenir.

Derin öğrenme, çok sayıda alanda önemli gelişmelere yol açmıştır. Bunlar arasında görüntü ve ses tanıma, doğal dil işleme, kişisel dijital asistanlar ve öneri sistemleri gibi uygulamalar bulunmaktadır. Bu teknolojiler, sağlık hizmetlerinden finansa, otomotivden eğlenceye kadar çok çeşitli sektörlerde kullanılmaktadır.

Öğrenme süreci genellikle aşağıdaki adımları içerir:

İleri yayılım: Model, giriş verilerini alır ve her bir katmanda işlemler gerçekleştirerek bir tahminde bulunur.

Kayıp hesaplama: Modelin tahmininin ne kadar doğru olduğunu ölçen bir kayıp fonksiyonu hesaplanır.

Geri yayılım: Kayıp, modelin her bir parametresinin ne kadar *'hatalı'* olduğunu belirlemek için modelin katmanları arasında geri yayılır.

Parametre güncelleme: Modelin parametreleri, kayıp fonksiyonunu azaltacak şekilde güncellenir.

Kayıp hesaplama bölümünde bahsedilen kayıp fonksiyonu (hata fonksiyonu), bir makine öğrenmesi modelinin performansını ölçmek için kullanılan bir matematiksel fonksiyondur. Derin öğrenme modellerinde, bir modelin tahminlerinin ne kadar doğru olduğunu değerlendirmek için bir kayıp fonksiyonu kullanılır. Genellikle, modelin tahmin ettiği değerler ile gerçek değerler arasındaki fark, bir tür kayıp fonksiyonu olan ortalama kare hatayı (Mean Squared Error - MSE) hesaplamak için kullanılır.

MSE gerçek değerler ile tahmin edilen değerler arasındaki farkların karelerinin ortalamasıdır. İki veri kümesi arasındaki hataları ölçmek için sıkça kullanılan bir metriktir. MSE'nin formülü 2.3'te gösterilmiştir:

$$\text{MSE}=\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \qquad (2.3)$$

Bu formülde:

- n, toplam veri noktalarının sayısıdır,
- y_i, i. gerçek değeri temsil eder,
- $\hat{y}_i$, i. tahmin edilen değeri temsil eder

Bu formülde, her bir veri noktasının gerçek değeri ile tahmin edilen değeri arasındaki farkın karesi alınır. Bu kare hataların toplamı, toplam veri noktalarının sayısına bölünerek ortalama bir değer elde edilir. Böylece, MSE, tahminlerin ne kadar iyi olduğunu ölçer. Değeri ne kadar düşükse, tahminler o kadar iyi demektir.

Kayıp fonksiyonunun değeri, modelin performansını değerlendirmek ve modelin ağırlıklarını ve öğrenilebilir parametrelerini güncellemek için bir "geriye yayılım" (backpropagation) sürecinde kullanılır. Bu süreçte, model, kayıp fonksiyonunu minimize etmek (tahminlerin doğruluğunu maksimize etmek) için öğrenilebilir parametrelerini ayarlar. Öğrenme sürecindeki adımlar, modelin performansı tatmin edici olana kadar veya belirlenen bir döngü sayısına ulaşıncaya kadar tekrar edilir.

Derin öğrenme birçok alanda kullanılır. Görüntü işleme ve tanıma, doğal dil işleme, ses tanıma, otonom araçlar ve tıbbi görüntüleme bunlardan birkaçıdır. Özellikle görüntü işleme alanında derin öğrenme, hem geniş veri kümeleriyle etkin bir şekilde çalışabilme hem de karmaşık özellikleri çözümleme yeteneği sebebiyle oldukça önemlidir. Derin öğrenme algoritmaları, resimdeki çizgiler ve renkler gibi basit özelliklerden, şekiller ve nesneler gibi daha karmaşık özelliklere kadar hiyerarşik özellikleri öğrenebilir. Örneğin bir görüntünün hangi sınıfa ait olduğunu belirleme veya bir görüntüde belirli bir nesneyi tanıma gibi konularda oldukça başarılıdır. Ayrıca, derin öğrenme modelleri genelleştirme yeteneğine sahip olduğundan dolayı, eğitim sürecinde bulunmayan yeni görüntülerde bile doğru tahminler yapabilir. Bu özellikler, derin öğrenmenin görüntü işleme alanında geniş çapta kullanılmasını sağlamıştır.

Hiperspektral görüntülerin karmaşıklığı ve çok boyutluluğu, onların analizi için gelişmiş teknikler gerektirir. Derin öğrenme, hiperspektral görüntülerin karmaşık yapılarını ve özelliklerini modelleme yeteneğine sahip olup, bu görüntülerin daha etkin ve doğru bir şekilde sınıflandırılmasını sağlar. Derin öğrenmenin hiperspektral görüntü sınıflandırması alanında kullanılmasının temel sebepleri şu şekildedir.

Karmaşık İlişkilerin Modellemesi: Derin öğrenme, spektral bantlar arasındaki karmaşık ilişkileri modelleyebilir, bu da daha iyi sınıflandırma performansı sağlar.

Genelleştirme Yeteneği: Derin öğrenme algoritmaları, eğitim verisinde bulunmayan yeni hiperspektral görüntüler üzerinde de iyi performans gösterir.

Hiperspektral görüntü sınıflandırmada sıklıkla kullanılan derin öğrenme algoritmaları arasında evrişimli sinir ağları, otomatik kodlayıcılar (Autoencoders) ve tekrarlayan sinir ağları bulunur. Bu algoritmalar, hiperspektral görüntülerin karmaşık yapısını ve yüksek boyutluluğunu yönetmek için geliştirilmiş özel teknikler ve yaklaşımlar kullanır.

Bu yaklaşımlar arasında özellikle CNN ve RNN'nin hiperspektral görüntü sınıflandırma konusunda elde ettiği başarı son yıllarda bu konuda ortaya atılan modellerde bu yaklaşımların sıklıkla kullanılmasından anlaşılabilir.

2.2.1. Evrişimli Sinir Ağları

Evrişimli sinir ağı, genellikle görüntü sınıflandırma, görüntü işleme ve doğal dil işleme gibi alanlarda kullanılan bir tür derin öğrenme modelidir. CNN'ler, çok boyutlu verileri giriş verisi olarak işleyebilecek şekilde tasarlanmıştır. CNN'lerin bu özelliği hiperspektral görüntülerin sınıflandırılmasında CNN yapısının kullanılmasının avantajlarından bir tanesidir.

CNN'ler, üç temel katmandan oluşur:

Evrişim Katmanları: Bu katmanlar, evrişim işlemi aracılığıyla giriş verisine uygulanan bir dizi filtreyi ya da çekirdeği içerir. Bu katman, giriş verisine -genellikle bir görüntüye- evrişim işlemi adı verilen bir matematiksel işlemi uygular. Bu işlem, bir filtre veya çekirdek adı verilen küçük bir matrisi kullanır. Filtre, genellikle yükseklik ve genişlik açısından oldukça küçük, ancak giriş verisiyle aynı derinliğe sahip bir matristir. Filtre, giriş verisi üzerinde kaydırılır, yani her pozisyonda, filtre ve giriş verisinin karşılık gelen elemanları arasındaki çarpma ve toplama işlemleri gerçekleştirilir. Bu işlem, giriş verisinin özellik haritası adı verilen bir çıktı oluşturur. Bu evrişim işlemi, belirli özellikleri veya desenleri tanıma yeteneği olan bir dizi filtreyi öğrenmek için kullanılır. Örneğin, bir filtre dikey kenarları, başka bir filtre yatay kenarları ve başka bir filtre belirli bir renk geçişini tanıyabilir. İlk evrişim katmanları genellikle görüntünün düşük seviyeli özelliklerini (örneğin, kenarlar ve renk blokları) yakalar, daha derin katmanlar ise bu düşük seviyeli özelliklerin kombinasyonlarından oluşan daha yüksek seviyeli ve daha soyut özellikleri (örneğin, bir nesnenin belirli bir parçası) öğrenir. Bu özellik öğrenme ve hiyerarşik öğrenme yeteneği, CNN'lerin görsel özellikleri etkili bir şekilde modellemesini ve görsel görevlerde yüksek performans göstermesini sağlar.

Havuzlama Katmanları (Pooling Layers): Bu katmanlar, her bir özellik haritasının boyutunu (yükseklik ve genişlik) küçültür, ancak derinliği aynı kalır. Havuzlama katmanı, genellikle küçük bir pencere boyutu üzerinde işlem yapar ve bu pencere giriş verisi üzerinde kaydırılır. Havuzlama işlemi sırasında, pencerenin kapsadığı değerler arasından belirli bir istatistik (örneğin, maksimum veya ortalama) seçilir ve çıktı olarak kullanılır.

Örneğin, maksimum havuzlama (max pooling) işlemi sırasında, pencerenin kapsadığı değerler arasından en yüksek değer seçilir ve çıktı olarak kullanılır. Bu, modelin bazı küçük yerel farklılıkları (örneğin, bir özelliğin konumundaki küçük değişiklikler) göz ardı etmesini ve böylece modelin dönüşüm dayanıklılığını artırmasını sağlar. Bu işlem aynı zamanda hesaplama yükünü azaltır ve aşırı öğrenme riskini düşürür, çünkü modelin öğrenmesi gereken parametre sayısını azaltır.

Sonuç olarak, havuzlama katmanları, modelin karmaşıklığını kontrol altına alırken, önemli özelliklerin korunmasına yardımcı olur ve modelin ölçek ve dönüşüm değişikliklerine karşı daha dayanıklı olmasını sağlar.

Tam Bağlantılı Katmanlar (Fully Connected Layers): Bu katmanlar, CNN'nin sonunda bulunur ve tüm öğrenilmiş özellikleri bir araya getirerek nihai çıktıyı oluşturur. Adından da anlaşılacağı gibi, tam bağlantılı bir katmanda her nöron, önceki katmandaki tüm nöronlara bağlıdır. Bu tam bağlantılılık, nöronların birbirleriyle kompleks ilişkiler oluşturmasına olanak sağlar.

Örneğin, bir görüntü sınıflandırma işleminde, tam bağlantılı katmanlar, önceki katmanlarda öğrenilen özellikleri kullanarak bir görüntünün belirli bir sınıfa ait olma olasılığını hesaplar. Bu, genellikle her bir sınıf için bir nöronun olduğu bir softmax aktivasyon fonksiyonu ile gerçekleştirilir. Her nöron, giriş verisinin belirli bir sınıfa ait olma olasılığını temsil eder.

Softmax aktivasyon fonksiyonu, bir sinir ağının çıktı katmanında sıklıkla kullanılır, özellikle sınıflandırma problemlerinde. Bu fonksiyon, her bir sınıf için tahmin edilen olasılıkların toplamının 1 olmasını sağlar, bu yüzden elde edilen değerler genellikle bir olasılık dağılımı olarak yorumlanır. Softmax aktivasyon fonksiyonunun formülü denklem 2.4'te gösterilmiştir:

$$\sigma(Z)_i = \frac{e^{zi}}{\sum_{j=1}^{K} e^{zj}} \tag{2.4}$$

2.4 denkleminde kullanılan değişkenler aşağıda tanımlanmıştır:

Z = Softmax fonksiyonunun girdi vektörü

Z_i = Girdi vektörünün girdi değerleri

e^{zi} = Girdi vektörünün her öğesine uygulanan üssel fonksiyon

K = Çoklu sınıflayıcılardaki sınıf sayısı

Tam bağlantılı katmanlar, modelin öğrendiği özellikleri belirli bir çıktıya bağlar. Yani, evrişim ve havuzlama katmanlarında öğrenilen özelliklerin tümü, tam bağlantılı katmanlar aracılığıyla nihai tahmine dahil edilir. Bu, modelin öğrendiği özelliklerden yola çıkarak belirli bir işlevi (örneğin, bir görüntünün hangi sınıfa ait olduğunu tahmin etme) gerçekleştirmesini sağlar.

Şekil 2.1'de bir evrişimli sinir ağı örneği verilmiştir. Şekilde, *Cx, Sx, Fx*, sırasıyla evrişim katmanı, havuzlama katmanı ve tam bağlı katmana karşılık gelir; burada *x,* katman indeksini gösterir. Giriş, 28×28 boyutunda görüntülerdir. *C1*, 5×5 boyutunda 6 adet evrişim çekirdeği olan ilk evrişim katmanıdır. *S2*, 2×2 boyutunda bir havuzlama penceresiyle, 6 evrişim çekirdekli ve 14×14 boyutlarında çıktılar veren bir havuzlama katmanıdır. *C3,* 5×5 boyutunda 16 adet evrişim çekirdeği olan bir evrişim katmanıdır. Bu nedenle, bu katmanın çıktısı 10×10 boyutlarında 16 evrişim çekirdeği bulunan bir öznitelik haritasıdır. *S4,* 2×2 boyutunda bir havuzlama penceresi olan havuzlama katmanıdır. Dolayısıyla, bu katmandan geçen görüntülerin boyutu yarıya düşer, 5×5 boyutlarında 16 evrişim çekirdekli çıktılar üretir. *F5 S4*'ün çıktısına bağlı olan 120 nörona sahip tam bağlantılı bir katmandır. *F6, F5*'in çıktısına bağlı olan 84 nörona sahip tam bağlantılı bir katmandır. Çıktı katmanı, sınıf sayısına (0'dan 9'a kadar olan sayılar) karşılık gelen 10 nöronu içerir.

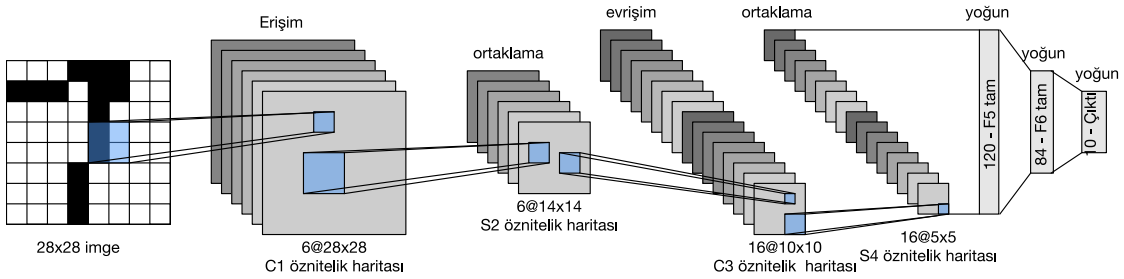

Şekil 2.1: Bir Evrişimli Sinir Ağı Örneği

Hiperspektral görüntü sınıflandırması alanında CNN'lerin kullanılmasının birçok avantajı bulunmaktadır. Bu avantajlar aşağıda belirtilmiştir:

Özellik Öğrenme: CNN'ler, verilerden otomatik olarak özellikler öğrenebilir. Bu, özellik mühendisliği ihtiyacını büyük ölçüde azaltır ve ayrıca modelin daha genel ve esnek olmasını sağlar.

Derinlik: CNN'ler, çok katmanlı yapıları sayesinde hiperspektral görüntüler gibi karmaşık yapılarda iyi çalışır. Bu, özellikle çok sayıda sınıfın olduğu ve sınıflar arasındaki farkların az olduğu hiperspektral görüntülerin sınıflandırılmasında önemlidir.

Yüksek Boyutlu Veriler: CNN'ler, yüksek boyutlu verilerde başarılıdır. Hiperspektral görüntüler, genellikle çok sayıda spektral bant içerdiğinden, CNN'lerin bu özelliği hiperspektral görüntü sınıflandırma işleminde önemlidir.

Esneklik ve Genelleme: CNN'ler, farklı görüntü çözünürlükleri ve boyutlarına uyum sağlama yeteneğine sahiptir. Ayrıca, öğrendikleri özellikler genellenebilir, bu da birçok farklı hiperspektral görüntü türünde iyi performans göstermelerini sağlar.

2.2.2. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları, derin öğrenme modelleri arasında önemli bir yere sahiptir. En temel özelliği, zaman serisi veya dizi verilerini işleme yeteneği olarak ön plana çıkmaktadır. Bu özellikleri onları, dil modelleme, makine çevirisi, konuşma tanıma gibi birçok karmaşık ve zamanla değişken veriye dayalı problemin çözümünde etkin kılar. RNN'ler, en basit anlatımla, bir nevi geriye dönük bağlantılar kurabilen yapay sinir ağlarıdır. Bu geri beslemeli bağlantılar, ağın daha önceki aşamalarda elde ettiği bilgileri saklamasına ve mevcut durumu anlama sürecinde bu bilgilerden yararlanmasına olanak tanır. Bir nevi hafıza görevi gören bu yapı, RNN'lerin, örneğin bir cümlenin tamamını anlamak veya bir video klibin içeriğini çözümlemek gibi, sürekli değişim içerisindeki durumları daha iyi analiz etmesine yardımcı olur. Ancak RNN'lerin, özellikle uzun süreli bağımlılıkların olduğu durumlarda performansı düşebilir. Yani, bir dizi veya zaman serisi boyunca uzun süreler boyunca bilgiyi koruma ve bu bilgiyi etkili bir şekilde kullanma yeteneği sınırlıdır. Bu problem, *'uzun süreli bağımlılıklar'* olarak adlandırılır ve RNN'lerin daha geniş uygulamalarında önemli bir engel oluşturur. Bu tür zorlukları aşmak amacıyla, daha gelişmiş RNN türleri ortaya çıkmıştır. Uzun Kısa Vadeli Bellek (Long Short-Term Memory - LSTM) ve Kapılı Tekrarlayan Birimler (Gated Recurrent Units - GRU) gibi modeller, RNN'lerin bu sınırlamalarını aşmayı hedefler. Bu modeller, daha karmaşık iç yapıları ve ek mekanizmaları ile uzun süreli bağımlılıkları daha etkin bir şekilde modellemeye olanak sağlar.

Uzun kısa vadeli bellek, RNN ailesinin bir üyesi olan gelişmiş bir derin öğrenme modelidir. LSTM, Sepp Hochreiter ve Jürgen Schmidhuber tarafından 1997 yılında tanıtılmıştır [4]. Bu modelin temel amacı, RNN'lerin uzun dizi verileri işlemedeki zorluklarını gidermektir. LSTM'ler, standart RNN'lerin aksine uzun süreli bağımlılıklar problemiyle daha etkili bir şekilde başa çıkabilirler. Yani, LSTM'ler, uzun zaman serileri boyunca bilgiyi koruyabilir ve bu bilgiyi etkin bir şekilde kullanabilirler. LSTM'lerin bu özelliği, birçok doğal dil işleme (Natural Language Processing - NLP) görevinde oldukça kullanışlı kılar. LSTM'lerin bu yeteneği, özel bir iç yapıya ve hücre durumu (cell state) olarak adlandırılan bir bileşene sahip olmasından kaynaklanır. Bir LSTM hücresi, bir bilgi *'otoyolu'* gibi çalışan ve LSTM hücresi boyunca ilerleyen bir hücre durumuna sahiptir. Bu durum, ağ boyunca bilgiyi taşıyan bir mekanizmadır ve üzerinde gerçekleştirilen işlemler, bilginin ne kadarının taşınacağını ve neyin unutulacağını kontrol eder. Bir LSTM hücresi, bu hücre durumunu etkileyebilecek üç kapıya sahiptir: unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate). Bu kapılar, hangi bilgilerin korunacağını, hangi yeni bilgilerin hücre durumuna ekleneceğini ve hangi bilgilerin sonuç olarak üretileceğini belirlemeye yardımcı olur. Bu kapıların her biri, aktivasyon fonksiyonları kullanılarak hesaplanır, bu sayede değerler 0 ve 1 arasında olur, bilginin ne kadarının geçeceğini veya unutulacağını belirler. Bu karmaşık yapısı ve hücre durumunun benzersiz mekanizması sayesinde, LSTM'ler, uzun süreli bağımlılıkları modelleme ve geniş zaman serileri üzerinde daha etkin çalışma yeteneği kazanır. Bu nedenle, uzun dizi verileri üzerinde çalışmak için genellikle RNN'ler yerine LSTM'ler tercih edilir.

Kapılı Tekrarlayan Birimler (Gated Recurrent Units - GRU), RNN ailesinin bir diğer üyesidir ve GRU da, uzun süreli bağımlılıklarla daha etkili bir şekilde başa çıkmak için tasarlanmıştır. GRU modeli, LSTM'lerin getirdiği bazı kavramları basitleştirmeyi hedefler, böylece daha az hesaplama karmaşıklığına sahip olurken benzer performansı korumayı amaçlar. GRU, 2014 yılında tanıtılmıştır. LSTM'lerden farklı olarak, GRU'nun yalnızca iki kapısı vardır: sıfırlama kapısı (reset gate) ve güncelleme kapısı (update gate). Bu iki kapı, bir GRU hücresinin hangi bilgileri hatırlaması veya unutması gerektiğini belirlemeye yardımcı olur. Sıfırlama kapısı, geçmiş bilgilerin ne kadarının yeni gelen bilgiyle birleştirileceğini kontrol eder. Güncelleme kapısı ise, geçmiş hücre durumunun ne kadarının yeni hücre durumu tarafından alınacağını belirler. Bu iki kapının birleşiminden dolayı, GRU modeli LSTM'lere benzer bir şekilde uzun süreli bağımlılıkları modelleyebilir. Ancak, GRU'nun LSTM'lerden daha basit bir yapıya sahip olması avantajlara sahip olduğu gibi bazı dezavantajları da beraberinde getirir. Bazı

durumlarda, LSTM'lerin ek kapısı ve daha karmaşık iç yapısı, daha karmaşık problemleri modellemek için gereklidir. Diğer taraftan, GRU'nun daha basit yapısı, daha az hesaplama gerektirdiği için daha hızlı eğitilebilir ve daha az veriye sahip durumlarda daha iyi performans gösterebilir. Bu nedenle, hangi modelin kullanılacağına karar verirken, veri kümesinin doğası ve modelin karmaşıklığına dayalı bir değerlendirme yapmak önemlidir. Hiperspektral görüntüler, genellikle her bir pikselin kendi spektral imzasına sahip olduğu yüzlerce spektral bant içerir. GRU, bu spektral bilgiyi dizi veya sekans olarak işleyebilir. Özellikle, GRU, bir dizi spektral bandı zamansal bir dizi olarak modelleyerek, bir bandın önceki ve sonraki bandlarla olan ilişkisini anlamada başarılıdır. GRU, LSTM'ye kıyasla daha basit bir yapıya sahiptir. Bu daha basit yapı, GRU'nun daha hızlı eğitilebilir olmasını sağlar, bu da daha az veri ve daha az hesaplama kaynağı gerektirir. Ayrıca, GRU'nun daha az parametreli yapısı, modelin daha az aşırı öğrenme eğilimi göstermesini sağlar. Hiperspektral görüntülerin çok boyutlu ve karmaşık spektral yapısı sebebiyle GRU, LSTM'ye kıyasla daha verimli çalışır.

2.2.3. Dikkat Mekanizması

Dikkat mekanizması, derin öğrenme modellerine, öğrenme sürecinde hangi bilgilere odaklanmaları gerektiğini belirleme yeteneği kazandırmak için kullanılan bir tekniktir. Bu teknik, insan beyninin dikkat sürecini modelleyerek geliştirilmiştir. İnsan beyni, belirli bir durumda veya görevde en önemli bilgilere odaklanır ve diğer bilgileri görmezden gelir. Dikkat mekanizması, bu insana özgü süreci taklit ederek, bir derin öğrenme modelinin verinin belirli kısımlarına daha fazla odaklanmasını sağlar.

Dikkat mekanizması, bir dizi skor hesaplar (bu skorlar genellikle giriş dizisi üzerinde bir softmax aktivasyon fonksiyonu kullanılarak hesaplanır), ve bu skorlar, modelin giriş dizisindeki her öğeye ne kadar *'dikkat etmesi'* gerektiğini belirler. Daha sonra, bu dikkat skorları çıktı dizisini oluştururken kullanılır. Dikkat mekanizması, derin öğrenme modellerinin öğrenme sürecini daha etkili ve etkin hale getirir, çünkü modelin en önemli bilgilere odaklanmasını sağlar. Bu, modelin daha iyi sonuçlar üretmesine ve daha hızlı öğrenmesine yardımcı olur.

Dikkat mekanizması, genel olarak ağırlıklı toplam veya ağırlıklı ortalama formülüyle ifade edilebilir. Bu formül, dikkat ağırlıklarının verilere uygulanmasını sağlar. Dikkat mekanizmasının genel formülü 2.5'teki gibi gösterilebilir:

$$dm = \sum_{i=1}^{N} da(i) * g(i) \tag{2.5}$$

2.5 denkleminde kullanılan değişkenler aşağıda tanımlanmıştır:

dm, dikkat mekanizması sonucunda elde edilen çıktıdır.

N, girişin boyutunu temsil eder.

da, i. girişin dikkat ağırlığını ifade eder.

g(i), i. girişin değerini ifade eder.

Hiperspektral görüntü sınıflandırmasında kullanılan dikkat mekanizmaları, farklı özelliklere odaklanarak sınıflandırma performansını artırmayı amaçlar. Bu alanda kullanılan bazı dikkat mekanizması türleri şu şekildedir:

Kanal Bazlı Dikkat Mekanizması: Hiperspektral verilerin farklı spektral kanallarına odaklanılır. Her spektral kanalın önemini belirleyen ağırlıklar hesaplanır ve bu ağırlıklar spektral verilere uygulanır. Modelin önemli spektral özellikler *'dikkat etmesi'* ve sınıflandırma işlemi için daha verimli bir şekilde kullanılması sağlanır.

Sıralı Dikkat Mekanizması: Hiperspektral verilerin zaman veya uzamsal sıralamasına odaklanır. Özellikle hiperspektral küp gibi 3 boyutlu hiperspektral verilerde kullanılır. Sıralı dikkat mekanizması, verinin zaman veya uzamsal boyutlarındaki önemli özellikleri belirler ve bu özelliklere odaklanarak sınıflandırma performansını artırır.

İlişkisel Dikkat Mekanizması: Hiperspektral verilerde farklı pikseller veya bölgeler arasındaki ilişkilere odaklanır. İlişkisel dikkat mekanizması, pikseller arasındaki bağımlılıkları ve etkileşimleri modellemek için kullanılır. Özellikle hiperspektral verilerdeki kontrastlı nesneler veya bitki türleri arasındaki ilişkileri yakalamak için etkili bir mekanizmadır.

Bu dikkat mekanizmaları, hiperspektral verilerin özelliklerini daha etkin bir şekilde kullanmayı ve sınıflandırma performansını artırmayı hedefler. Her bir mekanizma, verinin doğasına ve probleme özgü gereksinimlere bağlı olarak tercih edilebilir. Bu mekanizmalar, daha spesifik bir odaklanma ve daha iyi sınıflandırma sonuçları elde etmek için hiperspektral görüntü sınıflandırmasında yaygın olarak kullanılan teknikler arasındadır.

2.3. LİTERATÜR ÇALIŞMALARI

2000'lerin başına hiperspektral görüntü sınıflandırması alanında geleneksel yöntemler olarak adlandırılan bazı yöntemler kullanılmıştır. Geleneksel yöntemlerin en popülerlerinden bir tanesi boyut azaltma teknikleridir. 1994 yılında ortaya atılan [5] ile verilen çalışmada, hiperspektral görüntülerin sınıflandırılması ve boyut indirgeme konularına odaklanmıştır. [5] çalışmasında, yazarlar hiperspektral görüntüleri sınıflandırmak için bir Ortogonal alt uzay projeksiyonu (Orthogonal Subspace Projection - OSP) yöntemi önermişlerdir. OSP, bir çıktı vektörünün belirli bir alt uzaya dik olduğundan emin olmak için kullanılan bir işlemdir. Bu, genellikle bir dizi verinin belirli bir özelliğini korurken diğer özellikleri silmek için kullanılır. [5] çalışmasında, OSP yaklaşımını hiperspektral görüntülerin boyutunu azaltmak için kullanmıştır, daha sonra elde edilen veri kümesini sınıflandırmak için bir dizi denetimli sınıflandırma algoritması kullanılmıştır.

Geleneksel yöntemlerde hiperspektral görüntülerde bant seçimi teknikleri de 2000'lerin başına kadar sıkça kullanılan bir yöntem olmuştur. [6] ile verilen çalışmada, hiperspektral görüntü sınıflandırmasında bant seçimi konusuna odaklanmıştır. Hiperspektral görüntüler, genellikle çok sayıda spektral bant içerir ve yüksek boyutlu veri kümeleri oluşturur. Bu yüzden, etkili bir sınıflandırma için genellikle en çok bilgi içeren ve azami öznitelik içeren bantların seçilmesi gerekir. Ancak bu seçim genellikle zor bir süreçtir çünkü her bir bandın bilgisi birbirine bağımlıdır ve bazı bantlar diğerlerine göre daha fazla bilgi içerebilir. Bu çalışmada, band seçimi iki adımlı bir süreç olarak ele alınmıştır. Bunlar, bant önceliklendirme ve bant dekorelasyondur (korelasyonun giderilmesi). Önceliklendirme, her bir bandın sınıflandırma için ne kadar önemli olduğunu belirlerken, dekorelasyon, seçilen bantların birbirlerine göre ne kadar bağımsız olduğunu belirler. Bu çalışmanın sonuçları, bu iki adımlı yaklaşımın, hiperspektral görüntü sınıflandırmasında bant seçimini etkili bir şekilde yönetmeye yardımcı olduğunu göstermiştir. Bu, hem sınıflandırma doğruluğunu arttırır, hem de sınıflandırma işlemini daha hızlı ve daha verimli hale getirir. Ayrıca, bu yaklaşımın farklı sınıflandırma algoritmalarıyla da kullanılabilir olması, bu yaklaşımı geniş bir uygulama yelpazesi için uygun hale getirmektedir.

Hiperspektral görüntüler genellikle çok yüksek boyutlu veri setleridir ve bu, geleneksel sınıflandırma ve analiz yöntemleri için önemli zorluklara yol açar. Geleneksel yöntemler genellikle karmaşık ve doğrusal olmayan veri dağılımlarıyla başa çıkmakta zorlanır. Bundan dolayı araştırmacılar yeni hiperspektral görüntü sınıflandırması alanında yeni yöntemler aramışlardır.

2000’lerin başından beri, derin öğrenme algoritmalarıyla ilişkili birçok görüntü işleme tekniği hiperspektral veri sınıflandırmasında uygulanmıştır.

Hiperspektral görüntü sınıflandırma için temelde 3 tür mimari bulunmaktadır :

- *Spektral Bilgi*

Örneklemeler için çekirdek yöntemler kullanarak yüksek boyutlu özellik alanlarında marjı maksimize eden Destek Vektör Makinesi (Support Vector Machine - SVM), hiperspektral verilerin sınıflandırılması için ortaya atılmıştır. SVM tabanlı sınıflandırma yöntemleri uzun süre boyunca en gelişmiş yöntemler arasındaki yerini korumuştur [7].

Spektral modeller yalnızca 1-D spektral bilgiyi giriş olarak kullanır. Aşırı öğrenme sorununu azaltmak ve genelleştirme kapasitesini artırmak için 1x1 evrişimli çekirdekleri ve geliştirilmiş bırakma oranları olan bir CNN yapısı [8] ile verilen çalışmada önerilmiştir. Ağın parametrelerini daha da azaltmak için, tamamen bağlı bir katman global ortalama havuzlama katmanı ile değiştirilir. 1-D spektral vektörü, 2-D özellik matrisine dönüştürerek ve 1x1 ve 3x3 evrişim katmanlarından oluşan bileşik katmanları birleştiren bir yapı, Hiperspektral görüntü (Hyperspectral Image - HSI) bantları arasındaki yüksek korelasyonu azaltırken özellik yeniden kullanma yeteneğini elde edebilmiştir. [8] ile verilen çalışmaya benzer şekilde, [9] ile verilen çalışma ağın eğitim parametrelerini düşürürken yüksek boyutlu özellikleri çıkarmak için global ortalama havuzlama katmanını kullanmıştır.

- *Mekansal Bilgi*

Mekansal modeller yalnızca mekansal bilgileri dikkate alır ve orijinal HSI verilerinin boyutsallığını azaltmak için spektral alan üzerinde boyut azaltma yöntemleri kullanır. Örneğin [10] ile gösterilen çalışmada, sadece mekansal bilgi içeren ilk temel bileşeni ayıklamak için PCA kullanmıştır ve elde edilen mekansal bilgiyi sınıflandırmak için CNN kullanmıştır. Benzer şekilde, [11] çalışmasında bir temel bileşen ile mekansal tabanlı bir 2D-CNN kullanmıştır. Bununla birlikte, oldukça benzer spektral özelliklere sahip sınırlı eğitim örnekleri, derin öğrenme modellerini aşırı öğrenmeye eğilimli hale getirir. [12] ile verilen çalışmada, sınırlı eğitim örnekleri nedeniyle aşırı öğrenme sorununun üstesinden gelmek için Gabor filtreleme tekniğini 2D-CNN ile birleştirmiştir. Gabor filtreleme, fazla öğrenme sorununu etkili bir şekilde azaltan kenarlar ve dokular dahil olmak üzere mekansal özellikleri çıkarır.

- *Spektral-Mekansal Bilgi*

Spektral-mekansal hiperspektral görüntü sınıflandırması, hem mekansal özellikleri hem de spektral özellikleri dikkate alır. Markov Rastgele Alan (Markov Random Field - MRF) modeli mekansal ve spektral özellikleri birleştirerek hiperspektral veri sınıflandırması için kullanılmıştır [13], [14]. Hem spektral hem de mekansal bilgiyi eşzamanlı olarak kullanmayı sağlayan verimli bir derin 3D-CNN modeli, [15] ile verilen çalışmada hiperspektral görüntü sınıflandırma için önerilmiştir. [16] ile gösterilen çalışmada, yüksek mekansal çeşitliliğe sahip görüntülerden ayrımlayıcı özellikler öğrenebilen, HSIC için derin, çok ölçekli spektral-mekansal özellik çıkarımı yaklaşımını önermiştir. Bu yaklaşım, mekansal bilgiyi çıkarmak için Tam Konvolüsyonel Ağ (Fully Convolutional Network - FCN) kullanır ve ardından, bu özellikler, ağırlıklı bir birleştirme stratejisi kullanarak spektral bilgiyle birleştirilir. Son olarak, bu birleştirilmiş özellikler üzerinde piksel bazında sınıflandırma gerçekleştirilir. Derin Evrişimli Sinir Ağları (Deep Convolutional Neural Network - DCNN), evrişim katmanları ve alt örnekleme katmanlarından oluşan ve görüntü sınıflandırması gibi görevlerde üstün performans sağlayabilen bir derin öğrenme mimarisidir. Bu mimari, el yazısı karakterleri ve trafik işaretlerinin tanınması gibi alanlarda en gelişmiş performanslardan birini elde etmiştir [17]. Evrişimli Sinir Ağı mimarisi, [18] çalışmasında sunulan biyolojik görsel sistem tarafından ilham alınmıştır. CNN mimarisi iki ana bölüme ayrılabilir: Birincisi Özellik Çıkarma (Feature Extraction - FE) ağı, diğeriyse ilk aşamada çıkarılan özellik haritalarına dayalı bir sınıflandırmadır. Tam bağlantılı katmanlar ve bir SoftMax aktivasyon fonksiyonundan oluşan sınıflandırma aşaması, FE aşamasında çıkarılan özellik haritalarına dayanarak, giriş örüntüsünün belirli bir sınıfa ait olma olasılığını verir. Tam bağlantılı katman, önceki katmandaki her nöronu mevcut katmandaki her nörona bağlar. [19] ve [20] ile gösterilen çalışmalarda, araştırmacılar tam bağlantılı katmanın, global ortalama havuzlama katmanı kullanılarak göz ardı edilebileceğini öne sürmüşlerdir. Softmax genellikle sınıflandırma görevleri için kullanılır [21], [22] ancak, birçok çalışma bu amaçla SVM'yi [23], [24] kullanmıştır.

Hiperspektral verilerin sınıflandırılmasında hem mekansal hem spektral özelliklerin kullanılmasının büyük avantajları vardır. Her iki tür bilginin kullanılması, verinin daha kapsamlı bir şekilde analiz edilmesini sağlar. Hem spektral hem de mekansal bilgileri kullanan modeller genellikle daha yüksek sınıflandırma doğruluğuna sahiptir. Mekansal bilgiler, pikseller arasındaki ilişkileri ve yapıları göz önünde bulundururken, spektral bilgiler piksellerin

kendine özgü spektral özelliklerini içerir. Bu iki bilgi türünün kombinasyonu genellikle daha iyi sınıflandırma performansı sağlar. Hem mekansal hem de spektral bilgi kullanan sınıflandırma yöntemleri, karmaşık ve değişken ortamlarda daha etkilidir. Hem spektral hem de mekansal bilgiyi birleştiren sınıflandırma modelleri genellikle daha genel kabul edilebilir. Yani, farklı görüntü türlerinde veya koşullarda daha iyi performans gösterirler. Bu, özellikle çok çeşitli arazi sınıflarının ve nesnelerin bulunduğu geniş ölçekli ve çeşitli veri kümelerinde faydalıdır.

Hiperspektral görüntü sınıflandırmasında dikkat modülü, modelin giriş verilerindeki en alakalı özelliklere odaklanması için kullanılan bir mekanizmadır. Bir dikkat modülünü kullanmanın amacı, modelin yüksek boyutlu hiperspektral verilerden önemli bilgileri öğrenmesini ve çıkarmasını kolaylaştırarak hiperspektral görüntü sınıflandırma modelinin performansını iyileştirmektir.

Dikkat modüllerinin çeşitli biçimleri vardır, bunlar arasında öz-dikkat ve kanal bazında dikkat bulunur. Öz-dikkat modelleri, bir hiperspektral görüntüdeki her piksele, alakalılığına dayanarak bir ağırlık atar. Kanal bazında dikkat modelleri ise görüntüdeki her spektral banda, sınıflandırma görevine olan katkısına dayanarak bir ağırlık atar.

Hiperspektral görüntü sınıflandırmasında, dikkat modülleri, doğruluk ve hesaplama verimliliği açısından büyük katkılar sağlamıştır. Dikkat modülleri, giriş verisinin boyutunu azaltarak modelin dikkatini en alakalı özelliklere seçici olarak odaklaması sayesinde, veriyi doğru bir şekilde öğrenme ve sınıflandırma sürecini kolaylaştırır. Bu yaklaşım, modelin gereksiz veya gürültülü bilgileri atlamasına ve önemli özelliklere odaklanmasına olanak sağlar. Böylece, daha etkili bir özellik çıkarma süreci gerçekleştirilir ve veri temsili daha etkili bir şekilde elde edilir. Bu şekilde, dikkat modülleri, veri içerisindeki gürültüyü ve yanlış sinyalleri filtreleyerek, daha temiz ve daha önemli bilgilerin vurgulanmasına yardımcı olur. HSI sınıflandırması için [25] ile verilen çalışma, olasılık temelli bir komşuluk birleştirme dikkat ağı önermiştir. [26] çalışmasında, HSI'deki bant fazlalığını ve gürültüyü azaltmak amacıyla geleneksel CNN yapısına bir dikkat modülü ekleyerek hiperspektral görüntü sınıflandırma için yeni bir mimari ortaya atmıştır.

HSI sınıflandırılması için önerilen [27] ile gösterilen çalışma, spektral düzlemde dikkat mekanizması olan yeni bir uçtan uca 3-D yoğun evrişim ağı önermektedir. Önerilen yaklaşım, farklı ölçeklerde eşzamanlı olarak spektral ve mekansal özellikleri yakalamak için 3-D

evrişimler kullanır ve tüm 3-D özellik haritalarını yoğun bir şekilde birbirine bağlar. Spektral özelliklerin ayırt edilebilirliğini artırmak için de bir spektral düzlemde dikkat mekanizması eklenmiştir, bu da eğitimli modellerin sınıflandırma performansını artırır. [28] ile verilen çalışma, hiperspektral görüntülerin spektral-mekansal sınıflandırılması için dikkat destekli bir CNN modeli önermiştir. Sırasıyla spektral ve mekansal sınıflandırmalar için bir spektral dikkat alt ağı ve bir mekansal dikkat alt ağı kullanılması önerilmiştir.

2.4. Literatür Analizi

Hiperspektral görüntü sınıflandırma üzerine yapılan bu çalışmalar, bu konunun kritik önemini ve gelecekteki araştırmalar için ön planda bir konu olacağını göstermektedir. Özellikle son zamanlarda gerçekleştirilen çalışmalar, Evrişimli Sinir Ağları, Tekrarlayan Sinir Ağları ve dikkat mekanizmalarının bu alandaki uygulanabilirliğinin ve öneminin belirgin bir biçimde ortaya çıkmasını sağlamıştır. Literatürdeki son çalışmalar incelendiğinde, hiperspektral görüntü sınıflandırılmasında, hiperspektral görüntünün spektral ve mekansal özelliklerini ayrı ayrı ele almanın sınıflandırma başarısındaki önemi ortaya çıkmaktadır. Ayrıca son 2-3 yılda ortaya çıkan çalışmalar, özellikle artan hiperspektral görüntü boyutları göz önüne alındığında, dikkat mekanizmalarının bu alanda kullanılmasının kaynak tüketiminin verimliliği konusunda çok önemli olduğunu göstermektedir.

Tüm bunlar göz önüne alınarak bu çalışmada gerçekleştirilen model, hiperspektral görüntü verilerini işlerken, hem spektral hem de mekansal boyutları dikkate alan çok katmanlı bir yaklaşıma sahiptir. Bu yaklaşım, farklı özellikte olan mekansal ve spektral katmanları minimum kayıp olacak şekilde işlemesini sağlamaktadır.

Modelin önemli bir özelliği olan dikkat mekanizması, belirli özelliklerin öğrenilmesi ve ağırlıklandırılmasında büyük rol oynar. Dikkat mekanizması, modelin önemli bilgileri belirleyerek, gereksiz bilgileri gürültü olarak süzmesini sağlar. Dikkat mekanizması, modelin performansını iyileştirir ve daha hızlı ve etkili bir şekilde eğitilmesine yardımcı olur.

Bu modelde CNN ve çift yönlü tekrarlayan sinir ağları (Bidirectional Recurrent Neural Network - Bi-RNN) kullanılmıştır. CNN'nin mekansal özellikleri öğrenme kabiliyeti ve Bi-RNN'nin spektral özelliklerin zamansal bağlantılarını yakalama yeteneği, modelin her iki bilgi türünü de kapsamlı bir şekilde öğrenmesini sağlar.

Son olarak, modeldeki yoğun katmanlar (dense) ve bırakma (dropout) katmanları, aşırı öğrenmenin önlenmesine yardımcı olur. Bu, modelin genelleme kabiliyetini geliştirir. Bu tür bir tasarım, modelin genel verimliliğini ve etkinliğini artırır.

3. YÖNTEM

3.1. Veri Kümeleri

Hiperspektral görüntü sınıflandırma veri kümeleri, diğer görüntü sınıflandırma veri kümelerine göre daha sınırlı sayıdadır. Bu kısmen, hiperspektral verilerin toplanması için özel sensörler ve hava platformlarına ihtiyaç duyulması, bu sürecin zorlukları ve maliyetiyle ilgilidir. Bununla birlikte, sınırlı veri kümesi, hiperspektral görüntü sınıflandırma algoritmalarının ve tekniklerinin geliştirilmesini engellemez. Araştırmacılar, hiperspektral görüntü sınıflandırmasının doğruluğunu artırmak için yeni yöntemler keşfetmeye devam etmektedirler.

Sınırlı sayıdaki veri kümelerine rağmen, bu veri kümeleri birçok araştırma makalesinde kullanılmaktadır ve hiperspektral görüntü sınıflandırmasında son teknolojiyi ilerletmede önemli bir rol oynamaktadır. Ayrıca, yeni hiperspektral görüntü veri kümeleri periyodik olarak geliştirilmekte ve yayınlanmaktadır.

Bu çalışmada kullanılan veri kümeleri aşağıdaki gibidir:

Indian Pines (Indian Pines - IP): AVIRIS sensörü tarafından Indiana, ABD'deki bir tarım alanı üzerinde toplanmıştır ve 145x145 piksel ile 224 spektral bant içerir.

Pavia Üniversitesi (Pavia University - PU): ROSIS sensörü tarafından Pavia, İtalya'daki bir kentsel alan üzerinde toplanmıştır ve 610x340 piksel ile 103 spektral bant içerir.

Salinas (Salinas - SA): AVIRIS sensörü tarafından Kaliforniya, Salinas Vadisi'ndeki bir tarım alanı üzerinde toplanmıştır ve 512x217 piksel ile 204 spektral bant içerir.

Kennedy Uzay Merkezi (Kennedy Space Center - KSC): AVIRIS sensörü tarafından Kennedy Uzay Merkezi, Florida üzerinde toplanmıştır ve 512x256 piksel ile 224 spektral bant içerir.

Tablo 3.1'de, bu çalışmada kullanılan veri kümeleri verilmiştir. Tabloda kullanılan veri kümelerinin hangi yılda elde edildiği, hangi sensör tarafından elde edildiği, boyutları, çözünürlüğü, spektral menzili, bant sayısı ve sınıf sayısı verilmiştir.

Tablo 3.1: IP, SA, PU, KSC veri kümelerinin özellikleri

No.	Indian Pines	Salinas	Pavia Üniversitesi	Kennedy Uzay Merkezi
Yıl	1992	-	2003	1996
Sensörler	AVIRIS	AVIRIS	ROSIS	AVIRIS
Boyut	145x145	512x217	610x340	512x614
Mekansal Çözünürlük.(/m)	20	3.7	1.3	-
Spektral Menzil (nm)	400 ~ 2500	-	430 ~ 860	400 ~ 2500
Bant	200	204	103	176
Kategori Sayısı	16	16	9	13

Çalışmalarda kullanılan veri kümelerinin arazi örtüsü sınıfları Tablo 3.2, Tablo 3.3, Tablo 3.4 ve Tablo 3.5'te verilmiştir.

Tablo 3.2'de, IP veri kümesinde 16 arazi örtüsü sınıfı gösterilmektedir. IP veri kümesi, hiperspektral görüntü sınıflandırma algoritmalarının geliştirilmesi ve performansının değerlendirilmesi için bir benchmark olarak sıklıkla kullanılmaktadır. Veri kümesi, sınırlı sayıda örnekleme verisine sahip olmasına rağmen, farklı sınıfların spektral özelliklerini ve mekansal dağılımlarını temsil etmektedir. Bu nedenle, IP veri kümesi, hiperspektral görüntü sınıflandırma çalışmalarında yaygın bir şekilde kullanılan bir örnekleme haline gelmiştir.

Tablo 3.2: Indian Pines veri kümesinin arazi örtüsü sınıfları

Sınıf No.	Sınıf Adı
1	Corn Notill
2	Corn Mintill
3	Corn
4	Grass Pasture
5	Grass Trees
6	Hay Windrowed
7	Soybean Notill
8	Soybean Mintill
9	Soybean Clean
10	Wheat
11	Woods
12	Building Grass Trees Drives
13	Stone Steel Towers
14	Alfalfa
15	Grass Pasture Mowed
16	Oats

Tablo 3.3: Pavia Üniversitesi veri kümesinin arazi örtüsü sınıfları

Sınıf No.	Sınıf İsmi
1	Asphalt
2	Meadows
3	Gravel
4	Trees
5	Metal Sheets
6	Bare Soil
7	Bitumen
8	Bricks
9	Shadows

PU sahnesinde 9 arazi örtüsü sınıfı bulunmaktadır ve sınıf isimleri Tablo 3.3'te yer almaktadır.

Tablo 3.4, SA’daki 16 arazi örtüsü sınıfını göstermektedir.

Tablo 3.4: Salinas veri kümesinin arazi örtüsü sınıfları

Sınıf No.	Sınıf İsmi
1	Brocoli green weeds 1
2	Brocoli green weeds 2
3	Fallow
4	Fallow rough plow
5	Fallow smooth
6	Stubble
7	Celery
8	Grapes untrained
9	Soil vinyard develop
10	Corn senesced green weeds
11	Lettuce romaine 4
12	Lettuce romaine 5
13	Lettuce romaine 6
14	Lettuce romaine 7
15	Vinyard untrained
16	Vinyard vertical trellis

Tablo 3.5'te ise KSC veri kümesindeki 13 arazi örtüsü sınıfı gösterilmiştir.

Tablo 3.5: Kennedy Space Center veri kümesinin arazi örtüsü sınıfları

Sınıf No.	Sınıf İsmi
1	Trees
2	Shrubbery
3	Grass
4	Vegetation cover
5	Building
6	Roads
7	Railway
8	Park areas
9	Airport
10	Water surface
11	Coast
12	Urban areas
13	Mining areas

Yukarıda bahsedilen ve bu çalışmada kullanılan veri kümeleri hiperspektral görüntü sınıflandırma alanında yaygın olarak kullanılan veri kümeleridir.

Hiperspektral veri kümeleri görselleştirilirken ve sınıflandırılırken kullanılan bazı teknikler ve bileşenler vardır. Bunlardan aşağıda bahsedilmiştir:

3 bantlı sahte renk bileşimi, hiperspektral görüntü sınıflandırmada yaygın olarak kullanılan bir görselleştirme tekniğidir. Bu teknikte, hiperspektral verilerin farklı spektral bantlardan elde edilen bilgileri, kırmızı (R), yeşil (G) ve mavi (B) renk bileşenleri olarak atanır. Genellikle, spektral bantlar kırmızı, yeşil ve yakın kızılötesi bölgelerde yer alır. Böylece, görsel olarak anlaşılır bir renkli görüntü oluşturulur.

Yer referans haritası, hiperspektral görüntü sınıflandırmada kullanılan bir başka önemli bileşendir. Yer referans haritası, hiperspektral görüntülerdeki her bir pikselin arazi örtüsü

sınıfını temsil eden etiketleri içerir. Örneğin, mısır tarlası, orman, su alanı, yol gibi farklı sınıfları belirleyen etiketlerden oluşur.

Yer referans haritası, hiperspektral görüntü sınıflandırma algoritmalarının doğruluğunu değerlendirmek ve performanslarını ölçmek için kullanılır. Algoritmalar, yer referans haritasındaki sınıf etiketleriyle karşılaştırılarak sınıflandırma doğruluğu hesaplanır. Bu, algoritmaların farklı sınıfları doğru bir şekilde ayırt etme becerisini ve sınıflandırma performansını değerlendirmek için önemli bir araçtır.

3 bantlı sahte renk bileşimi ve yer referans haritası, hiperspektral görüntü sınıflandırmada görselleştirme ve doğruluk değerlendirme için önemli araçlardır. Sahte renk üçlü bileşimi, verilerin görsel olarak daha anlaşılır hale getirilmesine yardımcı olurken, yer referans haritası algoritmaların performansının değerlendirilmesine katkı sağlar.

IP, PU, SA, KSC veri kümelerinin sahte renk bileşimi ve karşılık gelen yer referans verileri sırasıyla Şekil 3.1, Şekil 3.2, Şekil 3.3 ve Şekil 3.4'te gösterilmektedir.

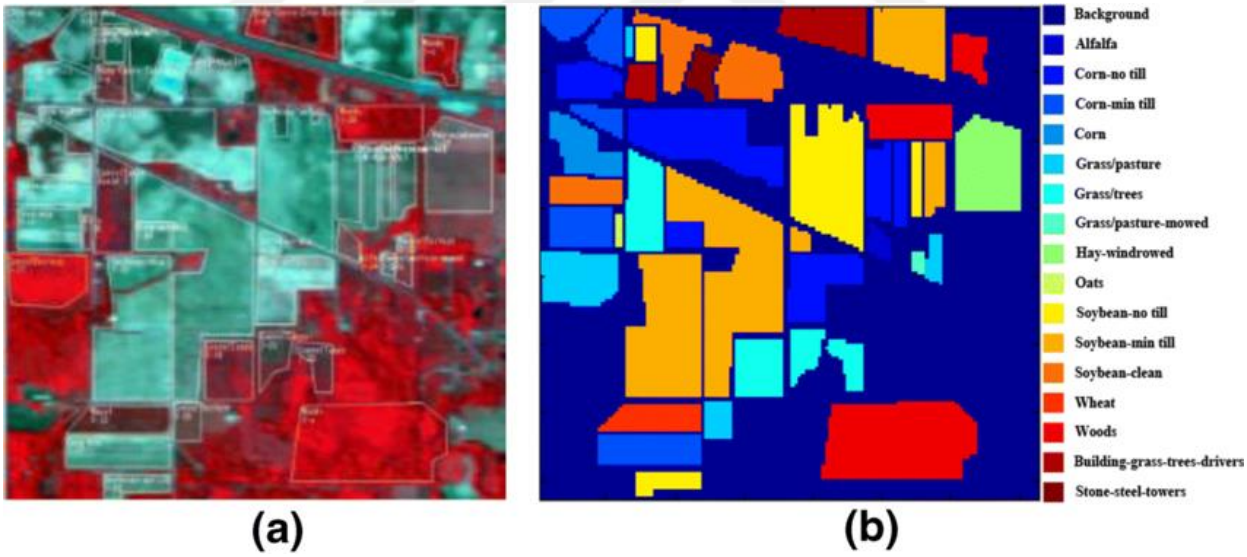

Şekil 3.1: IP veri kümesi. (a) 3 bantlı sahte renk bileşimi (b) Zemin referans verileri ve renk kodu

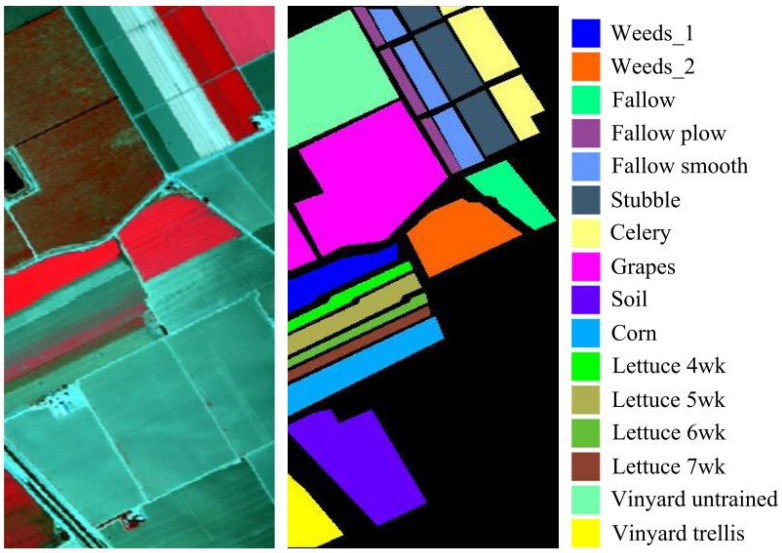

Şekil 3.2: Salinas veri kümesi. (a) 3 bantlı sahte renk bileşimi (b) Zemin referans verileri ve renk kodu

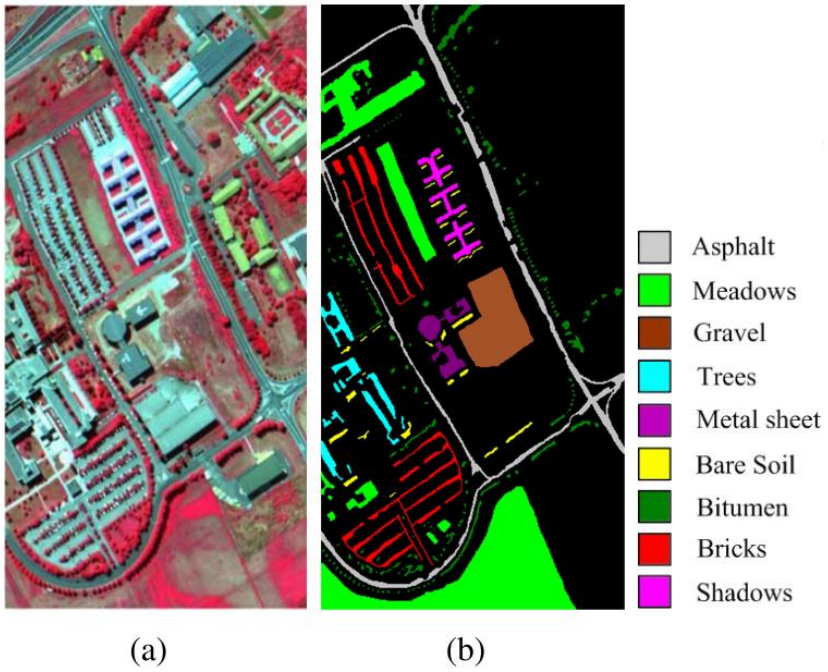

Şekil 3.3: Pavia Üniversitesi veri kümesi. (a) 3 bantlı sahte renk bileşimi (b) Zemin referans verileri ve renk kodu

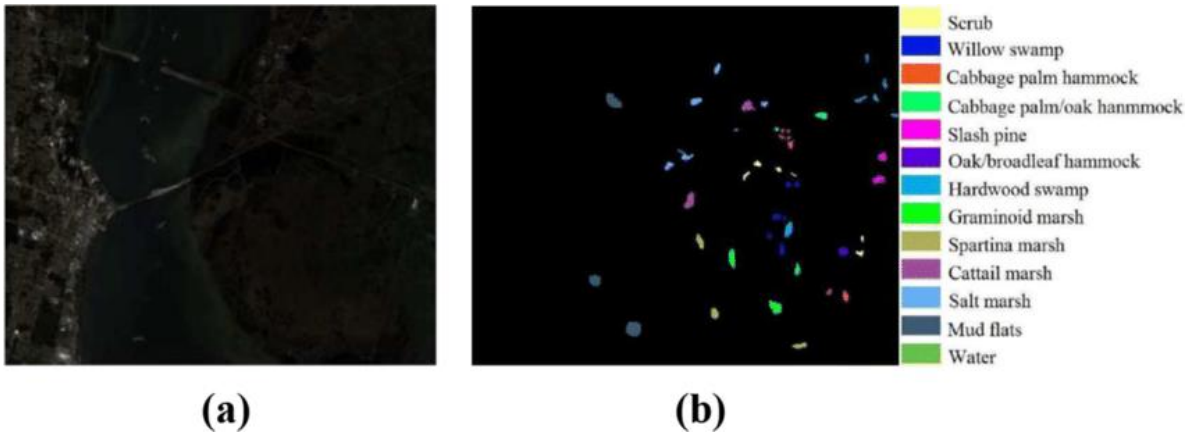

Şekil 3.4: KSC veri kümesi. (a) 3 bantlı sahte renk bileşimi (b) Zemin referans verileri ve renk kodu

Bu çalışmada ortaya koyulan modelin genelleştirilebilirliğini göstermek için farklı karakteristikteki 4 veri kümesi üzerinde çalışılmıştır. Daha küçük boyutlu ve az etiketli IP veri kümesi, daha belirgin sınıflara sahip SA veri kümesi, daha keskin geçişlere sahip sınıfların iç içe geçtiği PU veri kümesi ve ayrık ve küçük bölümlerde kümelenmiş KSC veri kümesi kullanılmıştır.

3.2. Önerilen Model

Bu çalışmanın gerçekleştirilmesinde temelde Kavramsal Çerçeve kısmında anlatılan derin öğrenme metotlarından Evrişimli Sinir Ağları ve Tekrarlayan Sinir Ağları kullanılmıştır.

Bu çalışma, hiperspektral görüntü sınıflandırması üzerine odaklanmaktadır. Derin öğrenme yöntemlerini kullanarak, gelen verinin spektral ve mekansal özelliklerini ayrı ayrı işleyen bir model önerilmiştir. Bu modelin temel amacı, hiperspektral görüntü verisindeki karmaşık ve yoğun bilgiyi en yüksek doğruluk ile sınıflandırmaktır. Hiperspektral görüntülerin yüksek boyutlu olmasından dolayı, hem kaynak tüketimi hem de sınıflandırma performansı metrikleri dikkate alınmıştır.

Bu çalışma, hiperspektral görüntü sınıflandırmasında iki temel katmana dayanmaktadır: spektral dikkat mekanizması içeren çift yönlü tekrarlayan sinir ağı ve mekansal dikkat mekanizması içeren evrişimli sinir ağı. Her iki katmanda da ayrı ayrı dikkat mekanizmaları bulunmaktadır.

Şekil 3.5'te geliştirilen modelin genel yapısı gösterilmiştir. Hiperspektral veri spektral ve mekansal olarak ikiye ayrılır. Spektral veri spektral modüle, mekansal veri ise mekansal modüle girdi olarak verilir. Spektral modüle girdi olarak verilen veri sırasıyla GRU, yoğun, aktivasyon ve dikkat mekanizması katmanlarıyla işlenir. Mekansal modüle girdi olarak verilen veri ise 2 adet 2-D evrişimli katman, yoğun, aktivasyon ve dikkat mekanizması katmanlarına girerek işlenir. Bu iki modülden elde edilen çıktılar birleştirilir. Elde edilen veri bir dizi ReLU (Doğrultulmuş Lineer Birim - Rectified Linear Unit) aktivasyon fonksiyonu ve bırakma katmanlarından geçirildikten sonra çıktı elde edilir.

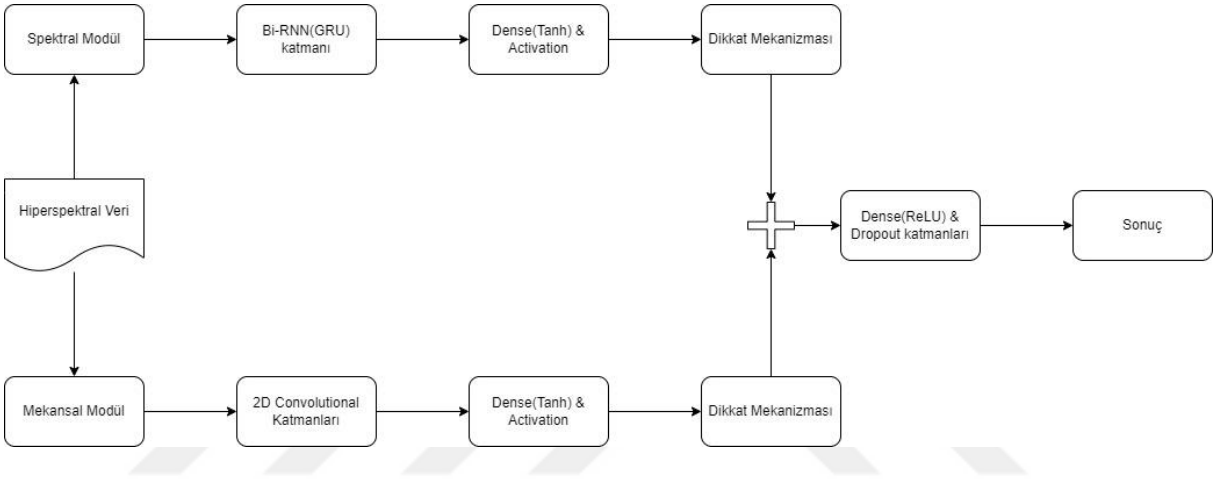

Şekil 3.5: Önerilen modelin genel yapısı

3.3. Veri Ön İşleme

Veri ön işleme, verilerin model tarafından daha etkin bir şekilde işlenmesini sağlamak için gerçekleştirilen bir dizi işlemi içerir. Görüntü sınıflandırması özelinde, özellikle derin öğrenme modeline girdi olarak verilecek görüntülerin ön işlemesi büyük önem taşır.

Hiperspektral görüntüler, her bir pikselin bir spektrum olarak geniş bir frekans aralığında yüzlerce veya binlerce bantta veri içerdiği görüntülerdir. Bu, hiperspektral verilerin, geleneksel RGB görüntülerine kıyasla çok daha fazla bilgi taşıdığı anlamına gelir. Ancak bu, verinin işlenmesini ve yorumlanmasını daha zor hale getirebilir.

Veri ön işleme, hiperspektral verilerin yönetilebilir ve anlamlı hale getirilmesinde kritik bir rol oynar. Hiperspektral görüntülerin sınıflandırılmasında kullanılan bazı veri ön işleme teknikleri aşağıda gösterilmiştir:

Spektral Özellik Çıkarımı: Her bir pikselin geniş bir spektrum içerdiği göz önüne alındığında, önemli özelliklerin çıkarılması ve hedef analizler için kullanılması gerekebilir. Bu genellikle spektral bant seçimi veya spektral dönüşüm tekniklerini içerir.

Boyut Azaltma: Hiperspektral veriler, büyük miktarda bant içerdiği için, boyut indirgeme teknikleri oldukça önemlidir. Bu, genellikle Öz Sıralı Kümeleme, Temel Bileşen Analizi (Principal Component Analysis - PCA) veya Bağımsız Bileşen Analizi (Independent Component Analysis - ICA) gibi yöntemler kullanılarak gerçekleştirilir.

Sonuç olarak, veri ön işleme süreci, veri kümelerinin makine öğrenmesi ve derin öğrenme modelleri için uygun hale getirilmesi için kritik bir aşamadır. Bu, hem standart görüntü sınıflandırma için geçerli olmasının yanı sıra, özellikle hiperspektral gibi karmaşık ve çok boyutlu veri kümelerinde önemlidir.

Bu çalışmada kullanılan hiperspektral görüntülere uygulanan veri ön işleme adımları şu şekildedir:

*Verinin Yüklenmesi***:** İlgili veri kümesi yüklenir. Veri kümesi ve etiketler iki ayrı değişkene atanır.

*Temel Bileşen Analizi (Principal Component Analysis - PCA) Uygulanması***:** Bu, veri boyutunu azaltmaya yardımcı olur. Bu değer veri kümesinin boyutunu ve spektral katman sayısına göre farklılık gösterebilmektedir.

*Verinin Hazırlanması***:** Boyutu azaltılan veri bir takım işlemlerden geçirilir. Bu işlemler aşağıdaki adımları içerir:

- *Küp Çıkarımı:* Hiperspektral görüntülerden belirli boyutlarda küpler çıkarılır. Bu küplerin boyutları küçüldükçe daha detaylı ve başarılı sonuçlar alınabilmektedir. Ancak aynı zamanda bu hiperspektral verilerin büyüklüğü göz önüne alındığında dikkatli karar verilmesi gereken bir değerdir. Bu çalışmada sınıflandırma sonuçları ve kaynak tüketimini dengeleyecek en uygun değer 27x27 olarak belirlenmiştir.

- *Normalizasyon:* Elde edilen veri kümesi, verinin en büyük değeriyle bölünerek 0-1 aralığına normalleştirilir.

- *Verinin spektral ve mekansal bileşenlere ayrılması:* Spektral bileşenler, küplerin tüm piksellerinin spektral bantları boyunca ortalamasını alarak bulunur. Mekansal bileşenler, orijinal görüntü verisi ile aynıdır.

- *Eğitim ve test setlerine bölünmesi:* Son olarak, veri eğitim ve test setlerine bölünür. Test verisi oranı %1, %5 ve %10 olarak farklı değerler kullanılarak ölçülmüştür ve bu şekilde karşılaştırılmıştır. Indian Pines gibi küçük veri kümeleri için ise bu değerler %5, %15 ve %30 olarak belirlenmiştir.

3.4. Spektral Modülün İşlenmesi

Bu çalışmada ortaya konulan modelin spektral kısmı, Çift-Yönlü GRU katmanıyla başlar. Gelişmiş bir RNN olan GRU, bellek hücrelerini kullanarak bilgiyi uzun süreli bağımlılıklarla birlikte saklayabilir. Çift yönlü GRU'nun kullanılması, hem geçmiş hem de gelecek bilgilerinden yararlanarak daha kapsamlı bir anlayış elde edilmesini sağlar. Bu, özellikle hiperspektral veri gibi karmaşık ve yüksek boyutlu verilerde önemlidir.

Hiperspektral görüntü sınıflandırma, genellikle karmaşık bir işlem olup, çok sayıda spektral kanala sahip olduğu için yüksek boyutlu verileri işlemeyi gerektirir. Geleneksel görüntü işleme tekniklerinin yanı sıra, derin öğrenme modelleri bu alanda yaygın olarak kullanılır. Çift yönlü GRU, CNN ve LSTM bunlar arasında önemli olanlardır. Her birinin kendi avantajları vardır; ancak çift yönlü GRU'nun kullanımı, belirli durumlardaki performansı nedeniyle bu çalışmada tercih edilmiştir.

Çift Yönlü Bilgi Akışı: Çift yönlü GRU, bir dizi verinin hem geçmişini hem de geleceğini aynı anda modele sunar. Bu, her zaman noktasında daha fazla bağlam sağlar ve hiperspektral görüntülerdeki kompleks spektral korelasyonları anlamada yardımcı olur.

Veri Verimliliği: GRU, LSTM'ye benzer şekilde uzun dizi bağımlılıklarını modellemek için tasarlanmıştır. Ancak, GRU daha az parametreli bir yapı kullanır, bu da daha az veri gerektirdiği ve daha hızlı eğitildiği anlamına gelir. Bu, özellikle etiketli hiperspektral görüntülerin yüksek boyutları göz önüne alınınca LSTM'ye göre büyük bir avantaj sağlar.

Bu çalışmada verimizin spektral kısmını işlerken genel kanının aksine CNN yerine çift yönlü GRU kullanılmasının temel sebepleri, CNN'in geniş veya sıralı bağlamları modellemesinde çift yönlü GRU kadar başarılı olamamasıdır. Çift yönlü GRU'nun çift yönlü yapısı, hiperspektral verilerdeki geniş bağlamı daha etkin bir şekilde ele alır. Ayrıca yine bir RNN çeşidi olan LSTM'ler, hafıza hücresi adı verilen bir bileşen aracılığıyla uzun dizi bağımlılıklarını modellemekte son derece iyidirler. Ancak, bu ek hafıza biriminin işlemesi karmaşıklık ve hesaplama maliyetini artırır. GRU, LSTM'lerin karmaşıklığını azaltır ve yüksek boyutlu hiperspektral verilerin işlenmesi sırasındaki kaynak tüketimini kayda değer ölçüde azaltır. Yapılan karşılaştırmalarda Çift yönlü GRU modelinin çeşitli veri kümelerinde yapılan testlerde diğer modellere üstünlük sağladığı görülmektedir.

- *GRU katmanı:* Girdi olarak alınan spektral veri, GRU katmanına girdi olarak verilir. Çift yönlü RNN, hem geçmiş bilgileri (ileri yönlü durum) hem de gelecek bilgileri (geri yönlü durum) dikkate alır. Bu katmanda 256 gizli birim kullanılır.

- *Dikkat Mekanizması:* Bu adımda ilk olarak, çift yönlü GRU'nun çıktısı bir yoğun katmana girdi olarak verilir. Aktivasyon fonksiyonu olarak *'tanh'* kullanılır. Sonra dikkat ağırlıklarını hesaplamak için *'softmax'* fonksiyonu kullanılır. Softmax aktivasyonu, çıktılar arasında bir olasılık dağılımı oluşturur, bu da modelin hangi özelliklere dikkat etmesi gerektiğini belirler. Dikkat vektörü, çift yönlü GRU'nun çıktısının boyutuna uyması için boyutu ayarlanır, böylece çift yönlü GRU çıktısıyla çarpılabilir.

Hiperbolik tanjant aktivasyon fonksiyonunun (tanh) 3.1'de gösterilmiştir:

$$\tanh(x) = \frac{(e^{x} - e^{-x})}{e^{x} + e^{-x}} \tag{3.1}$$

Bu fonksiyon -1 ile 1 arasında bir çıktı verir ve bu nedenle genellikle sinir ağlarında, özellikle de tekrarlayan sinir ağlarında kullanılır.

Bu çalışmada kullanılan dikkat mekanizması 3 ana adımdan oluşur:

Skor Hesaplama: Her bir girişe bir skor atanır. Skor bir öğrenilebilir ağırlık matrisi ile girişin çarpımı olarak hesaplanır. Skor hesaplama formülü 3.2'de gösterilmiştir:

$$Skor(t) = v^{T} * \tanh\left(W_1 * h_t + W_2 * s_{t-1}\right) \tag{3.2}$$

Bu formülde h_t mevcut girdi, s_{t-1} önceki durum, v, W_1, W_2 öğrenilebilir ağırlıklar ve tanh aktivasyon fonksiyonudur.

Softmax: Skorlar bir softmax fonksiyonuna sokulur, böylece skorlar olasılıklara dönüşür. Bu, dikkat ağırlıkları olarak adlandırılır.

$$da = \frac{e^{Skor(t)}}{\sum e^{Skor(t)}} \tag{3.3}$$

Bu formüle *'da'* dikkat ağırlığıdır.

Ağırlıklı Toplam Hesaplama: Her bir giriş, ilgili dikkat ağırlığı ile çarpılır ve sonra ağırlıklı girişler toplanır. Bu toplam, girişlerin ağırlıklı bir kombinasyonunu oluşturur ve dikkat mekanizmasının çıktısını oluşturur. Bu yapı 3.4'te formülize edilmiştir.

$$Çıktı = \sum(da * h_t) \tag{3.4}$$

Burada da dikkat ağırlığıdır, h_t ise t. giriş değeridir.

- *Dikkat Ağırlıklarının Uygulanması:* Daha sonra, dikkat ağırlıkları çift yönlü GRU'nun çıktısıyla çarpılır. Bu, modelin belirli adımlara daha fazla "dikkat etmesini" sağlar, çünkü bu adımlar daha büyük bir ağırlığa sahip olacaktır.

Bu aşamalar sonucunda, spektral modülü, hiperspektral görüntülerin spektral özelliklerini çıkarır ve öğrenilmiş dikkat ağırlıklarına göre bu özelliklerin birleşimini sağlar. Bu bileşenler daha sonra mekansal modülün çıktısıyla birleştirilir.

Özetlemek gerekirse, spektral modül, RNN ve dikkat mekanizmasının yardımıyla hiperspektral görüntülerin spektral özelliklerini etkin bir şekilde işleyerek bir sonuç üretir. Bu modül, spektral özelliklerin daha hassas bir biçimde tespit edilmesini sağlar ve böylece modelin genel performansını belirgin şekilde iyileştirir.

3.5. Mekansal Modülün İşlenmesi

Hiperspektral görüntü sınıflandırması, genellikle hem mekansal hem de spektral bilgileri dikkate almayı gerektirir. Mekansal bilgi, görüntünün genel yapısı ve objelerin birbirine olan konumunu temsil ederken, spektral bilgi, her bir pikselin elektromanyetik spektrumu hakkında bilgi sağlar.

Mekansal bilginin işlenmesi konusunda, CNN genellikle öne çıkar. CNN, yerel özelliklerin çıkarılması ve daha yüksek seviyeli özelliklerin oluşturulması için oldukça uygundur. Ayrıca, yerel mekansal ilişkilerde veri kaybını minimumda tutarken, yüksek boyutlu verilerin boyutunu azaltabilme yetenekleri, hiperspektral görüntülerin işlenmesi açısından çok önemli bir özelliktir. Hiperspektral görüntünün mekânsal kısmında CNN yapısının belli başlı sebeplerden dolayı başarılı olduğu görülmüştür. Bunlardan bazıları şu şekildedir:

Sağlamlık: CNN'ler, dönüşüm ve ölçeklendirme değişiklikleri gibi çeşitli giriş değişikliklerinden daha az etkilenir. Bu, aynı sınıfa ait örneklerin farklı görünümlerini modelleyebilme yeteneğini artırır.

Uçtan uca öğrenme: CNN'ler, özellik çıkarımı ve sınıflandırma adımlarını bir arada yapabilir. Bu, modelin tüm öğrenme sürecini optimize eder ve performansı artırır.

Genellenebilirlik: CNN'ler, genellenebilirlik kabiliyeti yüksek modellerdir. Yani, öğrendikleri özellikler ve modeller, başka verilere uygulanabilir ve bu verileri doğru bir şekilde sınıflandırabilir.

Mekansal bilginin işlenmesinde, derin öğrenme modellerinden 2-D CNN kullanılmaktadır. Hiperspektral görüntülerin yüksek boyutlu ve karmaşık yapısını düşündüğümüzde, CNN, özellikle mekansal özelliklerin ayırt edilmesi ve çıkarılmasında başarılıdır.

Bu çalışmada oluşturulan modelin yapısı şu şekildedir:

- *Birinci 2-D CNN katmanı:* Girdi olarak alınan mekânsal veri, 2-D CNN katmanına girdi olarak verilir. Katman 32 filtre kullanır, her filtrenin boyutu 3x3'tür ve ReLU aktivasyon fonksiyonu kullanılır.

ReLU (Rectified Linear Unit) aktivasyon fonksiyonunun matematiksel formülü 3.5'te gösterilmiştir:

$$f(x) = \max(0, x) \tag{3.5}$$

Bu formül, eğer x pozitifse x'in kendisini, eğer x negatifse 0'ı döndürür. Bu, ReLU'nun en önemli özelliği olan 'doğrultma' işlemini gerçekleştirir, yani negatif değerler 0'a çekilir.

ReLU aktivasyon fonksiyonu, özellikle derin öğrenme modellerinde kullanılır çünkü doğrusallığı ve hesaplama verimliliği sayesinde modelin eğitim sürecini hızlandırır.

- *İkinci 2-D CNN katmanı:* Bir önceki evrişim katmanının çıktısı, 2D CNN katmanına girdi olarak verilir. Katman 64 filtre kullanır, her filtrenin boyutu 3x3'tür ve ReLU aktivasyon fonksiyonu kullanılır.

- *Dikkat mekanizması:* Bu adım spektral modüldeki dikkat mekanizmasına benzerlik göstermektedir. İlk olarak, ikinci 2D CNN katmanının çıktısı bir yoğun katmana girdi olarak verilir. Aktivasyon fonksiyonu olarak *'tanh'* kullanılır. Sonra dikkat ağırlıklarını hesaplamak için *'softmax'* fonksiyonu kullanılır. Softmax aktivasyonu, çıktılar arasında bir olasılık dağılımı oluşturur, bu da modelin hangi özelliklere dikkat etmesi gerektiğini belirler. Dikkat vektörü, 2D CNN'nin çıktısının boyutuna uyması için boyutu ayarlanır, böylece 2D CNN'nin çıktısıyla çarpılabilir.

- *Dikkat Ağırlıklarının Uygulanması:* Daha sonra, dikkat ağırlıkları 2D-CNN katmanının çıktısıyla çarpılır. Bu, modelin belirli adımlara daha fazla "dikkat etmesini" sağlar, çünkü bu adımlar daha büyük bir ağırlığa sahip olacaktır.

Bu aşamalar sonucunda, mekânsal modül, hiperspektral görüntülerin mekânsal özelliklerini çıkarır ve öğrenilmiş dikkat ağırlıklarına göre bu özelliklerin birleşimini sağlar. Bu bileşenler daha sonra spektral modülün çıktısıyla birleştirilir.

Özetlemek gerekirse, mekânsal modül, 2D-CNN ve dikkat mekanizmasının yardımıyla hiperspektral görüntülerin mekânsal özelliklerini etkin bir şekilde işleyerek bir sonuç üretir. Bu modül, mekânsal özelliklerin daha hassas bir biçimde tespit edilmesini sağlar ve böylece modelin genel performansını belirgin şekilde iyileştirir.

3.6. Spektral ve Mekansal Modülün Birleştirilmesi

Modelin spektral ve mekânsal katmanlarından elde edilen çıktılar birleştirme modülünde bir araya getirilir. Bu işlem her iki modülden gelen özellik vektörlerinin bir araya getirilmesini sağlar.

Bu birleşmiş çıktı, bir dizi yoğun (Dense) katman ve bırakma (Dropout) katmanı tarafından işlenir.

Yoğun katman, yapay sinir ağı mimarisinde sıklıkla kullanılan bir terimdir. Yoğun katman, ağdaki her bir nöronun her bir girdi öğesiyle bağlantılı olduğu bir tam bağlantılı katmandır. Yoğun katman, her bir girdi öğesinden geçen bilgileri birbirine bağlar ve çıktıları hesaplar. Bu katmanda bulunan nöronlar, girdi öğelerinden alınan değerleri, ağırlıklarla çarparak ve bir aktivasyon fonksiyonundan geçirerek işlerler. Bizim kullandığımız yoğun katmanlarda kullanılan aktivasyon fonksiyonu ReLU'dur. Bu işlem, bir girdi vektörünü, çıktı vektörüne dönüştürür.

Bırakma katmanı, yapay sinir ağlarında kullanılan bir düzenlileştirme tekniğidir. Bırakma katmanı, ağdaki bazı nöronların rastgele olarak "atılması" veya "bırakılması" anlamına gelir. Bu, her eğitim iterasyonunda bir nöronun belirli bir olasılıkla pasif hale getirilerek, o nöronun çıktılarının göz ardı edilmesini sağlar. Bırakma, aşırı öğrenme sorununu azaltmaya yardımcı olur. Eğitim sırasında, bırakma katmanı kullanılarak ağın farklı alt kümeleriyle eğitim yapılır ve böylece aşırı uyumun önüne geçilir.

İlk yoğun katman 512 nöron içerir ve ReLU aktivasyon fonksiyonunu kullanır. Bu katmandan elde edilen çıktı, aşırı öğrenmenin önlenmesi için bırakma katmanına sokulur. %40 oranda nöronları "kapatır", yani bu nöronların ağırlıklarını geçici olarak sıfırlar. Bırakma katmanının değerinin normalde kullanılan %50 değerinden %40'a çekilmesinin başlıca sebebi daha hızlı eğitim ve daha az bilgi kaybıdır. Daha az nöronun kapatılması, daha az bilginin yok olması demektir ve ayrıca daha az işlem ve kaynak tüketimi sağlar. %40 değeri bir çok veri kümesinde çeşitli değerlerin kullanıldıktan sonra en verimli değer olarak belirlenmiştir.

Bu işlem, ikinci yoğun katman ve bırakma katmanı ile tekrarlanır. İkinci yoğun tabaka 256 nöron içerir.

Son olarak, modelin çıktı katmanı bir yoğun katmandır ve çıktı boyutuna karşılık gelen sayıda nöron içerir. Çıktı boyutu veri kümesinden veri kümesine değişiklik göstermektedir. Bu katmanda softmax aktivasyon fonksiyonu kullanılır.

Bu model, spektral ve mekânsal girdileri alır ve çıktı olarak sınıflandırma sonuçlarını verir. Her iki modülün çıktılarının birleştirilmesi, modelin hem spektral hem de mekânsal bilgileri eşzamanlı olarak işlemesini ve hiperspektral görüntülerin daha kapsamlı bir analizini sağlar. Bu, modelin genel sınıflandırma performansını iyileştirir.

4. BULGULAR

Bu bölümde 3. Kısımda anlatılmış olan modelin hiperspektral veri kümeleri üzerindeki çalışma detayları, test verileri, test sırasında kullanılan metrikler ve test sonuçları incelenmiştir.

4.1. Değerlendirme Metrikleri

Bu çalışmada, 27 × 27'lik mekânsal bölümler, anlatılan 4 veri kümesi için ağın girdisi olarak kullanılır. Deneysel epokların sayısı 100 olarak ayarlanır. Öğrenme hızı, 0,001 olarak verilmiştir. Kayıp (Decay) fonksiyonu 0,06 olarak seçilir. Ayrıca, deneyde kullanılan optimizasyon yöntemi Adam'dır. Karşılaştırma için son yıllarda yoğun ilgi gören derin öğrenme tabanlı HSI sınıflandırma yöntemleri seçilmiştir. Nicel analiz için F1 puanı (F1 Score), genel doğruluk (OA), ortalama doğruluk (AA) ve Kappa katsayısı olmak üzere dört değerlendirme metriği kullanılmıştır.

4.1.1. F1 Puanı

F1 puanı, bir sınıflandırma modelinin performansını ölçen bir metriktir. F1 skoru, hassasiyet (precision) ve geri çağırma (recall) değerlerinin harmonik ortalamasını temsil eder.

Hassasiyet, doğru pozitif tahminlerin toplam pozitif tahminlere oranını gösterir. Yani, gerçek pozitiflerin ne kadarının doğru bir şekilde tanımlandığını gösterir. Hassasiyet, yanlış pozitif tahminlerin az olmasını hedefler.

Geri çağırma, gerçek pozitiflerin toplam pozitif örneklerin yüzdesini ifade eder. Yani, gerçek pozitiflerin ne kadarının doğru bir şekilde tespit edildiğini gösterir. Geri çağırma, yanlış negatif tahminleri minimize etmeyi amaçlar.

F1 skoru, hem hassasiyeti hem de geri çağırma değerini dikkate alarak bir denge sağlar. Bu, modelin hem yanlış pozitifleri hem de yanlış negatifleri minimize etme amacını yansıtır. F1 skoru, 4.1'de formülize edilmiştir.

$$F_1 = 2 * \frac{h*g}{h+g} \quad (4.1)$$

Formülde h değeri hassasiyeti, g değeri ise geri çağırmayı temsil eder. *F1* skoru 0 ile 1 arasında değer alır, 1 en iyi performansı temsil ederken 0 en kötü performansı gösterir. *F1* skoru ne kadar yüksekse, modelin sınıflandırma performansı o kadar iyidir.

4.1.2. Genel Doğruluk (OA)

Bu metrik, bir modelin tüm tahminlerinin ne kadar doğru olduğunu gösterir. Matematiksel olarak, doğru tahminlerin toplam tahminlere oranıdır. Yani, bir modelin yüzde 80 genel doğruluğu varsa, bu modelin tahminlerinin yüzde 80'inin doğru olduğunu söyleriz. Ancak, genel doğruluk metriği, bir sınıfın örneklerinin sayısı diğer sınıflardan çok daha fazla olması durumu gibi dengesiz veri kümelerinde yanıltıcı olabilir. Genel doğruluk 4.2'de formülize edilmiştir.

$$OA = \frac{T}{S} \quad (4.2)$$

Bu formülde T doğru sınıflandırılan örnekleri temsil eder, S ise toplam örnek sayısını temsil eder.

4.1.3. Ortalama Doğruluk (AA)

Ortalama doğruluk, her sınıf için doğruluk oranını hesaplar ve bu değerlerin ortalamasını alır. Bu metrik, dengesiz veri kümelerinde genel doğruluk metriğinin sınıf dengesizliği problemine bir alternatif olarak düşünülebilir. Çünkü her sınıf için ayrı ayrı doğruluk oranını hesaplar ve bu oranların ortalamasını alır. Ortalama doğruluk metriğinin formülü 4.3'te gösterilmiştir.

$$AA = \frac{1}{C} * \sum_1^C \frac{T_i}{S_i} \quad (4.3)$$

C, toplam sınıf sayısı

T_i, i. sınıfın doğru sınıflandırılan örneklerinin sayısı

S_i, i. sınıfa ait toplam örnek sayısı

4.1.4. Kappa Katsayısı

Puanlayıcılar arası güvenirlik belirlemede sıklıkla kullanılan Kappa katsayısı [29], 1960 yılında Jacob Cohen tarafından önerilmiştir. Sınıflama düzeyinde puanlama yapan iki puanlayıcı arasındaki uyumun derecesini belirlemek için geliştirilmiştir. Kappa katsayısının formülü 4.4'te gösterilmiştir.

$$\kappa = (P_o - P_e) / (1 - P_e) \quad (4.4)$$

Burada,

- P_o, gözlenen anlaşma oranıdır. Yani, iki değerlendirici arasındaki toplam durumların yüzdesidir.
- P_e, beklenen anlaşma oranıdır. Bu, iki değerlendiricinin tamamen rastgele seçim yaptığı durumda beklenen anlaşma yüzdesini ifade eder.

Kappa katsayısı 1'e yaklaştıkça, anlaşma daha iyi olur. 0'a yaklaştıkça, anlaşma rastgelelikle aynı seviyeye düşer. Negatif değerler genellikle değerlendiriciler arasında anlaşmazlık olduğunu gösterir.

4.2. Performans Analizi

Bu çalışmanın performansını test etmek ve karşılaştırmak adına, son yıllarda yapılan başlıca çalışmalar arasında RF, SVM, RNN, LSTM, CNN-2D, CNN-3D ve HybridSN dikkate alınmıştır ve deneysel sonuçları karşılaştırmak için kullanılmıştır. Karşılaştırma yapılan modeller şunlardır; Hiperspektral verilerin rastgele orman ile sınıflandırılması [30], Hiperspektral Uzaktan Algılama Görüntülerinin SVM ile Sınıflandırılması [7], (Support Vector Machines - SVM), hiperspektral görüntü sınıflandırma için Tekrarlayan Sinir Ağları [31] (RNN), Uzun Kısa Süreli Bellek [4] (LSTM), Hiperspektral Veri Sınıflandırması için Konvolüsyonel Sinir Ağları ile Derin Gözetimli Öğrenme [32] (CNN-2D), Uzaktan Algılama Görüntü Sınıflandırması için 3-D Derin Öğrenme Yaklaşımı [33] (CNN-3D), Hiperspektral görüntü sınıflandırması için 3-D-2-D CNN özellik hiyerarşisini keşfetme [34].

Hiperspektral görüntü sınıflandırmasında, hiperspektral görüntülerin zor elde edilmesi, yüksek boyutları ve düşük etiketli veri değerleri sebebiyle modellerin düşük eğitim oranlarıyla bile belli bir başarı elde etmesi önemli bir etkendir. Düşük eğitim oranlarıyla bile belli bir başarı elde

edilmesi, çalışmanın güçlü ve genelleştirilebilir özelliklerini vurgular. Bu sebeplerden dolayı öncelikle önerilen model %1 ve %5'lik düşük eğitim oranlarıyla test edilmiştir.

Tablo 4.1'de IP veri kümesi için %5'lik bir eğitim oranı kullanılıp sonuçları paylaşılmıştır. IP veri kümesinin boyutunun küçük olması, %5'lik kısmının eğitim için aslında yetersiz bir veri olduğunu gösterir. Buna ragmen önerilen model %70 gibi başarı oranlarına ulaşmıştır.

Tablo 4.1: IP veri kümesi için %5 eğitim oranıyla elde edilen sonuçlar

Sınıf	**Model (%5)**
1	63.64
2	68.39
3	69.48
4	49.40
5	75.74
6	69.63
7	46.81
8	99.57
9	63.83
10	78.51
11	83.50
12	65.90
13	82.57
14	90.85
15	69.29
16	50.41
OA	77.79
AA	74.45
K(x100)	68.06

Tablo 4.2'de PU veri kümesi için %1 ve %5'lik eğitim oranlarıyla elde edilen sonuçlar sunulmuştur. PU veri kümesinin IP veri kümesine göre boyutunun büyük olması %5'lik eğitim oranıyla alınan sonuçların yüzdesini oldukça arttırmıştır. PU veri kümesinde %5'lik eğitim oranıyla %95'lerin üzerine çıkan doğruluk oranları önerilen modelin düşük eğitim oranıyla bile yüksek bir başarı oranı sağladığını göstermektedir.

Tablo 4.2: PU veri kümesi için %1 ve %5'lik eğitim oranlarıyla alınan sonuçlar

Sınıf	**Model (%1)**	**Model (%5)**
1	81.45	96.82
2	97.25	99.74
3	58.62	90.08
4	59.56	94.98
5	93.05	99.12
6	82.75	99.67
7	76.88	96.86
8	64.65	90.82
9	66.58	96.76
OA	84.51	97.54
AA	79.46	96.09
K(x100)	74.84	97.52

Tablo 4.3'te KSC veri kümesinde %1 ve %5'lik eğitim oranlarıyla önerilen modelin elde ettiği sonuçlar sunulmuştur. KSC veri kümesi, diğer veri kümelerine göre arazi sınıflarının çok ayrık olarak bulunduğu bir veri kümesidir. Bu KSC veri kümesinde kullanılan modellerin başarı oranını düşüren önemli bir ayrıntıdır.

Tablo 4.3: KSC veri kümesi için %1 ve %5'lik eğitim oranlarıyla alınan sonuçlar

Sınıf	**Model (%1)**	**Model (%5)**
1	68.76	92.81
2	48.62	88.14
3	42.23	87.82
4	33.33	81.97
5	70.05	83.60
6	44.24	94.52
7	40.00	88.14
8	66.23	95.70
9	40.41	95.69
10	64.50	90.72
11	66.04	94.40
12	75.37	96.23
13	88.91	99.94
OA	65.90	93.58
AA	61.45	92.86
K(x100)	54.94	91.80

Düşük test oranlarında elde edilen başarı, modelin eğitim sürecinde aşırı öğrenme problemiyle etkili bir şekilde başa çıktığını gösterir. Aşırı öğrenme, bir modelin eğitim verisini aşırı derecede öğrenmesi ve bu yüzden yeni, görülmemiş verilere etkili bir şekilde genelleştirilememesi durumudur. Ancak, model düşük test oranlarında bile yüksek doğrulukta sonuçlar veriyorsa, bu modelin verileri aşırı öğrenme sorunu olmadığını göstermektedir. Düşük eğitim oranlarıyla verilen sonuçlar göstermektedir ki önerilen modelin aşırı öğrenme sorunu bulunmamaktadır. Bunun temel sebepleri, spectral ve mekansal modüllerde kullanılan dikkat mekanizmaları ve titizlikle belirlenen bırakma (dropout – 0.4) oranıdır.

Karşılaştırma yapılan çalışmalar RF ve SVM hariç, CNN ve RNN yapılarına dayalıdır ve dört temel HSI veri kümesi olan IP, PU, KSC ve SA veri kümesi üzerinde değerlendirilmiştir. Bu karşılaştırma, önerilen modelin popüler derin öğrenme metotlarıyla karşılaştırılması için yapılmıştır. Karşılaştırma yapılan modellerin eğitim oranı %15'tir. Bu çalışmada önerilen modelin eğitim oranı için ise söz konusu sonuçlardan daha düşük bir eğitim oranı olan %10'luk bir değer belirlenmiştir. Önerilen modelin eğitim oranının karşılaştırılan modellerden daha

düşük olmasının sebebi daha düşük bir eğitim oranıyla bile karşılaştırılan modellere üstünlük sağlayabileceğinin gösterilmesidir.

Burada, elde edilen sonuçlar üzerinde deneysel sonuçlar listelenmiştir. Dağıtılmış eğitim ve test örneklerine yönelik elde edilen sınıflandırma başarısı IP, PU, KSC ve SA veri kümelerinde karşılaştırılmıştır. Sırasıyla Tablo 4.4, 4.5, 4.6 ve 4.7'de karşılaştırma sonuçları gösterilmiştir. Bu çalışmada önerilen modelin sonuçları, F1 skoru, OA, AA ve kappa (κ) doğruluk oranları kullanılarak karşılaştırılmıştır. Her bir arazi sınıfı için F1 skorları ayrı ayrı verilmiştir.

Tablo 4.4: IP veri kümesi için karşılaştırma sonuçları

Sınıf	RF [30]	SVM [7]	RNN [31]	LSTM [4]	CNN-2D [32]	CNN-3D [33]	HybridSN [34]	Önerilen Model
1	85.33	88.0	58.4	89.6	73.64	48.18	82.66	**97.37**
2	55.11	80.0	75.5	82.22	83.12	85.12	82.17	**97.13**
3	22.77	69.55	63.37	64.16	81.98	77.22	76.73	**96.70**
4	13.13	48.48	29.49	55.35	46.39	85.11	33.33	**98.52**
5	41.6	87.23	87.59	89.27	89.11	80.28	81.14	**95.91**
6	94.06	96.33	95.31	96.39	95.02	89.81	97.36	**98.33**
7	0.0	50.0	0.0	0.0	0.0	0.0	0.0	**65.57**
8	91.33	**100.0**	99.52	99.2	99.96	95.96	96.53	98.91
9	40.0	50.0	56.0	76.0	26.66	77.78	66.66	**100.0**
10	26.83	76.54	71.13	81.51	77.44	77.9	74.35	**98.72**
11	81.06	87.7	78.86	80.4	89.4	82.73	79.18	**99.13**
12	28.95	77.3	71.91	76.31	87.72	82.64	71.04	**99.12**
13	96.25	97.5	97.0	97.25	95.28	89.72	96.25	**99.44**
14	91.07	91.38	90.28	94.13	**98.84**	98.32	91.68	98.76
15	10.10	80.81	75.56	90.71	82.02	55.17	45.45	**96.49**
16	71.96	**97.73**	88.64	94.09	80.0	82.5	84.09	97.50
OA	77.44	77.8	89.09	92.55	92.99	93.8	80.86	**98.14**
AA	80.18	86.12	89.5	89.94	92.98	92.68	72.41	**96.11**
K (x100)	70.44	72.06	85.5	89.9	90.98	91.69	78.24	**98.16**

Tablo 4.4'te IP veri kümesi için önerilen modelin diğer modeller ile karşılaştırılması yapılmıştır. IP veri kümesindeki her bir arazi sınıfı için ayrı ayrı F1 skorları dahil olmak üzere, OA, AA ve kappa doğruluk oranları verilmiştir. Tablo 4.4'te verilen karşılaştırmaya göre bazı arazi sınıflarında çok düşük ortalamalar alındığı görülmüştür. Bunun en belirgin örneği 7

numaralı arazi sınıfı olan *'Soybean Notill'* arazi sınıfıdır. Bunun sebebi bu veri kümesinde söz konusu arazi sınıfının etiketli veri sayısının diğer sınıflara göre çok düşük olmasıdır. IP veri kümesi için önerilen model, karşılaştırılan modellere göre çok daha iyi bir sınıflandırma performansı sağlamıştır.

Şekil 4.1'de IP veri kümesi için önerilen modelin eğitimi sırasında epoklara göre hata ve doğruluk grafikleri verilmiştir. %10'luk bir eğitim oranıyla modelin IP veri kümesinde doğruluk oranı yaklaşık 60 epokta %90'nın üzerinde doğruluk değerlerine ulaşmıştır.

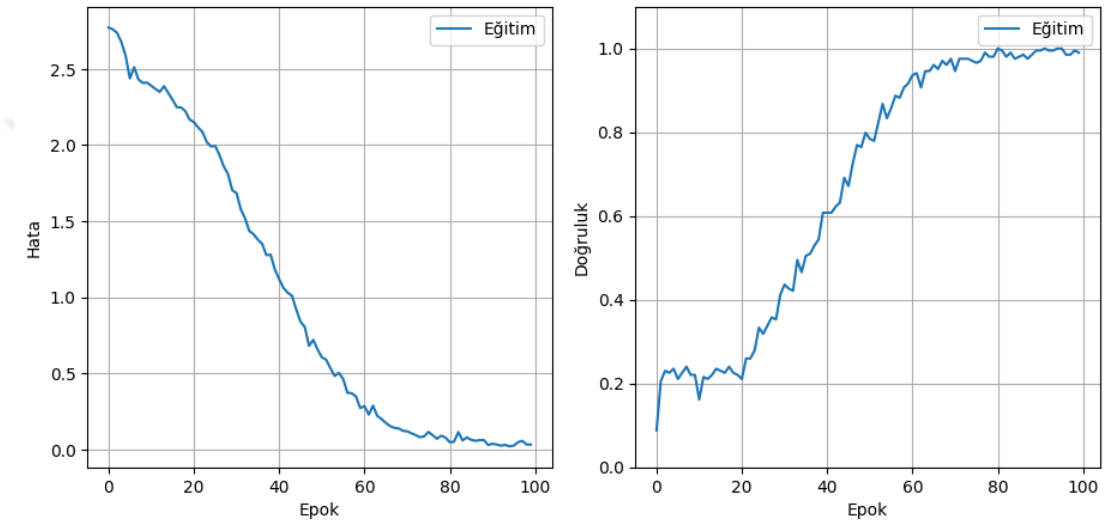

Şekil 4.1: IP veri kümesi için epoklara göre hata ve doğruluk grafikleri

Tablo 4.5'te PU veri kümesinde karşılaştırmalı sonuçlar verilmiştir.Bu tabloya bakacak olursak, bu veri kümesinde, oluşturulan model, sırasıyla %96.09, %97.54 ve %97.52 olan en yüksek ortalama, genel ve kappa (κ) doğruluğuna sahiptir ve diğer metotlardan yüksek bir başarı oranına sahiptir.

Tablo 4.5'teki modellerin başarı oranlarına bakacak olursak, benzer mekansal yapıya sahip arazi sınıflarındaki başarı oranlarının düşük çıktığı görülmüştür. PU veri kümesinde 2 ve 6 numaralı arazi sınıfları buna örnek olarak verilebilir. Buna rağmen bu çalışmada önerilen modelimiz bu alanlarda da %90 üzerinde sınıflandırma başarısına erişebilmiştir. Bu durum önerilen modelin benzer yapıdaki sınıfları birbirinden ayırt etme konusunda diğer yaklaşımlardan daha başarılı olduğunu göstermektedir.

Tablo 4.5: Pavia Üniversitesi veri kümesi için karşılaştırma sonuçları

Sınıf	RF [30]	SVM [7]	RNN [31]	LSTM [4]	CNN-2D [32]	CNN-3D [33]	HybridSN [34]	Önerilen Model
1	89.98	82.23	83.08	82.63	93.40	85.66	89.74	**96.82**
2	74.39	65.81	67.90	78.74	96.84	95.88	81.78	**99.74**
3	38.42	66.72	65.17	60.73	65.48	68.11	82.88	**90.08**
4	**98.24**	97.77	90.72	97.10	95.55	97.02	83.66	94.98
5	95.98	99.37	99.23	99.28	98.03	98.90	**99.94**	99.12
6	51.43	91.62	85.07	65.94	80.52	68.85	72.43	**99.67**
7	80.63	87.36	82.94	84.95	89.29	73.09	96.16	**96.86**
8	**97.64**	90.46	85.85	88.89	94.50	95.21	92.80	90.82
9	94.92	93.71	94.52	**98.29**	95.80	93.54	94.04	96.76
OA	77.44	77.80	77.07	80.38	92.55	89.43	84.18	**97.54**
AA	80.18	86.12	83.83	84.06	89.94	86.25	88.16	**96.09**
K(x100)	70.44	72.06	70.84	74.32	89.90	85.61	79.13	**97.52**

Şekil 4.2'de PU veri kümesi için önerilen modelin epoklara göre hata ve doğruluk grafikleri verilmiştir. IP veri kümesi gibi yine PU veri kümesinde de %90 civarında doğruluk oranlarına 60. Epok civarı ulaşıldığı görülmüştür. Bu durum hem modelin aşırı öğrenmeye karşı dayanıklı olduğunu hem de düşük oranda ve sayıda eğitim ile yüksek sınıflandırma başarısına çıkabildiğini göstermektedir.

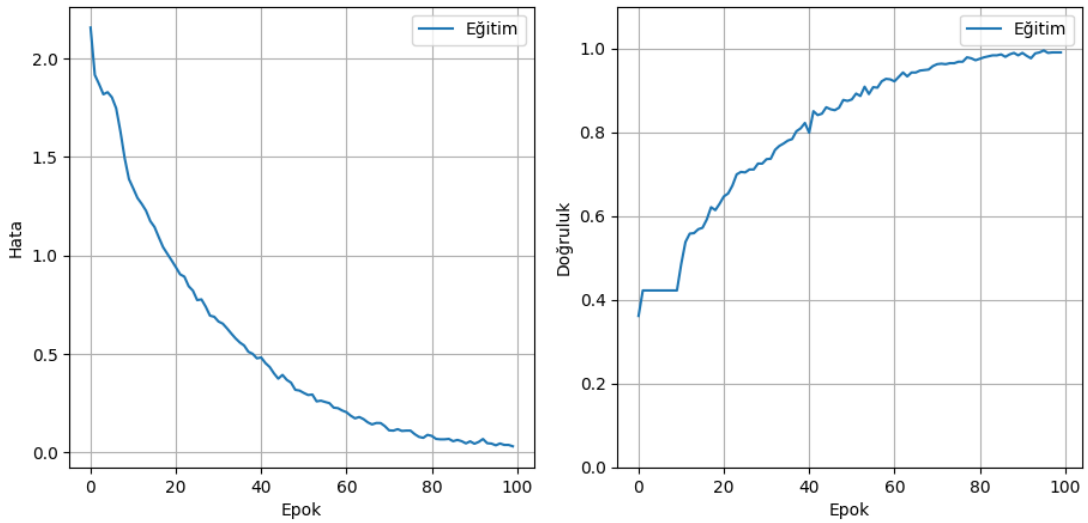

Şekil 4.2: PU veri kümesi için epoklara göre hata ve doğruluk grafikleri

Tablo 4.6'da KSC veri kümesi için önerilen model ile karşılaştırılan modellerin, her bir arazi sınıfı için F1 skorları ve OA, AA, kappa doğruluk oranları verilmiştir. KSC veri kümesi için önerilen model yine %90'ların üzerinde doğruluk oranları vermiştir. KSC veri kümesi, ayrık arazi örtüsü sınıfları içeren bir veri kümesidir. HybridSN diğer veri kümelerinin aksine bu veri kümesinde yüksek bir başarı oranına ulaşmıştır. Ancak HybridSN'in yoğun ve yüksek parametreli yapısı, bu veri kümesinin büyüklüğü de göz önünde bulundurulduğunda, bu veri kümesi için çok yüksek kaynak tüketimi ve uzun süreli bir eğitim süresine sahiptir. Eğitim süresi ve test süresi önerilen model için sırasıyla 44.15sn ve 1.5sn'dir. HybridSN için ise bu değerler 181.34sn ve 7.5sn'dir. Hiperspektral görüntülerin büyüklüğü ve yüksek spektral bant sayısı göz önünde bulundurulduğunda sınıflandırma modelinin az parametreli ve hızlı çalışması bu konuda önemli bir etkendir ve bu alanda önerilen model, düşük kaynak tüketimi ve hızlı eğitim ve test süresine sahiptir. Bunlarla beraber yine de %90 civarında sınıflandırma başarısı sağlayabilmektedir.

Tablo 4.6: KSC veri kümesi için karşılaştırma sonuçları

Sınıf	RF [30]	SVM [7]	RNN [31]	LSTM [4]	CNN-2D [32]	CNN-3D [33]	HybridSN [34]	Önerilen Model
1	99.69	94.13	87.33	92.22	85.52	97.17	**100.0**	97.82
2	98.38	00.0	63.12	81.64	67.31	92.91	**100.0**	90.49
3	99.23	54.59	69.72	75.38	60.09	81.04	**99.69**	92.80
4	88.16	17.28	47.82	58.09	45.17	44.54	**99.53**	81.62
5	73.72	0.00	68.37	74.21	67.40	85.15	**98.78**	95.93
6	88.88	0.00	56.24	65.12	65.47	62.74	**100.0**	**100.00**
7	**100.0**	0.00	83.52	90.26	77.15	80.52	97.75	59.02
8	85.51	60.10	65.57	71.40	64.75	71.49	**99.90**	88.78
9	96.68	89.37	88.39	90.72	89.22	98.94	**100.0**	93.54
10	99.22	98.83	92.42	88.92	73.08	90.67	**100.0**	96.22
11	**100.0**	94.94	83.89	90.26	87.55	97.56	96.34	99.13
12	97.89	89.25	81.31	87.46	82.48	**99.30**	99.06	97.12
13	**100.0**	**100.0**	99.88	**100.0**	99.92	**100.0**	**100.0**	99.09
OA	96.17	72.84	81.47	86.10	79.98	89.71	**99.48**	94.87
AA	94.41	53.73	75.96	81.97	74.24	84.77	**99.31**	91.05
K(x100)	95.74	69.29	79.33	84.51	77.63	88.51	**99.43**	94.28

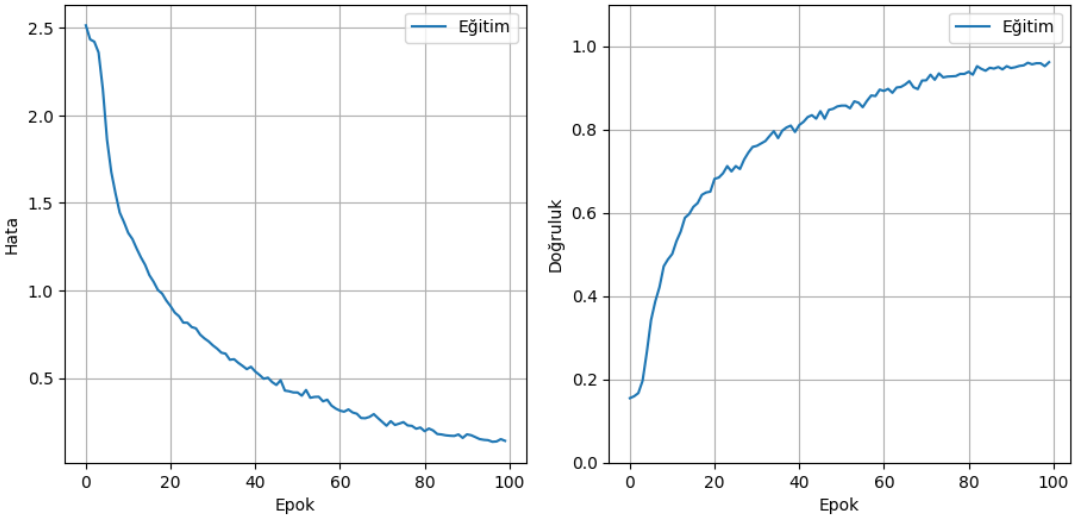

Şekil 4.3: KSC veri kümesi için epoklara göre hata ve doğruluk grafikleri

Şekil 4.3'te KSC veri kümesi için önerilen modelin epoklara göre hata ve doğruluk grafikleri verilmiştir. IP ve PU veri kümelerinin aksine KSC veri kümesinde %90 civarı sınıflandırma başarısına 70. Epoka doğru ulaşıldığı görülmüştür. KSC veri kümesinin ayrık arazi sınıfı örtüsü ve büyük boyutu bunun başlıca sebeplerindendir. Ancak yine de bu zorlu veri kümesinde dahi %10'luk bir eğitim oranıyla %90 sınıflandırma başarısına ulaşmak, modelin farklı ve zorlu veri kümelerinde bile başarılı olduğunu göstermektedir.

Tablo 4.7'de Salinas veri kümesi için önerilen model ile diğer modellerin her bir arazi sınıfı için F1 skoru ve OA, AA ve kappa doğruluk oranları verilmiştir. Salinas veri kümesinin arazi sınıfları PU veri kümesindeki *'Meadows'* ve *'Bare Soil'* arazi sınıflarının birbirine benzemesi gibi çok sayıda arazi sınıfının birbirine benzerlik gösterdiği bir veri kümesidir. Buna rağmen yine bu çalışmada önerilen model %90'lara ulaşan doğruluk oranlarına çıkmayı başarmıştır.

Tablo 4.7: Salinas veri kümesi için karşılaştırma sonuçları

Sınıf	RF [30]	SVM [7]	RNN [31]	LSTM [4]	CNN-2D [32]	CNN-3D [33]	HybridSN [34]	Önerilen Model
1	82.87	82.34	82.22	82.76	82.25	82.10	82.74	**96.65**
2	82.51	83.36	82.87	80.19	84.15	84.14	90.91	**91.30**
3	64.09	**99.80**	99.72	99.68	90.31	77.85	98.81	87.70
4	92.04	**98.96**	93.50	91.23	87.24	89.24	83.96	89.82
5	**99.81**	98.77	97.76	97.65	99.51	98.97	99.46	96.41
6	96.27	97.90	95.10	97.06	96.43	98.91	98.60	**99.46**
7	86.19	77.43	81.40	78.88	86.44	85.48	75.62	**95.96**
8	41.69	60.30	40.06	40.11	70.03	62.06	93.16	**95.56**
9	86.02	76.77	76.54	81.55	79.53	80.81	81.39	**97.81**
10	36.00	61.29	47.44	47.37	60.22	54.75	76.51	**89.15**
11	64.67	80.55	76.24	76.38	82.93	66.78	**89.21**	74.34
12	67.27	79.92	76.33	79.98	92.87	93.83	**96.28**	85.59
13	**89.23**	70.88	69.12	71.37	86.21	82.34	86.78	84.04
14	**100.0**	**100.0**	**100.0**	99.11	98.92	96.31	**100.0**	85.13
15	90.06	96.41	97.59	**98.14**	77.63	75.85	100.0	93.56
16	74.23	81.45	79.64	75.34	87.43	84.12	**97.00**	66.78
OA	75.38	81.86	77.95	78.16	83.27	80.24	88.31	**92.50**
AA	78.58	84.31	81.06	81.43	84.98	81.96	**90.23**	89.72
K(x100)	73.49	80.43	76.23	76.52	81.89	78.62	87.33	**91.65**

Şekil 4.4'te SA veri kümesi için önerilen modelin epoklara göre hata ve doğruluk grafikleri verilmiştir. SA veri kümesi de KSC gibi diğerlerine göre yine büyük veri kümelerindendir. Ayrıca SA veri kümesi iç içe geçmiş ve benzer özellikteki arazi sınıflarını barındıran bir veri kümesidir. Bu veri kümesinin zorlu yapısına rağmen yine önerilen model yine %90 üzerinde bir sınıflandırma başarısı yakalamıştır.

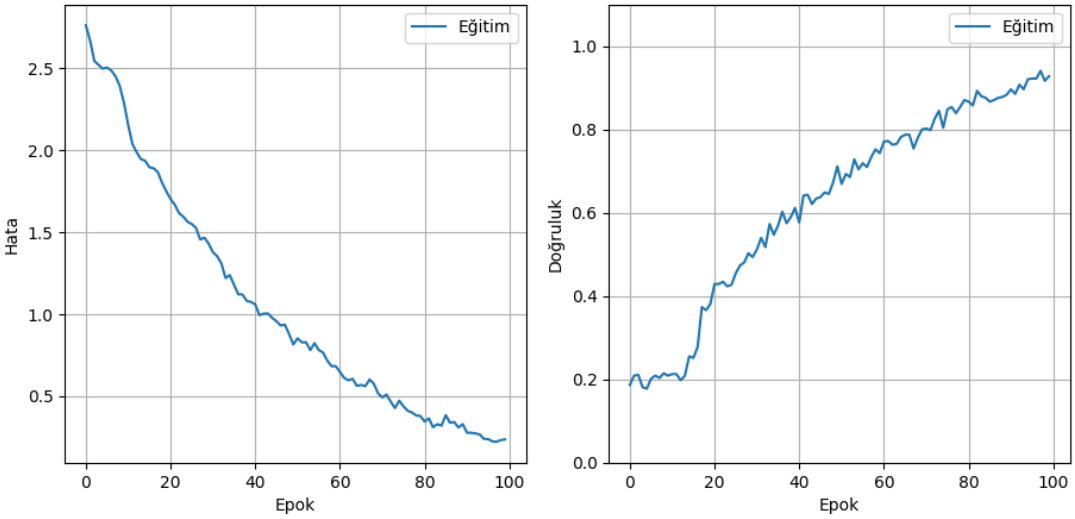

Şekil 4.4: SA veri kümesi için epoklara göre hata ve doğruluk grafikleri

Tablo 4.4, 4.5, 4.6, 4.7'deki sonuçlara bakılacak olursa bu çalışmada önerilen modelin düşük boyutlu veriler, az etiketli yer örnekleri, ve az korelasyonlu toprak yapıları bile göz önüne alındığında her zaman %90'ların üzerinde sonuç verdiği görülmüştür. KSC gibi sadece bazı veri kümelerinde çok başarılı olan HybridSN gibi modellerin aksine oluşturulan hibrit model her veri kümesinde belli başarı oranlarının üzerinde seyretmiştir. Görüntü işleme ve sınıflandırma alanlarındaki istikrarlılık metriğinin önemi göz önünde bulundurulduğunda bu çalışmada önerilen modelin kayda değer bir başarı elde ettiği görülmektedir.

5. TARTIŞMA

Bu tez çalışmasında, tekrarlayan sinir ağları ve evrişimli sinir ağları kullanılarak, hiperspektral görüntüleri sınıflandıran bir model önerilmiştir. Modelin başarısı, IP, PU, SA ve KSC veri kümelerinde test edilmiştir. Sonuçlar, modelin bu veri kümelerinde yüksek oranda sınıflandırma başarısı sağladığını göstermiştir.

Modelin doğruluk oranları, özellikle düşük sayıda örneklem ve yüksek korelasyonlu sınıflarda bile %90'ın üzerindedir. Bu oranlar, önerilen modelin, HybridSN gibi belli veri kümelerinde başarılı olan modellerin aksine tüm veri kümelerinde belli bir başarı oranı yakaladığını göstermektedir. Bu durum, özellikle diğer çalışmaların genellikle zorlandığı veri kümeleri, arazi sınıfları ve düşük sayıda örneklem bulunan durumlar için de geçerlidir.

Önerilen modelin belli bir oranın üzerinde başarı göstermesi, RNN ve CNN'nin bir arada kullanılmasından gelmektedir. CNN, özellikle hiperspektral görüntülerde bulunan karmaşık desenler ve yapılar gibi yerel özelliklerin tespiti ve sınıflandırılmasında başarılıdır. Öte yandan, RNN, hiperspektral görüntü sınıflandırmasında önemli bir rol oynayan uzun vadeli bağımlılıklar ve sıralı verilerin işlenmesinde iyi sonuçlar elde etmektedir. Bu iki yaklaşımın birleştirilmesi, önerilen modelin hiperspektral görüntülerin daha iyi sınıflandırılmasını sağlamaktadır. Bu çalışmada kullanılan hibrit model, tek bir yaklaşım kullanan [31] gibi modellerden daha üstün olduğunu göstermiştir. [31] çalışmasında kullanılan ve Pavia Üniversitesi, Houston gibi yüksek etiketli ve boyutlu veri kümelerinde verimli çalışan RNN modelleri, düşük boyutlu ve düşük spektral korelasyonlu veri kümelerinde düşük sonuçlar vermektedir.

Aynı zamanda yine sadece CNN kullanan modeller, yüksek spektral bant sayısı olan veri kümelerinde yeterli performans gösterememiştir. Bu çalışmada kullanılan yapı hem spektral verinin RNN ile yüksek verimlilikle sınıflandırılmasını hem de mekânsal verinin CNN kullanılarak daha verimli sınıflandırmasını sağlamıştır. Aynı zamanda hem spektral hem mekânsal kısımda dikkat mekanizmaları kullanılarak hem verinin kaynak tüketimini hem de performansı arttırmıştır.

Ayrıca, modelin sınıflandırma doğruluk oranının, IP, PU, SA ve KSC gibi farklı veri kümelerinde belli bir oranın üzerinde olduğu görülmüştür. Bu durum, önerilen modelin farklı karakteristikteki verilerde benzer oranlarda başarı sağlayabildiğini göstermiştir.

Sonuç olarak, bu tezde önerilen hibrit model, hiperspektral görüntü sınıflandırılmasında başarılı bir görüntü çizmektedir. Yüksek doğruluk oranları ve genelleştirme kabiliyeti, modelin bu alandaki mevcut tekniklerle rekabet edebileceğini veya onları aşabileceğini göstermektedir. Bu sonuçlar, modelin gelecekteki araştırmalar ve uygulamalar için değerli bir kaynak olabileceğini gösterir.

6. SONUÇ VE ÖNERİLER

Hiperspektral görüntüler, bir sahnenin veya bir nesnenin çok geniş bir dalga boyu aralığında yüzlerce veya binlerce spektral bant üzerinden görüntüler elde edilmesiyle oluşan görüntülerdir. Hiperspektral görüntüler, 3 boyutlu bir veri küpü olarak düşünülebilir. Bu *'çok boyutluluk'*, hiperspektral görüntülerin birçok uygulamasında önemli bir rol oynar. Ancak, aynı zamanda bu tür verilerin analizini ve işlenmesini de zorlaştırır, çünkü büyük miktarda veri ve karmaşık algoritmalar gerektirir. Bu çalışmada hiperspektral görüntülerin gerçek dünya uygulamalarındaki yerinden ve öneminden bahsedilmiştir. Hiperspektral görüntülerin sınıflandırılmasının zorlukları ve bu zorlukların giderilmesi için geliştirilen yöntemler irdelenmiştir. Hiperspektral görüntülerin sınıflandırılmasında geleneksel yöntemler, boyut azaltma teknikleri, derin öğrenme modelleri, dikkat mekanizması ve bu alanda kullanılan diğer yaklaşımlar değerlendirilmiştir.

Bu tez çalışması, hiperspektral görüntülerin sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini ve potansiyelini göstermeyi amaçlamıştır. Son yıllarda popüler bir çalışma alanı olan hiperspektral görüntü sınıflandırma konusunda mevcut zorluklardan ve son yıllarda önerilen araştırmalardan bahsedilmiştir. Bu zorluklar göz önünde bulundurularak, hiperspektral verilerin spektral ve mekânsal bölümlerini ayrı ayrı değerlendiren, CNN, RNN ve dikkat mekanizmaları içeren bir model önerilmiştir. Spektral ve mekansal özelliklerin ayrı ayrı ele alınması, hiperspektral görüntülerin daha doğru ve etkin bir şekilde sınıflandırılmasını sağlamıştır. Farklı özellikteki veri kümelerinden alınan tüm sonuçlarda sınıflandırma başarısı oranı %90'ların üzerinde seyretmiştir. Karşılaştırma için kullanılan başarım metrikleri F1 skor, OA, AA ve kappa katsayısıdır. Ayrıca hiperspektral görüntülerdeki düşük etiketli veri oranı da göz önünde bulundurulup, önerilen modelin düşük eğitim oranlarıyla alınan sonuçları da

değerlendirilmiştir. Önerilen modelin, düşük eğitim oranlarıyla bile iyi bir sınıflandırma başarısı sağladığı görülmüştür.

Hiperspektral görüntü sınıflandırması alanında bundan sonra hiperspektral görüntülerin bant sayıları, mekânsal çözünürlükleri ve boyutları artacağı göz önünde bulundurulduğunda sınıflandırma başarım oranları kadar düşük kaynak tüketimi ve hızlı sınıflandırma gibi özelliklerin önemi artacağı düşünülmektedir.

KAYNAKLAR

[1] Goetz, A. F., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging spectrometry for earth remote sensing. *Science*, 228(4704), 1147-1153.

[2] Landgrebe, D. (2002). Hyperspectral image data analysis. IEEE Signal processing magazine, 19(1), 17-28.

[3] Bellman, R., & Kalaba, R. (1959). On adaptive control processes. IRE Transactions on Automatic Control, 4(2), 1-9.

[4] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural computation, 9(8), 1735-1780.

[5] Harsanyi, J. C., & Chang, C. I. (1994). Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach. IEEE Transactions on geoscience and remote sensing, 32(4), 779-785.

[6] Chang, C. I., Du, Q., Sun, T. L., & Althouse, M. L. (1999). A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification. IEEE transactions on geoscience and remote sensing, 37(6), 2631-2641.

[7] Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. IEEE Transactions on geoscience and remote sensing, 42(8), 1778-1790.

[8] Yu, S., Jia, S., & Xu, C. (2017). Convolutional neural networks for hyperspectral image classification. Neurocomputing, 219, 88-98.

[9] Li, J., Bioucas-Dias, J. M., & Plaza, A. (2012). Spectral–spatial classification of hyperspectral data using loopy belief propagation and active learning. IEEE Transactions on Geoscience and remote sensing, 51(2), 844-856.

[10] Li, J., Zhao, X., Li, Y., Du, Q., Xi, B., & Hu, J. (2018). Classification of hyperspectral imagery using a new fully convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, *15*(2), 292-296.

[11] Haut, J. M., Paoletti, M. E., Plaza, J., Plaza, A., & Li, J. (2019). Hyperspectral image classification using random occlusion data augmentation. *IEEE Geoscience and Remote Sensing Letters*, *16*(11), 1751-1755.

[12] Chen, Y., Zhu, L., Ghamisi, P., Jia, X., Li, G., & Tang, L. (2017). Hyperspectral images classification with Gabor filtering and convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, *14*(12), 2355-2359.

[13] Tarabalka, Y., Fauvel, M., Chanussot, J., & Benediktsson, J. A. (2010). SVM-and MRF-based method for accurate classification of hyperspectral images. IEEE Geoscience and Remote Sensing Letters, 7(4), 736-740.

[14] Li, J., Bioucas-Dias, J. M., & Plaza, A. (2011). Spectral–spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields. IEEE Transactions on Geoscience and Remote Sensing, 50(3), 809-823.

[15] Paoletti, M. E., Haut, J. M., Plaza, J., & Plaza, A. (2018). A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS journal of photogrammetry and remote sensing*, *145*, 120-147.

[16] Jiao, L., Liang, M., Chen, H., Yang, S., Liu, H., & Cao, X. (2017). Deep fully convolutional network-based spatial distribution prediction for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, *55*(10), 5585-5599.

[17] Chen, X., Xiang, S., Liu, C.-L., & Pan, C.-H. (2014). Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks. IEEE Geoscience and Remote Sensing Letters, 11(10), 1797–1801.

[18] Hubel, D. H., & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. The Journal of physiology, 160(1), 106–154.

[19] Lin, M., Chen, Q., & Yan, S. (2013). Network in network. arXiv preprint arXiv:1312.4400.

[20] Gao, H., Yang, Y., Li, C., Zhou, H., & Qu, X. (2018). Joint alternate small convolution and feature reuse for hyperspectral image classification. ISPRS International Journal of Geo-Information, 7(9), 349.

[21] Zhao, W., Jiao, L., Ma, W., Zhao, J., Zhao, J., Liu, H., Cao, X., & Yang, S. (2017). Superpixel-based multiple local cnn for panchromatic and multispectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 55(7), 4141-4156.

[22] Alhichri, H., Alajlan, N., Bazi, Y., & Rabczuk, T. (2018). Multi-scale convolutional neural network for remote sensing scene classification. 2018 IEEE International Conference on Electro/Information Technology (EIT) (pp. 1-5). IEEE.

[23] Noor, M., Salwa, S., Ren, J., Marshall, S., & Michael, K. (2017). Hyperspectral image enhancement and mixture deep-learning classification of corneal epithelium injuries. Sensors, 17(11), 2644.

[24] Leng, J., Li, T., Bai, G., Dong, Q., & Dong, H. (2016). Cube-cnn-svm: a novel hyperspectral image classification method. 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI) (pp. 1027-1034). IEEE.

[25] Wang, Y., Song, T., Xie, Y., & Roy, S. K. (2021). A probabilistic neighbourhood pooling-based attention network for hyperspectral image classification. Remote Sensing Letters, 13(1), 65-75.

[26] Dong, H., Zhang, L., & Zou, B. (2019). Band attention convolutional networks for hyperspectral image classification. arXiv preprint arXiv:1906.04379.

[27] Fang, B., Li, Y., Zhang, H., & Chan, J. C. W. (2019). Hyperspectral images classification based on dense convolutional networks with spectral-wise attention mechanism. Remote Sensing, 11(2), 159.

[28] Hang, R., Li, Z., Liu, Q., Ghamisi, P., & Bhattacharyya, S. S. (2020). Hyperspectral image classification with attention-aided CNNs. IEEE Transactions on Geoscience and Remote Sensing, 59(3), 2281-2293.

[29] Cohen, J. (1960). A coefficient of agreement for nominal scales. Educational and psychological measurement, 20(1), 37-46.

[30] Ham, J., Chen, Y., Crawford, M. M., & Ghosh, J. (2005). Investigation of the random forest framework for classification of hyperspectral data. IEEE Transactions on Geoscience and Remote Sensing, 43(3), 492-501.

[31] Hang, R., Liu, Q., Hong, D., & Ghamisi, P. (2019). Cascaded recurrent neural networks for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 57(8), 5384-5394.

[32] Makantasis, K., Karantzalos, K., Doulamis, A., & Doulamis, N. (2015). Deep supervised learning for hyperspectral data classification through convolutional neural networks. In Proc. IGARSS (pp. 4959-4962). IEEE.

[33] Hamida, A. B., Benoit, A., Lambert, P., & Amar, C. B. (2018). 3-d deep learning approach for remote sensing image classification. IEEE Transactions on geoscience and remote sensing, 56(8), 4420-4434.

[34] Roy, S. K., Krishna, G., Dubey, S. R., & Chaudhuri, B. B. (2020). HybridSN: Exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification. IEEE Geoscience and Remote Sensing Letters, 17(2), 277-281.

İNTİHAL RAPORU İLK SAYFASI

Ali Gündüz

ORİJİNALLİK RAPORU

%6	%5	%1	%4
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%2
2	acikbilim.yok.gov.tr İnternet Kaynağı	%1
3	Jingyu Ji, Shaohui Mei, Xiao Liu, Xu Li, Shan Zeng, Zhiyong Wang. "Exploring Kernel Based Spatial Context for CNN Based Hyperspectral Image Classification", 2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA), 2017 Yayın	<%1
4	cdn.istanbul.edu.tr İnternet Kaynağı	<%1
5	downloads.hindawi.com İnternet Kaynağı	<%1
6	dergipark.org.tr İnternet Kaynağı	<%1

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Ali GÜNDÜZ

PATENT HAKKI İZNİ

Uyarı: Patent hakkı izni gerektirmeyen tez çalışmaları için bu bölüm ve başlık silinebilir!

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	
Doğum Tarihi	Tarih girmek için tıklayın veya dokunun.
Uyruğu	❒ T.C. ❒ Diğer:
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	
Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler