



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



İNVOLÜSYONEL SİNİR AĞLARI İLE
HİPERSPEKTRAL VERİLERİN ANALİZİ

Mücahit CİHAN

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Mayıs-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mücahit CİHAN tarafından hazırlanan “İnvolüsyonel Sinir Ağları ile Hiperspektral Verilerin Analizi” adlı tez çalışması 29/05/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Seral ÖZŞEN
(Konya Teknik Üniversitesi)

.....

Danışman

Prof. Dr. Murat CEYLAN
(Konya Teknik Üniversitesi)

.....

Üye

Doç. Dr. Hasan KOYUNCU
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Güzin ÖZMEN
(Selçuk Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Saim ERVURAL
(KTO Karatay Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 122E021 Numaralı proje ile desteklenmiştir. Projeye verdiği destekten ötürü TÜBİTAK'a teşekkürlerimizi sunarız.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mücahit CİHAN

Tarih: 29.05.2024

ÖZET

DOKTORA TEZİ

İNVOLÜSYONEL SİNİR AĞLARI İLE HİPERSPEKTRAL VERİLERİN ANALİZİ

Mücahit CİHAN

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat CEYLAN

2024, 146 Sayfa

Jüri

Prof. Dr. Murat CEYLAN

Prof. Dr. Seral ÖZŞEN

Doç. Dr. Hasan KOYUNCU

Dr. Öğr. Üyesi Güzin ÖZMEN

Dr. Öğr. Üyesi Saim ERVURAL

Hiperspektral görüntüleme (HSG), bir nesnenin yüzeyini geniş bir elektromanyetik spektrumda inceleyen ve her pikselde spektral bilgi sağlayan güçlü bir görüntüleme tekniğidir. Bu teknoloji, endüstriyel, tarım, çevre ve medikal gibi farklı alanlarda yaygın olarak kullanılmaktadır. HSG'nin farklı alanlarda yaygın olarak kullanılması, verilerin doğru bir şekilde analiz edilmesinin önemini vurgulamaktadır. Ancak, HSG verilerinin analizi ve sınıflandırılması, büyük boyutları ve yüksek hesaplama maliyetleri nedeniyle birçok zorlukla karşılaşmaktadır. Bu zorlukları aşmak ve HSG verilerini etkili bir şekilde analiz edip farklı alanlarda kullanabilmek için hassas ve güvenilir yöntemlere ihtiyaç vardır.

İnvölüsyonel Sinir Ağları (İSA) gibi derin öğrenme yöntemleri, HSG verilerinin analizi ve sınıflandırılmasında önemli bir rol oynayabilir. İnvölüsyon, geleneksel konvolüsyon tabanlı modellere göre daha az parametre ve hesaplama maliyeti gerektiren, ancak aynı zamanda etkili bir şekilde spektral-uzamsal bilgileri yakalayan bir yaklaşımdır. İnvölüsyon tabanlı geliştirilen modeller, geleneksel sinir ağı mimarilerinden farklı olarak, girdi verilerini analiz ederken hesaplama maliyetini azaltmak için öz-dikkat mekanizmalarını kullanırlar ve bu da özellikle HSG gibi büyük boyutlu veri setlerinde etkili olmaktadır.

Bu doktora tezi, HSG verilerinin analizi için İSA'ların kullanılmasını incelemekte ve bu teknolojinin avantajlarını vurgulamaktadır. Ayrıca, çeşitli çalışmaların sonuçlarına dayanarak, invölüsyonun HSG'deki potansiyelini değerlendirmektedir. Bu değerlendirmeler yapılırken uzaktan algılama ve yeryüzü gözlemi alanında yapılan çalışmalar için kamuya açık veri setleri kullanılmıştır. Biyomedikal alanında yapılan çalışmalar için ise TÜBİTAK projesi kapsamında oluşturulan yenidoğan HSG veri koleksiyonu temel alınmıştır. Bu alanlardaki HSG verilerini analiz etmek için invölüsyon tabanlı modeller geliştirilmiş ve bu modeller kullanılarak farklı performans ölçütleri ile kapsamlı analizler yapılmıştır.

İlk çalışmada, uzaktan algılama ve yeryüzü gözleme alanında kamuya açık Indian Pines (IP), Pavia University (PU), Salinas Scene (SA) ve Kennedy Space Center (KSC) veri setleri kullanılarak deneysel çalışmalar gerçekleştirilmiştir. Bu çalışma, invölüsyon kavramını entegre eden benzersiz bir sinir ağı modelinin, Involutional Residual Spectral Network (IRSN), HSG sınıflandırması üzerine odaklanmaktadır. Konvolüsyon tabanlı yöntemlerin hesaplama maliyetini azaltmayı hedefleyen bu model, invölüsyon yaklaşımını benimsemiş ve sınıflandırma doğruluğunu artırmış, aynı zamanda hesaplama

verimliliği sağlamıştır. Geliştirilen IRSN modeli, deneysel sonuçlara göre, HSG veri setleri için son derece uygun ve performans açısından üstün bir model olarak öne çıkmıştır.

Diğer bir çalışmada, yenidoğan sağlık durumunu değerlendirmek amacıyla involüsyon tabanlı HarmonyNet modeli geliştirilmiş ve kapsamlı bir değerlendirme yapılmıştır. 110 hasta ve 110 sağlıklı vakayı içeren HSG veri seti üzerinde gerçekleştirilen değerlendirmeler, HarmonyNet modelinin yüksek doğruluk, güvenilirlik ve düşük hesaplama maliyeti ile önemli bir başarı elde ettiğini göstermektedir. Yapılan analizler, involüsyon tasarımı içerisinde bulunan hiperparametre ayarlarının optimal bir şekilde yapılmasının modelin performansını artırmada kritik öneme sahip olduğunu göstermektedir. Ayrıca, ablastyon çalışması, modelin başarısının farklı özelliklerin sinerjik entegrasyonundan kaynaklandığını doğrulamış ve modelin geniş çapta uygulanabilir olduğunu vurgulamıştır.

Farklı bir çalışma, yenidoğan hastalıklarının tespiti için geliştirilen ve içerisinde çok ölçekli bağlamsal yapı ve başlangıç modülü bulunan involüsyon tabanlı MC-I²Net modelinin etkinliğini değerlendirmeyi amaçlamaktadır. Yapılan deneyler ve analizler, MC-I²Net modelinin beş hastalık (Solunum Sıkıntısı Sendromu, Nekrotizan Enterokolit, İntrakraniyal Kanama, Aort Koarktasyonu ve Pnömotoraks) ve bir kontrol grubuna ait 240 HSG veriyi sınıflandırmada önemli bir performans sergilediğini ve diğer konvolüsyon tabanlı modellere kıyasla daha yüksek başarı ölçütlerine ulaştığını göstermektedir. İnvolüsyon tabanlı MC-I²Net, konvolüsyon tabanlı yöntemlere kıyasla daha az parametre ve FLOP değerine sahip olsa da bazı durumlarda çıkarım süresi daha uzun olmuştur. Ancak bu çalışma, optimum performans için belirli parametrelerin doğru seçilmesinin önemini vurgulamıştır. Modelin performansını artırmak için yapılan analizler, başlangıç modülünün ve çok ölçekli bağlamsal yapının rolüne dikkat çekmiştir. Ayrıca, involüsyon tabanlı MC-I²Net'in daha az hesaplama gücü gerektirdiği ve yüksek performansı ile pratik uygulamalar için uygun bir seçenek olduğu vurgulanmıştır.

Tez kapsamında gerçekleştirilen başka bir çalışmada, yenidoğan sağlığının tespiti ve izlenmesi için yeni hibrit bir model önerilmiştir. Geleneksel olarak sadece spektrum verilerini kullanarak yapılan sınıflandırma deneyimlerinin ötesine geçilerek, hemogloblin ve bilirubin gibi kan biyobelirteçlerinin de dahil edilmesiyle daha etkili bir yaklaşım sağlanmıştır. Spektrumları ve kan biyobelirteçlerinin birlikte değerlendirilmesi için içerisinde hem 2B/3B konvolüsyon yapılarının hem de involüsyon yapılarının bulunduğu HybridCISN modeli geliştirilmiştir. Bu çalışmada iki farklı yaklaşım benimsenmiştir. Tek başına spektrumların değerlendirilmesi yaklaşımında sadece HybridCISN modeli kullanılmıştır. Birlikte değerlendirme yaklaşımında ise, spektrum verilerinden HybridCISN içerisindeki konvolüsyon ve involüsyon katmanları ile öznelilikler çıkarılmış ve kan biyobelirteçleri düzeltirme aşamasından sonra modele eklenmiştir. Bu aşamada farklı sınıflayıcılar kullanılmış ve performanslar değerlendirilmiştir. Bu yaklaşım ile spektrumların ve kan biyobelirteçlerinin birlikte değerlendirilmesi sağlanmıştır. İkili sınıflandırma ve çoklu sınıflandırma deneyleri yapılmıştır. Deneysel sonuçlar, spektrum verilerine kan biyobelirteçlerinin eklenmesiyle modelin performansında önemli bir iyileşme olduğunu göstermektedir. Ayrıca, ablastyon analizleri, modelin bileşenlerinin değerlendirilmesinde involüsyon katmanının önemini ortaya koymuş ve modelin performansını artırmak için gelecekte bu katmana odaklanılması gerektiğini göstermiştir.

Tezde yer alan 5. çalışmada ise, yenidoğan HSG verilerinin analizi ve sınıflandırması gerçekleştirilmiştir. Bu çalışma, çeşitli boyut indirgeme tekniklerinin değerlendirilmesini hedeflemiştir. İncelenen boyut indirgeme tekniklerinin, HSG veri analizinde önemli bir rol oynadığı ve İSA ile birleştirildiğinde daha etkili sonuçlar elde edildiği belirlenmiştir. Farklı tekniklerin performansı incelenmiş ve Negatif Olmayan Matris Ayrışımı (NOMA) ve Temel Bileşenler Analizi (TBA) gibi tekniklerin farklı sınıf etiketlerine sahip örnekleri doğru bir şekilde tanımlama ve tüm test verilerinde doğru tahminler yapma yeteneği açısından öne çıktığı görülmüştür. Bu çalışma, HSG verilerinin analizi için etkili ve güvenilir boyut indirgeme yöntemlerinin belirlenmesine katkıda bulunmuştur.

Bu çalışmalar, HSG verilerinin analizinde İSA'ların kullanımının sağladığı avantajları öne çıkarmaktadır. İSA'lar, geleneksel yöntemlere kıyasla daha az parametre ve hesaplama maliyeti gerektirirken, spektral-uzamsal bilgileri etkili bir şekilde yakalama yeteneğiyle dikkat çekmektedir. Özellikle, bu çalışmalar yenidoğanlar için dünya çapında ilk kez bir yaklaşımın geliştirilmesine öncülük etmiş ve TÜBİTAK projesi kapsamında oluşturulan kapsamlı bir veri koleksiyonunu tanıtmıştır. Yapılan çalışmalar, HSG teknolojisinin, endüstriyel, tarım, çevre ve medikal gibi farklı alanlarda önemli bir araç haline geldiğini ve İSA'ların, HSG verilerinin sınıflandırılması ve analizinde gelişmiş doğruluk ve verimlilik sağladığını göstermektedir. Bu bağlamda, İSA'ların, HSG teknolojisinin potansiyelini daha da artırarak, verilerin daha detaylı ve geniş kapsamlı bir şekilde analiz edilmesine katkı sağladığı görülmektedir. Bu çalışmaların sonuçları, İSA'ların HSG verilerinin analizi için güvenilir ve etkili birer araç olduğunu vurgulamakta ve gelecekteki araştırmalar için önemli bir temel oluşturmaktadır.

Anahtar Kelimeler: Hiperspektral Görüntüleme, İnvolüsyonel Sinir Ağları, Uzaktan Algılama, Biyomedikal, Spektral Analiz

ABSTRACT

PhD THESIS

ANALYSIS OF HYPERSPECTRAL DATA WITH INVOLUTIONAL NEURAL NETWORKS

Mücahit CİHAN

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Prof. Dr. Murat CEYLAN

2024, 146 Pages

Jury

Prof. Dr. Murat CEYLAN

Prof. Dr. Seral ÖZŞEN

Assoc. Prof. Dr. Hasan KOYUNCU

Asst. Prof. Dr. Güzin ÖZMEN

Asst. Prof. Dr. Saim ERVURAL

Hyperspectral Imaging (HSI) is a powerful imaging technique that examines the surface of an object across a wide electromagnetic spectrum, providing spectral information at each pixel. This technology finds widespread use in various fields such as industry, agriculture, environment, and medicine. The widespread use of HSI in different domains emphasizes the importance of accurately analyzing the data. However, the analysis and classification of HSI data face numerous challenges due to their large sizes and high computational costs. Overcoming these challenges and effectively analyzing HSI data for diverse applications require precise and reliable methods.

Deep learning methods such as Involutional Neural Networks (INNs) can play a significant role in the analysis and classification of HSI data. Involutions are an approach that requires fewer parameters and computational costs compared to traditional convolution-based models while effectively capturing spectral-spatial information. Models developed based on involution use self-attention mechanisms to reduce computational costs when analyzing input data, differing from traditional neural network architectures. This approach proves particularly effective in handling large datasets such as HSI.

This PhD thesis examines the use of INNs for the analysis of HSI data and highlights the advantages of this technology. Additionally, it evaluates the potential of involution in HSI based on the results of various studies. Public datasets for remote sensing and earth observation studies were used during these evaluations. For studies in the biomedical field, the neonatal HSI data collection created under a TÜBİTAK project was employed. Involution-based models were developed to analyze HSI data in these fields, and comprehensive analyses were conducted using various performance metrics.

In the initial study, experimental investigations were conducted using publicly available Indian Pines (IP), Pavia University (PU), Salinas Scene (SA), and Kennedy Space Center (KSC) datasets in the fields of remote sensing and earth observation. This study focuses on the classification of HSI by a unique neural network model integrating the concept of involution, known as the Involutional Residual Spectral Network (IRSN). This model aims to reduce the computational cost of convolution-based methods by adopting the involution approach, which enhances classification accuracy while ensuring computational efficiency. According to the experimental results, the developed IRSN model emerged as highly suitable for HSI datasets and stood out as a superior model in terms of performance.

In another study, the involution-based HarmonyNet model was developed to assess the health status of neonates, and a comprehensive evaluation was conducted. Assessments conducted on an HSI dataset comprising 110 patient cases and 110 healthy cases demonstrate that the HarmonyNet model achieved significant success with high accuracy, reliability, and low computational cost. The analyses indicate that optimizing hyperparameter settings within the involution design is crucial for enhancing the model's performance. Additionally, an ablation study confirmed that the model's success stems from the synergistic integration of different features and underscored the model's broad applicability.

Another study aims to evaluate the effectiveness of the involution-based MC-I²Net model, which incorporates multiscale contextual structure and inception modules, developed for the detection of neonate diseases. Experiments and analyses demonstrate that the MC-I²Net model exhibited significant performance in classifying 240 HSI data belonging to five diseases (Respiratory Distress Syndrome, Necrotizing Enterocolitis, Intracranial Hemorrhage, Aortic Coarctation, and Pneumothorax) and one control group, achieving higher success metrics compared to other convolution-based models. Although the involution-based MC-I²Net has fewer parameters and FLOP values compared to convolution-based methods, inference time was longer in some cases. However, this study emphasized the importance of selecting specific parameters for optimal performance. Analyses conducted to enhance the model's performance highlighted the significant role of the inception module and multiscale contextual structure. Additionally, it was emphasized that the involution-based MC-I²Net requires less computational power and is a suitable option for practical applications due to its high performance.

In another study conducted within the scope of the thesis, a novel hybrid model is proposed for the diagnosis and monitoring of neonate health. Beyond the classification experiments traditionally conducted using only spectral data, a more effective approach was achieved by incorporating blood biomarkers such as hemoglobin and bilirubin. The HybridCISN model, incorporating both 2D/3D convolutional structures and involution structures for the evaluation of spectra and blood biomarkers together, was developed. Two different approaches were adopted in this study. In the single spectrum evaluation approach, only the HybridCISN model was used. In the joint evaluation approach, features were extracted from the spectrum data using the convolution and involution layers within HybridCISN, and blood biomarkers were added to the model after the flattening stage. Different classifiers were used at this stage, and their performances were evaluated. This approach enabled the evaluation of spectra and blood biomarkers together. Binary and multi-classification experiments were conducted. Experimental results indicate a significant improvement in the model's performance with the addition of blood biomarkers to the spectral data. Additionally, ablation analyses underscored the importance of the involution layer in evaluating the model's components and suggested a focus on this layer for enhancing the model's performance in the future.

In the fifth study within the thesis, the analysis and classification of neonate HSI data were conducted. This study targeted the evaluation of various dimensionality reduction techniques. It was determined that the examined dimensionality reduction techniques played a significant role in HSI data analysis and yielded more effective results when combined with INNs. The performance of different techniques was examined, and methods such as Non-negative Matrix Factorization (NMF) and Principal Component Analysis (PCA) stood out for their ability to accurately classify samples with different class labels and make correct predictions across all test data. This study contributed to identifying effective and reliable dimensionality reduction methods for HSI data analysis.

These all studies highlight the advantages of using INNs in the analysis of HSI data. INNs attract attention for their ability to capture spectral-spatial information effectively while requiring fewer parameters and computational costs compared to traditional methods. Particularly, these studies have pioneered the development of a novel approach for neonates worldwide and introduced a comprehensive data collection created under a TÜBİTAK project for the first time. The studies indicate that HSI technology has become a significant tool in various fields such as industry, agriculture, environment, and medicine, and INNs provide enhanced accuracy and efficiency in the classification and analysis of HSI data. In this context, it is evident that INNs contribute to further enhancing the potential of HSI technology, enabling more detailed and comprehensive analysis of data. The results of these studies underscore the reliability and effectiveness of INNs as tools for the analysis of HSI data, laying an important foundation for future research.

Keywords: Hyperspectral Imaging, Involutional Neural Networks, Remote Sensing, Biomedical, Spectral Analysis

ÖNSÖZ

Doktora tez çalışmamı tamamlama sürecimde bana rehberlik eden ve tüm akademik hayatım boyunca değerli katkılarda bulunan danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Öğretim Üyesi Sayın Prof. Dr. Murat CEYLAN'a sonsuz şükranlarımı sunarım.

Tez İzleme Komitemde bulunan Prof. Dr. Seral ÖZŞEN ve Dr. Öğr. Üyesi Güzin ÖZMEN'e tez sürecim boyunca yol gösterici tutumları ve destekleyici tavırlarından dolayı minnettarım. Ayrıca, Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesinden veri alma sürecinde yardımcı olan öğretim üyeleri Sayın Prof. Dr. Hanifi SOYLU, Doç. Dr. Murat KONAK ve yoğun bakım ünitesi hemşiresi Nezahat YILMAZ'a çok teşekkür ederim.

Son olarak, beni yetiştiren, her daim inanan ve yanımda olan anneme, babama, kardeşlerime ve aramızdan çok kısa bir süre önce ayrılmasına rağmen bana her zaman ilham kaynağı olan değerli büyüğüm babaanneme en içten teşekkürlerimi sunarım.

Mücahit CİHAN
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Kapsam ve Amaç	1
1.2. Hiperspektral Görüntüleme.....	2
1.3. İnvolüsyonel Sinir Ağları.....	4
1.4. Araştırma Soruları ve Hipotezler	5
1.5. Tezin Yapısı	6
2. KAYNAK ARAŞTIRMASI	8
2.1. Hiperspektral Görüntülemelerde Konvolüsyon ve İnvolüsyon Kullanımı	8
2.1.1. Uzaktan Algılama ve Yeryüzü Gözlemede	9
2.1.2. Biyomedikal Görüntülemelerde	12
2.2. Hiperspektral Görüntüleme için Ön İşleme ve Boyut İndirme Yöntemlerinin Kullanımı	15
3. MATERYAL VE YÖNTEM.....	18
3.1. Veri Setleri	18
3.1.1. Uzaktan Algılama ve Yeryüzü Gözleme Veri Setleri.....	18
3.1.1.1. Indian Pines (IP) Veri Seti	18
3.1.1.2. University of Pavia (UP) Veri Seti	19
3.1.1.3. Salinas Scene (SA) Veri Seti	20
3.1.1.4. Kennedy Space Center (KSC) Veri Seti	20
3.1.2. Biyomedikal Görüntüleme Veri Seti	21
3.1.2.1. Hiperspektral Görüntüleme Sistemi ve Veri Toplama	21
3.1.2.2. Veri Seti Tanımı.....	24
3.1.2.3. Ön İşleme	26
3.1.2.3.1. Normalizasyon	26
3.1.2.3.2. Spektral Bant Seçimi	27
3.1.2.3.3. Spektrumları Yumuşatma	27
3.2. Yöntemler	30
3.2.1. Konvolüsyon Taslağı	30
3.2.1.1. 2B Konvolüsyon	31
3.2.1.2. 3B Konvolüsyon	31
3.2.2. İnvolüsyon Tasarımı	33
3.2.3. Boyut İndirme Yöntemleri.....	36
3.2.3.1. Spektral Gömme (SG)	36

3.2.3.2. Yerel Doğrusal Gömme (YDG).....	37
3.2.3.3. Bağımsız Bileşenler Analizi (BBA)	38
3.2.3.4. Tekil Değer Ayrışması (TDA).....	38
3.2.3.5. Temel Bileşenler Analizi (TBA).....	39
3.2.3.6. Negatif Olmayan Matris Ayrışımı (NOMA)	40
3.2.4. Derin Öğrenme Modelleri İçerisinde Kullanılan Özel Yapılar	42
3.2.4.1. Artık Blok	42
3.2.4.2. Başlangıç Modülü	42
3.2.4.3. Çok Ölçekli Bağlamsal Yapı	44
3.3. Deneysel Ayarlar	45
3.3.1. Deney Ortamı ve Araçları.....	46
3.3.2. Performans Değerlendirme Ölçütleri.....	46
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	51
4.1. Uzaktan Algılama ve Yeryüzü Gözleme Deneyleri	51
4.1.1. Involutional Residual Spectral Network (IRSN).....	51
4.1.2. Deneysel Sonuçlar	53
4.1.2.1. Eğitim Detayları.....	53
4.1.2.2. Deneysel Tartışma	53
4.1.4. Araştırma Bulguları	61
4.2. Biyomedikal Görüntüleme Deneyleri.....	64
4.2.1. İnvolüsyon Tabanlı HarmonyNet: Yenidoğan Sağlık Durumunun Otomatik Tespiti için Verimli Bir Hiperspektral Görüntüleme Modeli	64
4.2.1.1. HarmonyNet.....	64
4.2.1.2. Deneysel Sonuçlar	67
4.2.1.2.1. HarmonyNet'in Eğitim Aşaması	67
4.2.1.2.2. Sonuçlar ve Analiz.....	68
4.2.1.2.3. Tartışma	76
4.2.1.3. Araştırma Sonuçları	78
4.2.2. Hiperspektral Görüntüleme ile Yenidoğan Hastalığı Teşhisi için MC-I ² Net: Çok Ölçekli Bağlamsal Yapı ve Başlangıç Modülü ile İnvolüsyon Tabanlı Derin Öğrenme Yaklaşımı	79
4.2.2.1. MC-I ² Net	79
4.2.2.2. Deneysel Sonuçlar ve Tartışma	81
4.2.2.2.1. Eğitim Detayları.....	81
4.2.2.2.2. Sınıflandırma Performansı.....	82
4.2.2.2.3. Ablasyon Analizi	88
4.2.2.3. Elde Edilen Bulgular.....	89
4.2.3. Hiperspektral Görüntüleme ve Kan Biyobelirteçleri Kullanılarak Yenidoğan Hastalığının Tanımlanması için 2B/3B Konvolüsyon ve İnvolüsyon Tabanlı HybridCISN Modeli	90
4.2.3.1. HybridCISN	92
4.2.3.2. Deneysel Sonuçlar	94
4.2.3.2.1. Eğitim Detayları.....	94
4.2.3.2.2. Deneyler ve Sonuçlar.....	95
4.2.3.2.2.1. İkili Sınıflandırma Deneyi	95
4.2.3.2.2.2. Çoklu Sınıflandırma Deneyi	99
4.2.3.3. Tartışma	103
4.2.3.4. Sonuç Değerlendirmesi.....	104

4.3. Boyut İndirme Tekniklerinin Etkisinin Değerlendirilmesi	105
4.3.1. İnvolüsyonel Sinir Ağı Modeli	105
4.3.2. Deneysel Sonuçlar	107
4.3.3. Tartışma	109
4.3.4. Sonuçların İncelenmesi	110
4.4. Araştırma Bulgularının Değerlendirilmesi	111
5. SONUÇLAR VE ÖNERİLER	114
5.1. Sonuçlar	114
5.1.1. Ana Bulgular	114
5.1.2. Tezin Katkıları	116
5.2. Öneriler	117
5.2.1. Gelecekteki Araştırma Önerileri	117
5.2.2. Pratik Uygulama Alanları	118
KAYNAKLAR	119
EKLER	129

SİMGELER VE KISALTMALAR

Simgeler

$\oplus$	: Uzayda toplama işlemi
$\otimes$	: Kanallar arası çarpma işlemi
$\times$	: Kartezyen çarpımı
B, λ	: Spektral bant boyutu
C	: Kanal sayısı
C_0	: Bir dizi konvolüsyon filtresi
G	: Grup sayısı
H	: Yükseklik
I	: Ham veri
K	: Anahtar (key)
$K \times K$	: Çekirdek boyutu
L	: Laplacian matrisi
M	: Savitzky-Golay pencere boyutu
p	: Dolgu (padding)
P_0	: Gözlenen doğruluk
P_c	: Gerçekleşme olasılığı
Q	: Sorgu (query)
r	: Düşürme oranı
s	: Adım (stride)
$S \times S$	: Mini parça boyutları
V	: Değer (value)
W	: Genişlik
W_0, W_1	: Darboğaz yapısı oluşturan doğrusal dönüşümler
X'	: Azaltılmış boyuttaki veri
X	: Giriş özellik haritası
Y	: Çıkış özellik haritası
Z	: Temel bileşen matrisi
Δ_k	: Konvolüsyon komşuluğundaki ofset kümesi
Σ	: Kovaryans matrisi
σ	: Yığın normalleştirme (batch normalization)
ϕ	: Kernel Generation Function
Ψ_{ij}	: İnvolüsyon çekirdeğinin koşullandırıldığı piksel kümesi
$\mathcal{F}$	: Konvolüsyon çekirdeği
$\mathcal{H}$	: İnvolüsyon çekirdeği

Kısaltmalar

1B	: 1 (bir) Boyutlu
2B	: 2 (iki) Boyutlu
3B	: 3 (üç) Boyutlu
AORT	: Aort Koarktasyonu
AR	: Anti-Reflektif
AUC	: Eğri Altındaki Alan
AVIRIS	: Hava Görünür/Kızılötesi Görüntüleme Spektrometresi
BBA	: Bağımsız Bileşenler Analizi
Bil	: Bilirubin

BİS	: Boyut İndirgeme Süresi
BN	: Batch Normalization
DMCA	: Deep Margin Cosine Autoencoder
DN	: Doğru Negatif
DP	: Doğru Pozitif
DPO	: Doğru Pozitif Oranı
DVM	: Destek Vektör Makinaları
FC	: Tam Bağlı Katman
FLOP	: Kayan Nokta İşlemleri
GD	: Genel Doğruluk
Hgb	: Hemoglobin
HSG	: Hiperspektral Görüntüleme
HybridCISN	: Hybrid Convolutional and Involutional Spectral Network
ICH	: İntrakraniyal Kanama
IP	: Indian Pines
IR	: Kızılötesi
IRSN	: Involutional Residual Spectral Network
IT-UNet	: Involution Transformer based U-Net
İnv	: İnvolyasyon
İSA	: İnvolyasyonel Sinir Ağları
Kappa	: Cohen'in Kappa Katsayısı
KBA	: Kompakt Bant Ağırlıklandırma
KÇ	: Komşuluk Çıkarma
k-EYK	: k-En Yakın Komşu
KGF	: Kernel Generation Function
Konv	: Konvolüsyon
KSC	: Kennedy Space Center
LDA	: Lineer Diskriminant Analizi
maks	: Maksimum
MaksHavuz	: Maksimum Havuzlama
MC-I ² Net	: Multi Contextual Involution Inception Network
MHSG	: Medikal Hiperspektral Görüntüleme
min	: Minimum
MKK	: Matthews Korelasyon Katsayısı
NB	: Naive Bayes
NEC	: Nekrotizan Enterokolit
NLOY	: Negatif Log Olasılık Yoğunluğu
NOMA	: Negatif Olmayan Matris Ayrışımı
norm	: Normalizasyon
OD	: Ortalama Doğruluk
OrtHavuz	: Ortalama Havuzlama
PTX	: Pnömotoraks
RDS	: Solunum Sıkıntısı Sendromu
ROC	: Alıcı İşletim Karakteristiği
ROSIS	: Reflektif Optik Sistem Görüntüleme Spektrometresi
SA	: Salinas Scene
SG	: Spektral Gömme
SGE	: Split Grouping Embedding
SK	: Seyrek Kodlama
SSIN	: Spatial-spectral involution multilayer perceptron network

Sum	: Toplama
TB	: Temel Bileşen
TBA	: Temel Bileşenler Analizi
TDA	: Tekil Değer Ayrışması
t-SKG	: t-Dağıtılmış Stokastik Komşu Gömme
UP	: University of Pavia
YDG	: Yerel Doğrusal Gömme
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YPO	: Yanlış Pozitif Oranı
YSA	: Yapay Sinir Ağı
YYBÜ	: Yenidoğan Yoğun Bakım Ünitesi



1. GİRİŞ

1.1. Kapsam ve Amaç

Günümüzde, görüntüleme teknolojileri ve derin öğrenme yöntemleri, bilimsel araştırmalardan endüstriyel uygulamalara kadar geniş bir yelpazede devrim niteliğinde ilerlemeler sağlamaktadır. Bu ilerlemeler, Hiperspektral Görüntüleme (HSG) alanında, veri analizi ve işleme yeteneklerini büyük ölçüde artırmıştır. Bu çalışma, bu ilerlemelerin bir sonucu olarak ortaya çıkmıştır.

Görüntüleme teknolojilerinin evrimi, insanlığın çeşitli ihtiyaçlarına yönelik olarak sürekli bir şekilde gelişmektedir (Wang ve diğ., 2020). Bu teknolojiler, görüntüleme sistemlerinin algıladığı bilgi miktarını artırırken, aynı zamanda daha ayrıntılı ve hassas verilerin elde edilmesine imkân tanımaktadır. Özellikle HSG, nesnelerin yüzey özelliklerini spektral imzalar aracılığıyla daha ayrıntılı bir şekilde analiz etme yeteneği sunar (Jaiswal ve diğ., 2021). Bu teknoloji, tarım, çevre izleme, tıp ve askeri uygulamalar gibi birçok alanda yaygın olarak kullanılmaktadır (Cihan, 2020).

Derin öğrenme yöntemleri, son yıllarda makine öğrenimi alanında büyük bir dönüşüm yaratmıştır. Derin öğrenme algoritmaları, karmaşık veri yapılarını ve ilişkilerini otomatik olarak öğrenme yeteneğiyle öne çıkmaktadır (Masson ve diğ., 2023). Bu da büyük veri setlerinden anlamlı bilgilerin çıkarılmasını ve kritik kararların daha doğru bir şekilde alınmasını sağlar. Özellikle, Evrişimsel Sinir Ağları (ESA'lar), görüntü verilerini işleme ve sınıflandırma konusunda olağanüstü başarılar elde etmiştir. ESA'lar, birçok görüntü işleme ve tanıma görevinde dikkate değer sonuçlar elde etmiş olmasına rağmen bazı dezavantajlara sahiptir. Bu dezavantajları ortadan kaldırmak veya azaltmak için yenilikçi yaklaşımlar geliştirilmektedir.



Bu tez çalışması, HSG verilerin analizi için İnvolüsyonel Sinir Ağlarının (İSA'lar) kullanımını inceleyerek, görüntüleme teknolojileri ve derin öğrenme yöntemlerinin birleşiminden doğan güçlü bir sentezi ele almaktadır. Geliştirilen yöntemler, yapısal özellikleri dikkate alınan HSG verilerinden daha az parametre kullanarak önemli bilgilerin çıkarılmasında yeni yaklaşımlar sunmayı amaçlayarak, çeşitli uygulama alanlarındaki yöntemlerin ötesine geçmeyi hedeflemektedir.

Bu sentez, görüntüleme teknolojilerinin ve derin öğrenme yöntemlerinin ileri düzeydeki potansiyelini ortaya çıkarmakla kalmayıp aynı zamanda bu alanlarda var olan

zorlukları ele alarak gelecekteki arařtırmalar için bir çerçeve sunmayı hedeflemektedir. Bu çerçeve, daha etkili ve yenilikçi çözümler üretebilmek için arařtırmacılara yön gösterecektir.

1.2. Hiperspektral Görüntüleme

Günümüzde, görüntüleme teknolojilerindeki hızlı ilerlemeler, çeşitli endüstrilerde yeni ve etkileyici uygulamaların ortaya çıkmasına yol açmaktadır. Bu manzaranın içinde dikkate değer bir teknolojik ilerleme, HSG yöntemidir. Geleneksel görüntüleme sistemlerinden ayrılan HSG, elektromanyetik spektrumun geniş bir yelpazesini aynı anda algılayıp analiz etme yeteneğiyle öne çıkmaktadır (Şekil 1.1(a)). Bu benzersiz nitelik, nesnelerin yüzey özelliklerinin daha karmaşık ve hassas bir şekilde incelenmesini sağlar. HSG'nin dönüřtürücü doğası, çeşitli alanlarda geliştirilmiş içgörüler ve uygulamalar için yeni olanaklar sunmakta ve bu sayede malzemelerin ve çevrelerin daha kapsamlı bir şekilde anlaşılmasını sağlamaktadır.



Şekil 1.1. HSG'nin geniş spektral kapsamı ve geleneksel RGB görüntüleme ile karşılaştırılması. (a) HSG, görünür spektruma ek olarak yakın, kısa, orta ve uzun dalga kırmızıtesi bölgelerini kapsar. (b) RGB görüntüleme 3 bant ile sınırlıyken, HSG daha fazla spektral bant sunar.

HSG, geleneksel renkli görüntüleme tekniklerini ötesine geçen, geniş bir yelpazede yüksek çözünürlüklü spektral imzaları yakalayan gelişmiş bir görüntüleme tekniğidir (Şekil 1.1(b)) (Aburaed ve diğ., 2023). Bu teknoloji, nesne spektrumlarının detaylı analizini sağlayan birçok spektral kanalda çalışırken, çeşitli uygulama alanlarında kullanılmaktadır. HSG'nin nesne tanımlama, analiz ve sınıflandırmayı geliştirmesi, araştırmacılar ve uygulamacılar için bilgiye dayalı kararlar almayı sağlamaktadır.

HSG verileri, iki uzamsal boyut (x, y) ve bir spektral boyutta (λ) büyük hacimli veri setleri oluşturur (Cihan ve Ceylan, 2023). Boyutsal karmaşıklık, veri depolama, işleme ve analiz açısından zorluklar doğurmaktadır. Yüksek boyutlu HSG veri karmaşıklığı, analiz ve sınıflandırmada zorluklar ortaya çıkarmaktadır. Spektral kanalların fazlalığı ve yüksek boyutlu verilerin karmaşıklığı, veri analizi yöntemleri ve algoritmalarının seçimini etkilemektedir (Pandey ve diğ., 2020). Bu zorlukları aşmak ve analiz sürecini optimize etmek için sınıflandırma algoritmaları, özellik seçimi ve boyut indirgeme teknikleri tercih edilmektedir.

HSG'nin yeryüzü gözleme alanındaki kullanımı büyük önem taşımaktadır. Çevre izleme ve tarım uygulamalarında, HSG bitkilerin hastalıklarını erken teşhis etme (Terentev ve diğ., 2022), tarım verimliliğini artırma (Sethy ve diğ., 2022) ve su kaynaklarını daha etkin bir şekilde yönetme (Liu ve diğ., 2021) gibi önemli roller üstlenmektedir. Bitki sağlığı izleme, hastalıklı bitkilerin erken tespiti ve zararlı organizmaların belirlenmesi gibi konularda HSG, tarımsal üretimde önemli bir araç haline gelmiştir (Rayhana ve diğ., 2023).

HSG'nin sağlık sektöründeki potansiyeli giderek artmaktadır (Yoon, 2022). Özellikle, kanser tespiti, doku karakterizasyonu ve cerrahi müdahaleler gibi birçok önemli uygulama alanında kullanılmaktadır (Campbell ve diğ., 2023). HSG, kanserli dokuların sağlıklı dokulardan farklı spektral özelliklerini belirleyerek tümör sınırlarını daha hassas bir şekilde haritalama (Halicek ve diğ., 2019), ayrıca nöro cerrahi, kardiyoloji, gastroenteroloji, ortopedi gibi çeşitli tıbbi alanlarda kullanılarak teşhis ve tedavi süreçlerini iyileştirebilme kabiliyetine sahiptir (Zaffino ve diğ., 2020). Bu sayede, HSG, teşhis ve tedavi süreçlerinde daha doğru, etkili ve güvenli sonuçlar elde edilmesine yardımcı olmaktadır.

Sonuç olarak, HSG teknolojisinin hızla gelişen ve genişleyen bir alan olduğu açıktır. Bu teknolojinin sağladığı kapsamlı veri analizi imkanları ve uygulama alanlarının çeşitliliği, farklı endüstrilerdeki araştırmacılar ve uygulamacılar için heyecan verici yeni fırsatlar sunmaktadır. HSG verilerinin analizi, büyük veri tekniklerinin ve yapay zekâ algoritmalarının kullanımını gerektirir. Bu analizler, veri depolama, işleme ve analiz açısından zorluklarla karşılaşabilir, ancak doğru yaklaşımlarla bu zorluklar aşılabilmektedir. Özellikle, makine öğrenimi ve derin öğrenme teknikleri, HSG verilerinin analizinde önemli bir rol oynamakta ve verilerden anlamlı bilgiler çıkarmak için kullanılmaktadır. HSG verilerinin önemi, sürekli olarak yeni analiz yöntemlerinin ve tekniklerinin geliştirilmesini teşvik etmektedir. Bu yeni yöntemler, veri analizi süreçlerini optimize etmek ve daha kesin sonuçlar elde etmek için kullanılmaktadır. Örneğin, HSG verilerinin daha etkili bir şekilde analiz edilmesi ve özelliklerinin belirlenmesi için yeni algoritmalar geliştirilebilir. Bu bağlamda, HSG verilerinin önemi, kullanımı, analizi ve yeni yöntemlerin geliştirilmesi konuları, çeşitli endüstrilerde bilgiye dayalı karar almayı sağlayarak, daha etkili ve verimli çözümler sunma potansiyeline sahiptir. Bu nedenle, HSG teknolojisinin daha da ilerlemesi ve geliştirilmesi, gelecekte daha fazla yenilik ve fayda sağlayacaktır.

1.3. İnvölüsyonel Sinir Ağları

Görüntü işleme ve derin öğrenme alanlarında yaşanan hızlı ilerlemeler, bilgisayarla görme sistemlerinin performansını yükseltirken, karmaşıklığını da artırmıştır. Bu ilerlemelerin temelinde, ESA'lar gibi evrişim (konvolüsyon) tabanlı mimarilerin etkisi büyüktür. Özellikle, ESA'lar görüntü sınıflandırma, nesne algılama ve görüntü segmentasyonu gibi görsel görevlerde olağanüstü başarılar elde etmiştir (Hoeser ve diğ., 2020). Ancak, geleneksel konvolüsyon tabanlı yaklaşımların bazı belirli sınırlamaları mevcuttur. Konvolüsyon işlemi, uzamsal-agnostik bir yapıya sahiptir, yani konvolüsyon çekirdekleri görüntünün herhangi bir konumunda aynı şekilde çalışmaktadır. Bu özellik, konvolüsyon çekirdeklerinin farklı uzamsal konumlara göre çeşitli görsel kalıplara uyum sağlama yeteneğini kısıtlamaktadır (Li ve diğ., 2021). Ayrıca, konvolüsyon işlemi kanal-spesifik özelliklere dayanmaktadır. Farklı kanallarda kodlanmış çeşitli bilgilerin toplanmasıyla oluşan bu yapı, konvolüsyon çekirdeklerinin yüksek uyarlanabilirliğini sağlamaktadır. Ancak bu yapı aynı zamanda konvolüsyon çekirdeklerinin sayısını çoğaltarak hesaplama karmaşıklığını artırmaktadır.

Bu tez kapsamında, geleneksel konvolüsyon tabanlı yaklaşımların sınırlamalarını aşmak için yeni bir sinir ağı yapısı olan "*İnvolüsyon*" kullanılacaktır. İnvolüsyon, konvolüsyon ile karşılaştırıldığında simetrik olarak ters içsel (zıt) özelliklere sahiptir; uzamsal-spesifik ve kanaldan-bağımsız bir işlem sunmaktadır (Li ve diğ., 2021). Bu gelişmiş yapı, daha geniş bir uzamsal modelleme yeteneği sağlamakta ve hesaplama karmaşıklığını azaltmaktadır.

Bu tez kapsamında, HSG verilerinin analizi için İSA'ların teorik temelleri incelenmekte, etkinliğini göstermek amacıyla yeni modeller geliştirilmekte ve bu modellerle çeşitli deneyler ve analizler yapılması hedeflenmektedir. Bu deneylerin, İSA'ların geleneksel konvolüsyon tabanlı yaklaşımlara göre avantajlarını ve dezavantajlarını ortaya koyması ve İSA'ların gerçek dünya görüntü işleme uygulamalarında ne kadar etkili olduğunu göstermesi beklenmektedir. İSA'ların geleneksel konvolüsyon tabanlı yaklaşımların ötesine geçerek yeni bir görüntü işleme paradigması sunacağı düşünülmektedir. Bu paradigma, daha geniş bir uzamsal modelleme yeteneği ve hesaplama karmaşıklığının azalması gibi avantajlarla birlikte, çeşitli görüntü işleme görevlerinde daha etkili çözümler sunabilir.

1.4. Araştırma Soruları ve Hipotezler

Görüntüleme teknolojileri ve derin öğrenme yöntemlerinin bir araya gelmesi, HSG verilerinin analizi alanında önemli bir ilerleme sağlamaktadır. Bu sentez, çeşitli endüstrilerde yeni uygulamaların keşfedilmesine ve bilimsel araştırmalarda daha kapsamlı analizlerin yapılmasına olanak tanımaktadır. Bu çalışmanın amacı, İSA'lar gibi yeni sinir ağı yapılarının HSG verilerinin analizindeki potansiyelini değerlendirmektir. Bu bağlamda, araştırma soruları ve hipotezler aşağıdaki gibidir:

- 1) HSG verilerinin İSA'lar ile işlenmesi, geleneksel konvolüsyon tabanlı yaklaşımlara kıyasla hangi avantajları sağlar?
- 2) İSA'lar, HSG verilerinin analizinde hangi özel zorlukları aşabilir ve hangi alanlarda daha etkili sonuçlar sağlayabilir?
- 3) İSA'lar, HSG verilerindeki yüksek boyutluluk ve karmaşıklık gibi zorluklarla nasıl başa çıkabilir ve veri işleme sürecini nasıl optimize edebilir?
- 4) Geleneksel evrişim tabanlı yöntemlere kıyasla, İSA'lar HSG verilerinde daha geniş bir uzamsal modelleme yeteneği sağlar mı? Bu durum hangi tür uygulamalarda faydalı olabilir?

- 5) İSA'ların HSG verileri üzerindeki performansı, farklı uygulama alanları için ne gibi sonuçlar doğurabilir? Örneğin, çevre izleme ve tıp uygulamalarında nasıl bir katma değer sağlayabilirler?
- 6) İSA'lar, HSG verilerinin analizinde hangi belirgin özellikleri veya spektral imzaları daha başarılı bir şekilde tanımlayabilir ve sınıflandırabilir? Bu, belirli endüstriyel uygulamalar için nasıl bir potansiyel sunar?
- 7) İSA'lar ve geleneksel konvolüsyon tabanlı yöntemler arasında performans karşılaştırmaları yapılırken, hangi kriterler ve ölçütler dikkate alınmalıdır? Bu karşılaştırmalar, hangi algoritmaların hangi koşullarda daha uygun olduğunu belirlemede yardımcı olabilir?

Bu araştırma soruları, İSA'ların HSG verilerinin analizindeki potansiyelini ve etkinliğini değerlendirmeyi, geleneksel yöntemlerle karşılaştırmayı ve belirli uygulama alanlarında nasıl kullanılabileceklerini anlamayı amaçlamaktadır. Bu soruların yanıtları, bu yeni sinir ağı yapısının pratik uygulamalardaki değerini ve gelecek projeksiyonunu belirlemeye yardımcı olacaktır.

1.5. Tezin Yapısı

Bu tez, HSG alanında yeni bir derin öğrenme yöntemi olan İSA kullanımı üzerine bir araştırmayı içermektedir. İlk olarak, Kaynak Araştırması bölümünde HSG'de konvolüsyon ve involüsyon tekniklerinin uzaktan algılama, yeryüzü gözleme ve biyomedikal görüntüleme alanlarında nasıl kullanıldığı incelenmektedir. Ayrıca, ön işleme ve boyut indirgeme yöntemlerinin HSG verilerine nasıl uygulandığı ve bu yöntemlerin geliştirilen İSA modellerinin performansına etkisi de detaylı bir şekilde ele alınmaktadır.

Materyal ve Yöntem bölümünde, HSG çalışmalarında kullanılan veri setleri ve bu veriler üzerinde uygulanan yöntemler detaylı bir şekilde açıklanmaktadır. Uzaktan algılama ve yeryüzü gözleme veri setleri arasında Indian Pines (IP), Pavia University (PU), Salinas Scene (SA) ve Kennedy Space Center (KSC) gibi kamuya açık veri setleri bulunmaktadır. Bunlar, farklı coğrafi alanlardan elde edilen HSG verilerinden oluşmakta ve çeşitli spektral imzalar içermektedir. Biyomedikal görüntü veri seti, **"Hiperspektral Görüntüleme ve Yapay Zekâ Kullanılarak Yenidoğanlar İçin Ön-Teşhis Sisteminin Geliştirilmesi"** başlıklı TÜBİTAK projesi (Proje No: 122E021) kapsamında elde edilmiş olup, belirli tıbbi durumları değerlendirmek için özel olarak

tasarlanmış HSG verilerinden oluşur. Veri toplama süreci ile ön işlem adımları ayrıntılı olarak açıklanmaktadır. Yöntemler kısmında, farklı boyutlara sahip konvolüsyon taslakları ve involüsyon tasarımının yanı sıra boyut indirme yöntemleri ve derin öğrenme modellerinde kullanılan özel yapılar ele alınmaktadır. Ayrıca, model eğitimi ve performans değerlendirme ölçütleri gibi deneysel ayarlar da detaylı bir şekilde açıklanmakta, böylece çalışmanın metodolojik temeli sağlamlaştırılmaktadır.

Araştırma Sonuçları ve Tartışma bölümü hem uzaktan algılama hem de biyomedikal görüntüleme deneylerinin sonuçlarını içermektedir. Uzaktan algılama ve yeryüzü gözleme deneyleri kapsamında, önerilen model olan *Involutorial Residual Spectral Network (IRSN)* ile gerçekleştirilen deneyler ve bu deneylerin sonuçları ayrıntılı bir şekilde incelenmiştir. Ayrıca, bu deneylerde elde edilen sonuçların, eğitim detayları ve deneysel tartışma bölümleriyle birlikte sunulması, modelin performansının kapsamlı analizini sağlamıştır. Öte yandan, biyomedikal görüntüleme deneylerinde ise özel olarak tasarlanan involüsyon tabanlı HarmonyNet, MC-I²Net ve HybridCISN gibi modellerin performansı üzerinde durulmuştur. Bu modellerin eğitim detayları, sınıflandırma sonuçları ve ablasyon analizi gibi farklı açılardan kapsamlı olarak incelenmesi, yenidoğan sağlık durumunun otomatik tespiti ve hastalıkların teşhisi için uygunluğunu gözden geçirmiştir. Modellerin performansını değerlendirmek için farklı yaklaşımlarda kurgulanmıştır. Ayrıca, boyut indirgeme yöntemlerinin etkisinin değerlendirildiği kısımda, İSA modelinin performansı üzerine elde edilen deneysel bulgular ve bu sonuçların tartışılması da bulunmaktadır. Bu bölüm, elde edilen bulguların özeti, çalışmanın sınırlamaları ve güçlü yönlerinin belirlenmesi gibi geniş kapsamlı bir inceleme sunmaktadır.

Sonuçlar ve Öneriler bölümünde, araştırmanın ana bulguları özetlenmekte ve tezin katkıları vurgulanmaktadır. Sonuçlar kısmında, yeni önerilen modellerin başarısı vurgulanmakta ve uzaktan algılama, yeryüzü gözleme ve biyomedikal görüntüleme alanlarında önemli ilerlemeler kaydedildiği görülmektedir. Öneriler kısmında, ileriye dönük araştırmalar için involüsyon tabanlı modellerin incelenmesi ve optimize edilmesi, İSA'ların farklı uygulamalarda kullanımı ve boyut indirgeme yöntemlerinin değerlendirilmesi gerektiği belirtilmektedir. Ayrıca, gelecekteki araştırma önerileri ve pratik uygulama alanları üzerine öneriler sunulmaktadır.

2. KAYNAK ARAŞTIRMASI

Yapay zekâ alanında, özellikle HSG veri analizi ve sınıflandırması için, HSG verilerinden özellik çıkarımı manuel veya otomatik yöntemlerle gerçekleştirilmektedir. Bu yaklaşımlar, HSG verilerinden anlamlı bilgiler çıkarmak için farklı stratejileri kullanmaktadır. İlk zamanlarda, manuel özellik çıkarma ve geleneksel makine öğrenimi sınıflandırması yaygın olarak kullanılmıştır (Archibald and Fann, 2007; Guo ve diğ., 2008) ve bu eğilim uzun bir süre devam etmiştir (Audebert ve diğ., 2019; Okwuashi and Ndehedehe, 2020). Ancak, derin öğrenme tekniklerinin gelişimi otomatik özellik çıkarımının önemini artırmıştır. Bu gelişmeler, derin öğrenme tekniklerinin kapsamlı bir şekilde araştırılmasıyla işaretlenen yeni HSG veri analizi ve sınıflandırma yöntemlerinin ortaya çıkmasına neden olmuştur. Otomatik özellik çıkarımına doğru geçiş, derin öğrenmenin yapay zekâ alanında HSG veri analizi ve sınıflandırmasındaki dönüştürücü etkisinin altını çizmektedir.

2.1. Hiperspektral Görüntülemede Konvolüsyon ve İnvolüsyon Kullanımı

HSG alanında, konvolüsyon ve involüsyon gibi evrişim temelli tekniklerin kullanımı oldukça kritiktir. Bu teknikler, görüntü işleme ve derin öğrenme alanlarında önemli bir role sahiptir. Bu alt başlıkta, literatür taraması sonucunda HSG için konvolüsyon ve involüsyon tekniklerinin kullanımına ve bu tekniklerin sağladığı avantajlara ve dezavantajlara odaklanılmıştır.

Konvolüsyon tabanlı yaklaşımlar, HSG verilerinin analizinde yaygın olarak kullanılmaktadır. Bu yaklaşımlar özellikle ESA mimarilerinde sıkça görülmektedir. ESA'lar, görüntü sınıflandırma, nesne tespiti ve görüntü segmentasyonu gibi görevlerde etkili sonuçlar vermektedir. Konvolüsyon katmanları, görüntü verilerini filtreleyerek özellik haritalarını çıkarmakta ve bu özelliklerin daha yüksek seviyeli temsillerini oluşturmaktadır. Bu sayede, HSG verilerin karmaşıklığını yönetmek ve önemli özellikleri vurgulamak mümkün olmaktadır.

İnvolüsyon, son yıllarda HSG alanında dikkat çeken konulardan birisidir. Konvolüsyonun simetrik tersine bir dönüşü olarak tanımlanan involüsyon, uzamsal-spesifik ve kanaldan-bağımsız bir işlem sunmaktadır. Bu özellikleri sayesinde, involüsyon tabanlı yaklaşımlar daha geniş bir uzamsal modelleme yeteneği sunmakta ve

hesaplama karmaşıklığını azaltmaktadır. Bu avantajlar, HSG verilerin daha etkili bir şekilde işlenmesini ve önemli bilgilerin çıkarılmasını sağlamaktadır.

Bu bölümde, literatürde yapılan çalışmaların kapsamlı bir incelenmesi yapılacak, konvolüsyon ve involüsyon tabanlı yaklaşımların HSG verilerinin analizi üzerindeki etkisi ile bu tekniklerin uzaktan algılama, yeryüzü gözleme ve biyomedikal alanlarında yapılan uygulamaları verilecektir.

2.1.1. Uzaktan Algılama ve Yeryüzü Gözlemede

ESA'lar, HSG veri uygulamalarında giderek artan bir ilgi görmektedir. Günümüzde, HSG verilerini analiz etmek için uzamsal, spektral ve spektral-uzamsal özellikleri çıkarmayı amaçlayan çeşitli ESA modelleri kullanılmaktadır. ESA'ların HSG verileri üzerinde eğitilmesi, nesnelerin uzamsal dağılımlarını, spektral özelliklerini ve bunların birleşimini daha etkili bir şekilde anlamalarını sağlamaktadır.

Literatürde, spektral bilgilerin yakalanması için dalga boyu boyunca yoğunluk değerlerini kullanan 1B evrişim katmanları dahil edilmiştir. Bu yöntemlerin, Huang ve diğ., 2022 ve Hu ve diğ., 2023 tarafından yapılan çalışmalarda HSG veri sınıflandırmasında çok önemli olduğu gösterilmiştir. Bu özellik çıkarma yöntemleri, bu alanda yaygın olarak tanınan ve kullanılan VGG (Gao ve diğ., 2021) ve ResNet (Priya ve Rajkumar, 2022) gibi iyi bilinen ESA mimarilerine başarıyla entegre edilmiştir.

HSG verilerin analizinde, uzamsal bilgiler genellikle orijinal HSG veri küpünden uzamsal kısımların kırılması da dahil olmak üzere çeşitli boyut indirgeme teknikleri ve yöntemleri aracılığıyla spektral boyutların azaltılması sonucu elde edilmektedir. Makantasis ve diğ., 2015 yılında geleneksel yöntemlerden farklı olarak derin öğrenmeye dayalı bir sınıflandırma yaklaşımı önermişler ve HSG veri analizi için bir 2B-ESA kullanmışlardır. Liang ve Li, 2016 yılında Seyrek Kodlama (SK) kullanarak bir 2B-ESA modeli için uzamsal özellikleri tespit etmiştir. Hsieh ve Kiang, 2020 yılında TBA'dan türetilen tek bir kanal üzerinde eğitilmiş 2B-ESA modeli kullanmıştır. Başka bir çalışmada Zhong ve diğ., 2021 yılında farklı spektral bantların katkılarını değerlendirmek için bir 2B-ESA modeli kullanarak HSG veri sınıflandırmasına bilgi katkısı sağlamak için bir Kompakt Bant Ağırlıklandırma (KBA) modülünü tanıtmıştır.

Spektral-uzamsal modeller, HSG veri küplerinden hem spektral hem de uzamsal bilgileri entegre ederek kapsamlı bir analiz sunar. ESA'ları kullanarak, 1B-ESA spektral

özellikleri çıkarırken, 2B-ESA uzamsal bilgileri çıkarmaktadır (Hu ve diğ., 2022). Bu yaklaşım, her bir pikselin hem spektral bilgilerini hem de uzamsal yapılarını anlamak için esnek bir strateji sağlayarak HSG verilerinin analizini ve sınıflandırılmasını geliştirmektedir (Datta ve diğ., 2022). Ek olarak, 3B-ESA modeli spektral-uzamsal sınıflandırma için kullanılmış ve doğrudan üst düzey özellikler çıkarılmıştır. Bu model hem spektral hem de uzamsal bilgileri aynı anda dikkate alarak HSG verilerin daha ayrıntılı ve daha bütünsel bir şekilde analiz edilmesini sağlamıştır. Spektral-uzamsal çıkarım için tasarlanan önemli modeller arasında, He ve diğ. tarafından 2017 yılında çok ölçekli spektral ve uzamsal özellikleri çıkarmayı amaçlayan çok ölçekli M3D-CNN modeli bulunmaktadır. Lee ve Kwon, 2017 yılında spektral-uzamsal özellikleri mevcut derin ağlara kıyasla daha fazla derinlik ve genişlik ile karakterize edilen bağlamsal bir derin evrişimli sinir ağı modeliyle birleştirdikleri bir çalışma yapmıştır. Zhong ve diğ., 2017 yılında SSRN modelini önererek, artık bloklar aracılığıyla bilgileri korurken 3B konvolüsyon çekirdekleri ile spektral-uzamsal özellikleri çıkarmayı amaçlamıştır. Paoletti ve diğ., 2019 yılında ise 3B konvolüsyon katmanlarına sahip 3B-ESA modelini tasarlamıştır.

Spektral boyutlardan ayırt edici özellik haritaları çıkarmada 2B-ESA'nın sınırlamalarını ve derin 3B-ESA'nın artan hesaplama karmaşıklığını göz önünde bulunduran Roy ve diğ., 2019 yılında bu zorlukların üstesinden gelmek için 2B-ESA ve 3B-ESA yapılarını birleştiren HybridSN modelini tanıtmıştır. HybridSN modeli, 2B ve 3B konvolüsyon katmanlarının entegrasyonu yoluyla spektral-uzamsal özellikleri verimli bir şekilde çıkarmaktadır. Bir diğer çalışmada, bağımsız 2B ve 3B konvolüsyonel sinir ağlarıyla ilişkili performans sorunlarını ele almak için özellik haritalarını bantlar arasında birleştirerek ve kovaryans havuzlama yoluyla boyutu azaltarak sınıflandırma doğruluğunu artıran hibrit bir ESA modeli önerilmiştir (Zheng ve diğ., 2021). Yang ve diğ., 2022 yılında CMR-CNN adında bir çapraz karıştırma artık ağ modelini sunarak hem uzamsal hem de spektral bilgileri çıkarmayı amaçlamıştır. Başka bir çalışmada Fırat ve diğ., 2023 yılında başlangıç modülünü içeren ve 2B-ESA ve 3B-ESA'larla hibrit bir yaklaşım kullanan Hybrid3D/2D modelini geliştirmiştir.

HSG analizindeki başarılarına rağmen, ESA yönteminin kendine özgü sınırlamaları bulunmaktadır. Geleneksel ESA'lar özellik çıkarımı için bir konvolüsyon işlemi kullanmakta, uzamsal bağımsızlığı vurgulamakta ve kanal temsiliyi göz ardı etmektedir. Bu ihmal, farklı kanallar arasındaki korelasyonların tam olarak

anlaşılmasını engellemektedir (Li ve diğ., 2023). Buna karşılık, bu çalışma konvolüsyon yerine involüsyon çekirdeklerini savunmaktadır. Uzamsal-spesifik ve kanaldan-bağımsız olan involüsyon, farklı kanallar arasındaki korelasyonların daha etkili bir şekilde araştırılmasını kolaylaştırmaktadır. Model geliştirme aşamasında, veriye özgü involüsyon çekirdekleri kullanılarak ayırım yeteneği ve ifade kapasitesi artırılmaktadır (Cihan ve Ceylan, 2024). Amaç, daha az çekirdekle daha anlamlı özellikler çıkarmak, minimum parametre ile yüksek performans elde etmek ve genel veriye özgü özellikleri daha etkili bir şekilde yakalamaktır. Üstelik, involüsyon çekirdekleri HSG veri analizinde önemli olan kanal korelasyonlarına odaklanma avantajı sunmaktadır. Farklı kanallar arasındaki ilişkilerin anlaşılması, doğru ve kapsamlı bir özellik çıkarma süreci için kritiktir (Cihan ve Ceylan, 2024). Bu nedenle, involüsyon çekirdekleri HSG veri analizi için önemli bir kapasite göstermektedir.

Uzaktan algılama ve yeryüzü gözleme uygulamaları için bazı çalışmalarda HSG verilerini analiz etmek için involüsyon kullanılmıştır. Meng ve diğ., 2021 yılında yapmış oldukları bir çalışmada, HSG veri sınıflandırmasında yeni bir yaklaşım olarak Deep Residual Involution Network (DRIN) modelini önermişler ve bu modelin uzun menzilli uzamsal etkileşimleri başarılı bir şekilde modellediğini belirtmişlerdir. DRIN modeli, geleneksel ESA'lardan daha iyi sınıflandırma sonuçları elde ederek involüsyonun HSG sınıflandırması için önemli bir potansiyeli olduğunu göstermiştir. Bir başka çalışmada ise Shao ve diğ., 2022 yılında HSG sınıflandırmasında özel Çok Katmanlı Algılayıcı (ÇKA) modellerin sıkça önerildiğini ancak bunların yetersiz uzamsal bilgi çıkarma sorunları olduğunu belirtmişlerdir. Bu bağlamda, spatial-spectral involution multilayer perceptron network (SSIN) isimli yeni bir model önererek, SSIN'in bazı yeni yöntemlere göre üstün performans sergilediğini göstermişlerdir.

Bir başka çalışmada, HSG sınıflandırmasında yaygın olarak kullanılan ESA'ların yüksek hesaplama maliyeti ve konvolüsyon çekirdeklerindeki gereksizliklerine alternatif olarak, spektral bakış açısından HSG'leri ele alıp involüsyon operatörü ile yeni bir model olan ESSINet önerilmiştir (Lv ve diğ., 2022). HSG ve LiDAR verilerini sınıflandırma için adaptif çok ölçekli spektral-uzamsal iyileştirme ağı olan AMSSE-Net Gao ve diğ., 2023 tarafından tanımlanmıştır. AMSSE-Net, involüsyon operatörü ile spektral özelliklerin derinlemesine çıkarılmasını ve çeşitli kaynaklardan gelen özelliklerin etkin bir şekilde birleştirilmesini sağlayan bir mekanizma sunmuştur.

Yapılan çalışmalar incelendiğinde involüsyon yapıları, yüksek çözünürlüklü spektral ve uzamsal verilerin işlenmesinde oldukça uygun olup, uzaktan algılama ve yeryüzü gözleme alanlarında önemli bir rol oynamıştır. Bu yapılar, uzamsal ve spektral bilgiyi birleştirme yeteneği sayesinde doğru analiz imkânı sunmuş ve uzun menzilli uzamsal etkileşimleri daha etkili bir şekilde modelleyerek sınıflandırma ve tanıma performansını artırmıştır. Ayrıca, daha düşük hesaplama maliyetiyle büyük ölçekli verilerin işlenmesinde avantaj sağlamıştır. Bu nedenle, involüsyon yapıları, uzaktan algılama ve yeryüzü gözleme alanlarında kullanımı giderek artan bir öneme sahiptir.

2.1.2. Biyomedikal Görüntülemeye

HSG, biyomedikal görüntüleme alanında giderek artan ilgiye sahip bir görüntüleme teknolojisidir. Bu teknoloji, elektromanyetik spektrumun geniş bir yelpazesini kullanarak nesnelerin spektral imzasını analiz etmeyi sağlamaktadır. Geleneksel görüntüleme yöntemlerine kıyasla, HSG, dokuların kimyasal bileşimini, yapısal özelliklerini ve fizyolojik durumlarını daha ayrıntılı bir şekilde incelemek için benzersiz bir kapasite sunmaktadır. Bu özellikleri sayesinde, tıbbi teşhis ve görüntüleme, cerrahi prosedürlerin yönlendirilmesi, biyolojik örneklerin analizi ve tıbbi araştırmalar gibi birçok alanda önemli uygulamalara sahiptir. HSG, hastalıkların erken teşhisi, tedaviye yanıtın izlenmesi ve gerçek zamanlı tarama gibi kritik alanlarda büyük bir potansiyel taşımaktadır. Bu nedenle, biyomedikal araştırmacılar ve sağlık profesyonelleri arasında HSG'nin kullanımıyla ilgili artan bir ilgi gözlemlenmektedir.

Literatürde, HSG ile elde edilen çok boyutlu biyomedikal verilerin analizi ve sınıflandırılması için konvolüsyon tabanlı yöntemler sıklıkla kullanılmıştır. Wang ve diğ., 2017 yılında lökosit sınıflandırması için 3B-ESA ve 3B dikkat modülünü birleştiren bir derin-hiper 3B konvolüsyonel ağı tanıtmışlardır. Huang ve diğ., 2018 yılında, küçük örneklem boyutlu durumlarda hücrelerin sınıflandırma doğruluğunu artırmak için Gabor filtreleriyle birleştirilmiş ESA'lar kullanarak yeni bir yöntem önermişlerdir. Bu yöntem, Medikal Hiperspektral Görüntülemenin (MHSG) derin özelliklerini çıkarmayı amaçlamaktadır. Wei ve diğ., 2019 yılında EtoE-Net modelini önererek, orijinal MHSG ile ana bant görüntüleri arasında piksel bazında eşleme yaparak küresel olarak birleştirilmiş özellikler oluşturan iki kanallı bir ESA kullanmışlardır. Ardından, Huang ve diğ., 2020 yılında kan hücrelerini sınıflandırmak

için Gabor filtreli bir sınıflandırma çerçevesi olan MGCNN isimli derin konvolüsyonel ağı geliştirmişlerdir.

Kanser teşhisi alanında, ESA'lar genellikle HSG verilerinin sınıflandırılması için kullanılmaktadır. Sommer ve diğ., 2018 yılında HSG verilerine dayanan ESA'lar ile nefronları sınıflandırmışlardır. Li ve diğ., 2019 yılında gastrik kanserlerin sınıflandırılması için ResNet34 tabanlı derin öğrenme mimarisini kullanmışlar ve modelin %96'dan fazla sınıflandırma doğruluğuna ulaştığını göstermişlerdir. Bengs ve diğ., 2020 yılında HSG kullanarak daha zorlu tümör kategorisi sınıflandırma zorluklarını incelemişler ve bu amaçla bir CGRU ve DenseNet birleşimi kullanmışlardır. Grigoriu ve diğ., 2021 yılında gerçekleştirdikleri çalışmada HSG endoskopisi verilerinin çevrimiçi sınıflandırılması için ESA'lar kullanmışlar ve derin öğrenme algoritmalarının renk tabanlı sınıflandırmada büyük bir potansiyele sahip olduğunu göstermişlerdir.

Manni ve diğ., 2020 yılında Glioblastoma tümörlerinin spektral-uzamsal özelliklerini kullanarak 4'lü sınıf ayrımı için yeni bir 3B-2B-ESA hibrit modeli önermişlerdir. Bu hibrit model, geleneksel ESA'lara kıyasla daha doğru sonuçlar vermiştir. Collins ve diğ., 2022 yılında yapmış oldukları çalışmada HSG ile kolorektal tümörlerin otomatik tespiti için son teknoloji ESA'lar geliştirmişlerdir. Bu çalışmada, 3B-ESA'ların, spektral-uzamsal bilgiyi kullanma yetenekleri sayesinde, gelecekte tahrip edici biyopsiler için uygun bir çözüm olabileceğini kanıtlamışlardır.

2022 yılında gerçekleştirilen bir çalışmada Cihan ve diğ., HSG ve 3B-ESA tekniklerini kullanarak prematüre bebeklerin sağlık durumlarını hızlı ve etkili bir şekilde değerlendirmeyi hedeflemişlerdir. Yapılan bu araştırmanın sonuçları hem HSG hem de 3B-ESA yöntemlerinin, prematüre bebeklerin sağlıklı ve sağlıklısız durumlarının değerlendirilmesinde oldukça etkili olduğunu göstermiştir. Bununla birlikte, 2023 yılında Wang ve diğ., HSG sınıflandırması için yenilikçi bir derin öğrenme yöntemi olan derin Deep Margin Cosine Autoencoder (DMCA) modelini önererek, tümör teşhis doğruluğunu önemli ölçüde artırmayı hedeflemişlerdir. Wang ve ekibi, DMCA modelinin umut verici sonuçlar sergilediğini belirtmişlerdir; ancak, bu modelin farklı veri kümeleri üzerinde sağlamlığını ve gerçek dünya klinik ayarlarında uygulanabilirliğini değerlendirmek için daha fazla araştırma yapılmasının gerektiğini ifade etmişlerdir.

Konvolüsyon tabanlı önerilen ESA modellerinin bazı zorlukları mevcuttur. Özellikle, HSG'nin büyük ve yüksek boyutlu veri setleri olması, ESA'ların eğitilmesi ve işlenmesi için hesaplama gücü ve veri yönetimi açısından zorluklar ortaya çıkarmaktadır. Ayrıca, HSG'nin doğru bir şekilde işlenmesi ve yorumlanması için özel olarak tasarlanmış yöntemler ve eğitim teknikleri gerekmektedir. Konvolüsyon operatörünün sınırlamalarını ortadan kaldırmak için sınırlı sayıda da olsa bazı biyomedikal çalışmalarda involüsyon operatörü kullanılmıştır. Bu çalışmalar aşağıda özetlenmiştir.

Asiri ve diğ., 2023 yılında beyin tümörü sınıflandırması için involüsyonel sinir ağları (InvNets) kullanarak geleneksel ESA'lara kıyasla daha az parametre ile daha yüksek verimlilik elde etmişlerdir. InvNets mimarisi, beyin görüntülerinde karmaşık özellikleri daha iyi yakalamak için uzamsal-spesifik ve kanaldan-bağımsız bir involüsyon çekirdeği kullanmış ve standart performans metriklerinde geleneksel ESA'lara göre daha yüksek doğruluk sağlamıştır. Nidamanuri ve diğ., 2023 yılında cilt kanseri erken teşhisi için SCED adlı entegre bir yaklaşım önermişlerdir. Önerdikleri yöntem, sezgisel arama involüsyon bloğu ile %84.7 test doğruluğu elde etmiş ve EfficientNet-İSA mimarisi ile %93.71 test doğruluğu sağlamıştır. 2024 yılında yapılan bir başka çalışmada Huang ve diğ., kalça ultrason görüntülerindeki belirleyici noktaları tespit etmek için İnvolüsyon Transformer tabanlı bir U-Net (IT-UNet) ağı önermişlerdir. IT-UNet'in, uzamsal bilgileri ve uzun menzilli bağımlılıkları yakalayarak özellik temsilini iyileştirdiğini ve en iyi tespit performansını sergilediğini gözlemlemişlerdir.

Yukarıda belirtildiği gibi, literatürde farklı görüntüleme teknikleriyle birlikte İSA'lar kullanılarak yapılmış çalışmalar bulunmasına rağmen, biyomedikal HSG verileri ve İSA'ların birlikte kullanıldığı herhangi bir çalışma mevcut değildir. Bu tez çalışması kapsamında özel bir veri setinin oluşturulması ve bu veri seti üzerinde gerçekleştirilecek çalışmalar hem klinik uygulamalara hem de araştırma alanına önemli katkılarda bulunacaktır. Bu çalışmalar, İSA ve HSG verilerinin birlikte değerlendirildiği ve involüsyon temelli modellerin geliştirildiği bir çerçeve sunarak, biyomedikal uygulamalarda karar alma süreçlerini destekleyecektir. Sonuç olarak, bu çalışmaların literatüre sağlayacağı katkı, klinik uygulamalarda daha etkili ve doğru tedavi yaklaşımlarının geliştirilmesine yönelik önemli bir adım olacaktır.

2.2. Hiperspektral Görüntüleme için Ön İşleme ve Boyut İndirme Yöntemlerinin Kullanımı

HSG verileri, iki uzamsal boyutu ve bir spektral boyutu kapsayan önemli miktarda bilgi içeren karmaşık veri kümeleridir. HSG verilerinin doğasında var olan yüksek boyutluluk, veri depolama, işleme ve analiz açısından zorluklar ortaya çıkarmaktadır (Thudumu ve diğ., 2020). Çok boyutlu HSG veri kümeleri, hesaplama kaynaklarından etkin bir şekilde yararlanmak ve depolama alanını verimli bir şekilde yönetmek için özel yöntemlerin kullanılmasını gerektirmektedir.

Veri analizinin karmaşıklığı, özellikle spektral kanalların çokluğu ve veri kümelerinin büyüklüğü göz önüne alındığında, analiz ve sınıflandırma süreçlerinde zorlayıcı durumlar oluşturmaktadır (Lupu ve diğ., 2022). Bu zorlukların ele alınmasında, sınıflandırma algoritmalarının, veri ön işleme adımlarının ve özellik seçimi ile boyut azaltma tekniklerinin önemi büyüktür. Bu yöntemler, yüksek boyutlu HSG verilerinin doğasında bulunan karmaşıklığı kontrol altına almak ve analiz sürecini daha kolay hale getirmek için çok önemli bir rol oynamaktadır. Uygun sınıflandırma algoritmaları ve veri ön işleme teknikleri, HSG verilerinin daha etkili bir şekilde işlenmesini ve yorumlanmasını sağlamaktadır, böylece zengin ve karmaşık veri ortamından anlamlı bilgi ve örüntüler çıkarılabilmektedir.

HSG, geniş bir elektromanyetik spektrumdan kaynaklanan yüzlerce hatta binlerce spektral bantla çalışmayı gerektirdiğinden, bu büyük veri miktarı işleme ve analizde zorluklar yaratmaktadır. Bu nedenle, HSG verisinin ön işleme aşamasında spektral bant seçimi önemli bir adımdır (Fu ve diğ., 2022). Özellikle uygulama alanına veya probleme özgü spektral bantların seçilmesi, veri kümesini basitleştirerek, analiz sürecini iyileştirmektedir. Bu adım, veri toplama sürecinde bazı bantlarda oluşan istenmeyen gürültüleri ortadan kaldırarak ve analizle ilgili spektral bantları vurgulayarak veri kümesinin kalitesinin iyileştirilmesine katkıda bulunmaktadır (Singh ve Karthikeyan, 2022). Literatürde yer alan çok sayıda çalışmada, farklı yöntemler kullanılarak HSG sınıflandırma performansını artırmak için spektral bant seçimi yapılmıştır (Ayala ve diğ., 2022; Zhu ve diğ., 2022; Li ve diğ., 2023; Cihan ve diğ., 2023).

HSG verileri sıklıkla çeşitli kaynaklardan gelen gürültüleri içermektedir. Spektrum yumuşatma, bu gürültüleri azaltmak için kullanılmakta ve daha pürüzsüz ve

daha tutarlı veriler elde edilmektedir (Wang ve diğ., 2023). Matematiksel işlemler ve filtreleme teknikleri yoluyla elde edilen bu adım, spektral kirliliği ortadan kaldırarak analiz için daha güvenilir veriler sağlamayı amaçlamaktadır. Aynı zamanda, yüzeylerindeki önemli spektral özellikleri vurgulayarak nesnelerin karakterizasyonunu geliştirmektedir. Literatürde, Savitzky-Golay (Kiani ve diğ., 2023) ve Yerel Regresyon (Ulya ve diğ., 2023) gibi yöntemler HSG verilerindeki spektrumları yumuşatmak için uygulanmıştır. Bu teknikler, HSG verilerinin rafine edilmesinde önemli bir rol oynayarak daha doğru ve anlamlı analiz sonuçlarına katkıda bulunmaktadır.

HSG verileri, her pikselde çok sayıda spektral bant içeren yüksek boyutlu ve karmaşık verilerdir, bu da işlenmelerini zorlu hale getirmektedir (Morales ve diğ., 2021). Bu büyük veri kümeleri, analiz süreçlerini karmaşıktırabilir, hesaplama maliyetlerini artırabilir ve sınıflandırma algoritmalarının etkinliğini olumsuz etkileyebilir. Bu zorlukların üstesinden gelmek ve HSG verilerinden anlamlı bilgiler elde etmek için boyut indirgeme yöntemleri kritik bir rol oynamaktadır.

Boyut indirgeme yöntemleri, yüksek boyutlu HSG verilerini daha düşük boyutlu temsillemlere dönüştürmeyi amaçlamaktadır. Bu süreç, gereksiz ve gürültülü bilgilerin elemine edilmesini içerirken önemli spektral özelliklerin korunmasına odaklanmaktadır. Bu, verilerin daha anlamlı ve işlenebilir hale gelmesini sağlar. Ayrıca, boyut indirgeme yöntemleri, sınıflandırma algoritmalarının daha iyi performans göstermesine yardımcı olmaktadır (Zebari ve diğ., 2020).

Temel Bileşenler Analizi (TBA) (Jolliffe, 2002), Bağımsız Bileşenler Analizi (BBA) (Hyvärinen, 2013), Tekil Değer Ayrışması (TDA) (Boardman, 1989), t-Dağıtılmış Stokastik Komşu Gömme (t-SKG) (Van der Maaten ve Hinton, 2008), Yerel Doğrusal Gömme (YDG) (Roweis, and L. K. Saul, 2000), Negatif olmayan Matris Ayrışımı (NOMA) (Sra ve Dhillon, 2005) ve Spektral Gömme (SG) (Von Luxburg, 2007) gibi çeşitli boyut indirgeme teknikleri HSG verilerinin işlenmesinde yaygın olarak kullanılmaktadır. Bu yöntemler, yüksek boyutlu verileri daha yönetilebilir boyutlara indirirken (örneğin, yüzlerce banttan onlarca banda) önemli bilgiyi korumaktadırlar. Literatürde, HSG verilerine farklı boyut indirgeme yöntemleri uygulanmıştır. Örneğin; Huang ve diğ., 2012 yılında HSG saçılım özelliklerini çıkarmak için bir YDG boyut indirgeme yöntemini kullanmışlardır. Haque ve Mishu, 2019 yılında TBA tabanlı boyut indirgeme tekniği ve çok ölçekli ESA'dan oluşan hibrit bir yöntem önermiş ve kullandıkları uzaktan algılama veri kümesinde %99 doğruluk

oranı elde etmişlerdir. Hossain ve Hossain, 2019 yılında TBA, NOMA, BBA ve TDA gibi boyut indirgeme algoritmalarını kullanmanın sınıflandırma üzerindeki etkilerini ve performansını göstermek için deneysel çalışmalar yapmışlardır. Devassy ve George, 2020 yılında, t-SKG boyut indirgeme yöntemini kullanarak spektral benzerlikleri daha düşük boyutlara ölçeklemişlerdir. Fırat ve diğ., 2022 yılında TBA'ya ilave olarak BBA ve TDA gibi boyut indirgeme yöntemlerini kullanarak HSG sınıflandırma performansını artırmışlardır. 2023 yılında ise Huang ve diğ., HSG verilerindeki komşu bantlardan yerel olarak spektral gömülmeleri etkili bir şekilde öğrenmek için Split Grouping Embedding (SGE) modülünü kullanmışlardır. Bu çalışmalar, HSG verilerinin boyutunun indirgenmesi ve analiz sürecinin kolaylaştırılması amacıyla çeşitli yöntemlerin kullanılmasını göstermektedir.



3. MATERYAL VE YÖNTEM

3.1. Veri Setleri

Kamuya açık olarak bulunan veya probleme özgü olarak oluşturulan HSG veri setleri, araştırma ve geliştirme için kritik bir kaynak oluşturmaktadır. Bu veri setleri, farklı sensörlerden, platformlardan ve ortamlardan elde edilen görüntülerden oluşmakta ve genellikle etiketlenmiş veya etiketlenmemiş olarak bulunmaktadır. Etiketlenmiş veri setleri, her piksel için bir sınıf etiketi veya spektral imza içerirken, etiketlenmemiş veri setlerinde her pikselin hangi sınıfa ait olduğuna dair bir bilgi bulunmaz. Bu veri setleri, algoritma geliştirme, model eğitimi ve performans değerlendirmesi için kullanılabileceği gibi, HSG teknolojisinin yeni uygulamalarını keşfetmek için de değerli bir kaynak sağlamaktadır. Bu tez kapsamında uzaktan algılama ve yeryüzü gözleme ile medikal alandaki çeşitli HSG veri setleri, İSA ile analiz edilmiştir. Bu veri setlerine ait bilgiler, aşağıda iki başlık altında detaylandırılmıştır.


3.1.1. Uzaktan Algılama ve Yeryüzü Gözleme Veri Setleri

Uzaktan algılama ve yeryüzü gözleme, HSG ile elde edilen verilerin analizi ve yorumlanması yoluyla dünyanın yüzeyini inceleyen önemli bir bilimsel ve uygulamalı araştırma alanını oluşturmaktadır. Bu alanda kullanılan HSG veri setleri, tarımda bitki örtüsü sınıflandırması, çevresel izleme, arazi kullanımı analizi, kentsel planlama ve doğal afetlerin izlenmesi gibi çeşitli alanlarda kritik bir rol oynamaktadır. Bu tez kapsamında, kamuya açık olan HSG uzaktan algılama ve yeryüzü gözlemi için geliştirilmiş dört farklı HSG veri seti kullanılmıştır.

3.1.1.1. Indian Pines (IP) Veri Seti

Indian Pines (IP) HSG veri seti, 1992 yılında Kuzeybatı Indiana'daki Indian Pines test alanında 145×145 piksel alanı üzerinde yakalanan bir HSG veri koleksiyonudur (GIC, 2024). Bu veriler, yüksek spektral çözünürlüğü ile bilinen bir sensör olan hava görünür/kızılötesi görüntüleme spektrometresi (Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) kullanılarak yakalanmıştır. AVIRIS sensörü, geniş bir dalga boyu aralığında detaylı bilgi yakalama yeteneğine sahiptir. Veri seti, piksel başına 20 metrekarelik bir uzamsal çözünürlüğe sahip olan 0.4 - 2.5 mikrometre dalga boyu aralığında 220 spektral yansıma bandını içermektedir. Su


emilimi etkileriyle bozulan 20 bant elimine edilerek bant seçimi yapılmış ve geriye kalan 200 bant uygulamalar için kullanılmıştır. Veri seti, mısır, soya fasulyesi, buğday, yulaf, saman, çimen, çıplak toprak, ağaçlar, çalılar, yol, binalar ve su gibi 16 farklı arazi örtü sınıfını kapsamaktadır (Şekil 3.1).



Şekil 3.1. IP veri seti. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c) Kesin Referans görüntüsündeki renklere karşılık gelen sınıflar.

3.1.1.2. University of Pavia (UP) Veri Seti


University of Pavia (UP) HSG veri seti, 1996 yılında İtalya'daki Pavia Üniversitesi kampüsünde 610×340 piksel alanı üzerinde yakalanan bir HSG veri koleksiyonudur (GIC, 2024). Bu veriler, reflektif optik sistem görüntüleme spektrometresi (Reflective Optics System Imaging Spectrometer, ROSIS) sensörü kullanılarak elde edilmiştir. Veri seti, 0.43 - 0.90 mikrometre dalga boyu aralığında 115 spektral yansıma bandını içerir ve piksel başına 1.3 metrekairelik bir uzamsal çözünürlüğe sahiptir. Bant seçimi yapılarak gürültülü bantlar çıkarıldıktan sonra, uygulamalar için 103 spektral bant kullanılmıştır. Veri seti, asfalt, çayır, çakıl, ağaçlar, metal levhalar, çıplak toprak, asfalt, tuğlalar ve gölgeler gibi 9 farklı arazi örtü sınıfını içermektedir (Şekil 3.2).



Şekil 3.2. UP veri seti. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c) Kesin Referans görüntüsündeki renklere karşılık gelen sınıflar.

3.1.1.3. Salinas Scene (SA) Veri Seti


Salinas Scene (SA) HSG veri seti, Kaliforniya, ABD'deki Salinas Vadisi'nde 512×217 piksel alanı üzerinde yakalanan bir HSG veri koleksiyonudur (GIC, 2024). Bu veri seti, çeşitli tarımsal peyzajları kapsayan önemli HSG bilgileri içermektedir. Veriler, AVIRIS sensörü kullanılarak yakalanmış olup 0.4 - 2.5 mikrometre aralığında 224 spektral yansıma bandını içermektedir. Gürültülü bantlar çıkarılmış ve uygulamalar için 204 bant kullanılmıştır. Veri setinin piksel başına uzamsal çözünürlüğü 3.7 metredir. Bu veri seti 16 farklı arazi örtüsü sınıfını kapsamakta ve Salinas Vadisi'ndeki tarımsal peyzajlarda yaygın olarak bulunan çeşitli bitki türlerini, çıplak toprağı ve diğer bitkileri temsil etmektedir (Şekil 3.3).



Şekil 3.3. SA veri seti. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c) Kesin Referans görüntüsündeki renklere karşılık gelen sınıflar.

3.1.1.4. Kennedy Space Center (KSC) Veri Seti

Kennedy Space Center (KSC) HSG veri seti, Florida, ABD'deki Kennedy Uzay Merkezi'nde 512×614 piksel alanı üzerinde yakalanan bir HSG veri koleksiyonudur (GIC, 2024). Bu veri seti, Florida'daki Kennedy Uzay Merkezi'nde HSG verileri kullanılarak sulak alan bitki örtüsünün sınıflandırması için tasarlanmıştır. Veriler, AVIRIS sensörü kullanılarak yakalanmış olup 0.4 - 2.5 mikrometre aralığında 224 spektral yansıma bandını içerir. Gürültülü bantlar çıkarılmış ve uygulamalar için 176 bant kullanılmıştır. Veri seti yaklaşık 20 km yükseklikten oluşturulmuş olup 18 m uzamsal çözünürlük sağlamaktadır. Karmaşık arazi örtüsü dinamiklerinin nüanslı bir anlayışını sunan 13 farklı sınıfı kapsamaktadır (Şekil 3.4).



Şekil 3.4. KSC veri seti. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c) Kesin Referans görüntüsünde renklere karşılık gelen sınıflar.

3.1.2. Biyomedikal Görüntüleme Veri Seti


HSG biyomedikal veri setleri, tıbbi görüntüleme cihazları ve biyomedikal sensörler tarafından elde edilen HSG verilerini içeren önemli kaynaklardır. Bu veri setleri, biyolojik dokuların spektral özelliklerini inceleyerek derinlemesine analiz imkânı sunarlar. Tıbbi teşhis, görüntüleme analizi, spektral görüntüleme ve biyolojik modelleme gibi disiplinlerde kullanılan bu veri setleri, hastalık teşhisi, doku karakterizasyonu, cerrahi planlama ve tedavi takibi gibi birçok uygulama alanına hizmet etmektedir. Bu tez kapsamında kullanılan biyomedikal veri seti, "**Hiperspektral Görüntüleme ve Yapay Zekâ Kullanılarak Yenidoğanlar İçin Ön-Teşhis Sisteminin Geliştirilmesi**" başlıklı 122E021 proje numaralı TÜBİTAK projesi çerçevesinde 16 aylık bir süreçte elde edilmiştir. Bu veri seti, belirli hastalıklara ait tıbbi durumları değerlendirmek için özel olarak tasarlanmış HSG verilerinden oluşmaktadır. HSG sistemi ve veri toplama süreci ile veri seti tanımlaması ve ön işleme adımları, ayrıntılı olarak aşağıda açıklanmıştır.

3.1.2.1. Hiperspektral Görüntüleme Sistemi ve Veri Toplama

Yenidoğan sağlığı, bebeklerin yaşamlarının kritik bir döneminde sağlık durumlarını izlemek ve gerektiğinde hızlı müdahaleleri sağlamak açısından büyük önem taşımaktadır. Bu bağlamda, prematüre bebeklerden elde edilen spektral verileri kullanarak yenidoğanların sağlık durumunu İSA ile değerlendirmek amacıyla Selçuk Üniversitesi Yenidoğan Yoğun Bakım Ünitesinden (YYBÜ) HSG verileri titizlikle toplanmıştır. HSG verilerinin alınması için 01.03.2022 tarihli, 2022/125 karar sayılı etik kurulu raporu EK-1'de verilmiştir. HSG için kapsamlı ölçüm kurulumu Şekil 3.5'te gösterilmiştir.

HSG verileri, MS Spektral firması (Ankara, Türkiye) tarafından tasarlanmış bir HSG sistemini kullanarak elde edilmiştir. Görüntüleme sistemi, 0,5 m mesafeden 50

mm çapında ışık toplayabilen bir nokta spektrometresidir. TÜBİTAK projesinde kullanılmak üzere özel olarak tasarlanan sistem, Şekil 3.5(1)'de gösterilmiştir. HSG verilerini toplamak için noktasal ölçüm tekniği kullanılmıştır.



Şekil 3.5. Hiperspektral Ölçüm Kurulumu. (1) Hiperspektral Kamera Sistemi, (2) Yenidoğan, (3) İnkübatör, (4) Tripod, (5) Bilgisayar ve (6) Beyaz Referans Paneli.

Bu sistem, BROADCOM tarafından geliştirilen AFBR-S20M2VN Qmini VIS/NIR-Miniature USB spektrometresi ile donatılmıştır ve cihazın detaylı teknik özellikleri Çizelge 3.1'de verilmiştir. Yansıyan spektrum ölçümlerinin kalibrasyonu, Şekil 3.5(6)'da gösterildiği gibi BaSO₄ tabanlı beyaz referans panel kullanılarak gerçekleştirilmiştir.

Çizelge 3.1. AFBR-S20M2VN Qmini VIS/NIR-Miniature USB spektrometrenin teknik özellikleri.

Özellik	Değer
Dalga Boyu Aralığı	480-1100 nm
Spektral Çözünürlük	0.3 nm
Dalga Boyu Sayısı	2018
Odak Uzaklığı	50 mm
Izgara (Grating)	300 lines/mm
Giriş Yarığı	50 µm
Dinamik Aralık	1300:1
Pozlama Süresi	3 µs to 600 s

Işık kaynağı olarak halojen bir ampul kullanılmıştır (Şekil 3.5(1)). Ampül önünde kızılötesi (IR) kesici filtre bulunmamaktadır. Buradan çıkan ışık Zenitar-M 50mm f/1.9 MC lens ile 0.5 m öteye odaklanmaktadır. Bu lens üzerinde Anti-reflektif

(AR) kaplamanın olmamasından ötürü, sistemin IR performansı artmaktadır. Güç kaynağı ve lens üzerindeki iris kullanılarak ışık miktarı ayarlanabilmektedir.


Bu düzenekte, karşı yüzeyde oluşan güç maksimum ayardayken ortalama olarak 4mW/cm^2 'dir. Örneğe ulaşan ışık, 430-1900 nm aralığında değişen bir spektrumu kapsamakta, ancak performans 500 nm'nin altında ve 1000 nm'nin üzerinde düşmektedir. Renk sıcaklığı yaklaşık olarak 2800K civarındadır. IR ışık miktarının düşük olması nedeniyle örnek üstünde herhangi bir termal etkiye neden olmamaktadır.

Bu sistemde, örnekten yansıyan ışığı toplamak için iki adet 50 mm çapında lens kullanılmıştır. Bir lensin odak uzunluğu 400 mm iken diğzerinin odak uzunluğu 35 mm'dir. Her iki lens de BK7 malzemeden yapılmış olup, AR kaplamaya sahip değildir. Ayarlanabilir aralığa sahip bir montajda konumlandırılmış bu lensler, toplanan ışığı yaklaşık olarak 3 mm çapında odaklamaktadır.

HSG sistemi, elektromanyetik spektrumun görünür ve yakın kızılötesi bölgelerini kapsamaktadır; 480 nm ile 1100 nm dalga boyları arasında 2018 farklı spektral bantta noktasal olarak veri toplayabilen bir spektrometreye sahiptir. Ölçümden önce beyaz renge uygun olarak spektral bant kalibrasyonu yapmak için beyaz bir referans panel kullanılmaktadır. Tripod, kamerayı sabitlemek ve titreşimleri azaltmak için kullanılmaktadır. Ölçümler supin pozisyonda yatan yenidoğandan 50 cm uzaklıktan alınmaktadır. Kamera açısı 45° olarak belirlenmiştir. Işık kaynağı olarak 21V/150W halojen ampül kullanılmaktadır. Sonuç olarak kamera her bir nokta için 2018 dalga boyunda veri toplamaktadır.

Proje kapsamında, HSG verilerinin toplanmasına ilişkin bir protokol geliştirilmiştir (Şekil 3.6). Bu protokolde ilk olarak Broadcom firmasının geliştirmiş olduğu waves spektrometre yazılımı açılır. Bu yazılım Qmini spektrometresinin kullanılabilmesi için geliştirilmiştir. Yazılım; spektrumları elde etmek, kalibrasyon ayarlarını yapmak, yansıyan spektrumları beyaz referansa göre ölçmek vb. işlemler için kullanılmaktadır. Uygulama açıldıktan sonra HSG sistemi ile bilgisayar arasındaki bağlantının sağlanması için type-c kablosu kullanılır. Daha sonra ölçümler yapılmadan yansıyan spektrumu doğru olarak ölçmek için beyaz ışık spektromnetreye tanıtılarak kalibrasyon işlemi yapılır. Bunun için BaSO_4 bazlı beyaz bir referans panel kullanılır. Kamera kalibrasyonu yapıp hazır hale getirildikten sonra, kamerayı kaydırma yöntemi ile farklı noktalardan spektrumlar elde edilir. Bu spektrumlar toplandıktan sonra, tüm

spektrumların ortalaması alınarak işlem tamamlanır. Son olarak ise tüm spektrumlar ve ortalama spektrum hem .txt hem de .spz dosya formatlarında kaydedilir.



Şekil 3.6. HSG verilerinin toplanması için geliştirilen veri toplama protokolü.


3.1.2.2. Veri Seti Tanımı

Toplanan HSG verileri, yenidoğan sağlık durumunu değerlendirmek ve olası hastalıkları tespit etmek için etiketlenmiştir. Hastanede bulunan deneyimli uzmanlar, doğru analizlerin yapılabilmesini sağlamak için etiketleme sürecini desteklemişlerdir. Veri seti, yüksek ölüm oranları ve uzun vadeli etkileri ile yenidoğan sağlığı için kritik olan çeşitli hasta sınıflarına ayrılmış örnekleri içermektedir. Bu örnek sınıfları şunlardır:

- *Solunum Sıkıntısı Sendromu (RDS)*: Prematüre bebeklerde görülen, yetersiz akciğer havalanması ve bozulmuş oksijen değişimi ile karakterize yaygın bir solunum problemidir (Luca, 2021).
- *Nekrotizan Enterokolit (NEC)*: Bağırsak dokusunda hasarla sonuçlanan ciddi bir bağırsak enfeksiyonudur. Yenidoğanlarda ölümcül olabilmektedir (Klinke ve diğ., 2021).
- *İntrakraniyal Kanama (ICH)*: Bebeğin beynindeki kan damarlarının hasar görmesi sonucu ortaya çıkan bir durumdur. Prematüre bebeklerde sıklıkla görülmekte ve ciddi sonuçlara yol açmaktadır (Atienza-Navarro ve diğ., 2020).
- *Aort Koarktasyonu (AORT)*: Bebeğin kalbindeki ana kan damarlarının daralması ile karakterizedir. Kan akışını engellemekte ve ciddi kalp sorunlarına yol açmaktadır (Hede ve diğ., 2020).
- *Pnömotoraks (PTX)*: Bebeğin akciğerlerinde hava kaçağı ile karakterizedir. Prematüre bebeklerde solunum sıkıntısına ve diğer ciddi komplikasyonlara neden olmaktadır (Liu ve diğ., 2020).

- *Kontrol Grubu (Healthy)*: Herhangi bir yenidoğan sağlık problemi olmayan sağlıklı bebeklerden oluşur.


Veriler, yukarıda belirtilen hastalıklara karşılık gelen belirli bölgelerden elde edilmiştir. Göğüs bölgesinden alınan RDS verileri akciğer havalanmasını değerlendirirken, PTX verileri akciğerlerdeki hava kaçaklarını tespit etmeyi amaçlamaktadır. Kalbe yakın bölgelerden elde edilen AORT verileri, kalp ve ana kan damarlarındaki daralmaları değerlendirmeye yöneliktir. Alt karın bölgesinden alınan NEC verileri bağırsak dokusundaki değişiklikleri, baş bölgesinden alınan ICH verileri ise beyin dokusu kanamalarını tespit etmeye odaklanmıştır. Sağlıklı bebeklerden toplanan kontrol grubu verileri, hastalıklı bölgelerle benzer şekilde toplanarak doğru bir karşılaştırma yapılmasını sağlamıştır. Açıklayıcı bir ölçüm görüntüsü Şekil 3.7’de sunulmuştur.



Şekil 3.7. Hastalığa özgü olarak farklı bölgelerden alınan HSG verileri. (a) Gövde, (b) Baş, (c) Alt karın.

Veri seti oluşturulurken toplamda 310 farklı yenidoğandan HSG verileri alınmıştır. Her bir hasta sınıfından 40 (5 hasta sınıfı için toplamda 200), kontrol grubundan ise 110 olmak üzere toplamda 310 HSG verisi elde edilmiştir. Bu veriler, yenidoğan sağlık koşullarını temsil etmektedir ve bu tez çalışması kapsamında biyomedikal HSG verilerinin analizi için kullanılmıştır.

Çalışma kapsamında kullanılan HSG kamerası noktasal veri toplayarak $1 \times 1 \times 2018$ boyutunda bir veri elde edilmesini sağlamıştır. Uzamsal boyutu genişletmek için çeşitli noktalardan ölçümler alınmış ve bu ölçümler birleştirilmiştir. Sonuç olarak, tek bir HSG verisi için 100 farklı noktadan spektral veri alınarak $10 \times 10 \times 2018$ HSG veri küpü oluşturulmuştur. Bir yenidoğanın spektral imzalarının sağlık durumlarına (hasta veya sağlıklı) bağlı olarak farklı noktalarda benzer özellikler sergilediği göz önüne alındığında, verilerin birleştirilmesi herhangi bir sorun teşkil etmemektedir (Cihan, 2020). Bu süreç hacimsel verilerin oluşturulmasını sağlamıştır (Şekil 3.8).



Şekil 3.8. Hacimsel HSG verilerinin oluşturulması için, yenidoğanların gövde bölgesinde çizgisel tarama yaparak, yan yana ve alt alta tarayacak şekilde farklı bölgelerden spektrumların elde edilmesi ve bu spektrumların birleştirilmesi.

3.1.2.3. Ön İşleme

Elde edilen biyomedikal HSG verileri, analiz hassasiyetini artırmak, veri kalitesini iyileştirmek ve özel uygulama gereksinimlerine uyum sağlamak için bir dizi ön işleme adımından geçirilmiştir. Bu adımlar arasında gürültü giderme, hata düzeltme, normalizasyon ve özellik çıkarma gibi belirli uygulamalar için verileri daha da iyileştiren işlemler yer almaktadır. Ön işleme, temizlenmiş ve düzenlenmiş verilerle daha hızlı, daha güvenilir ve karşılaştırılabilir sonuçlar elde edilmesini sağlamaktadır (Subudhi ve diğ., 2021). Elde edilen HSG verilere uygulanan ön işleme adımları aşağıda detaylandırılmıştır.

3.1.2.3.1. Normalizasyon

Normalizasyon işlemi, herhangi bir veri setindeki değerleri belirli bir aralığa dönüştürme sürecidir. Genellikle $[0, 1]$ veya $[0, 100]$ gibi belirli aralıklara dönüştürme yapılır. Matematiksel olarak, veri setindeki her bir öge, orijinal değerlerin minimum

(min) ve maksimum (maks) değerleri arasında yeniden ölçeklendirerek normalize edilir. Veri normalizasyon işlemi matematiksel olarak şu şekilde ifade edilir:

$$X_{norm} = \frac{X - X_{min}}{X_{maks} - X_{min}} \times (Y_{maks} - Y_{min}) + Y_{min} \quad 3.1$$

Burada X orijinal veriye, X_{min} veri setindeki en küçük değere, X_{maks} veri setindeki en büyük değere, Y_{min} ve Y_{maks} yeni aralığın en küçük ve en büyük değerlerine ve X_{norm} ise normalize edilmiş veriye karşılık gelmektedir.

Bu çalışmada elde edilen biyomedikal HSG veriler ölçüm birimlerini standartlaştırmak için $[0, 100]$ aralığına getirilmiştir. Bu normalleştirme işlemi, spektral verilerde tutarlılık sağlamayı ve HSG verileri arasındaki ölçüm birimlerindeki farklılıkları azaltarak analizlerin güvenilirliğini artırmayı amaçlamıştır.

3.1.2.3.2. Spektral Bant Seçimi

Spektral bant seçimi, HSG sistemlerinin performansını belirleyen kritik bir faktördür. Doğru spektral bantların seçilmesi, istenen nesne sınıflarının belirlenmesi ve verimli spektral özelliklerin yakalanması için önemlidir.

Bu çalışmada verilerin toplanması için kullanılan HSG sistemi 480 nm ve 1100 nm aralığını kapsayan 2018 farklı spektrum yakalamaktadır. Bununla birlikte, bazı spektrumların istenmeyen gürültü veya bilgilendirici olmayan bölgeler içerebileceği göz önünde bulundurularak, veri kümesini rafine etmek ve sonraki analiz ve yorumlama süreçlerini geliştirmek için belirli bir spektral aralık özenle seçilmiştir. Sonuç olarak, veri seti 480 nm ve 1100 nm'lik daha geniş bir spektrum aralığından 1538 spektrumu kapsayacak şekilde 500 nm ve 1000 nm'lik hedeflenen bir spektral aralıkla sınırlandırılmıştır. Bu seçici spektral odaklanma, veri setindeki istenmeyen gürültüyü en aza indirmeyi, analiz doğruluğunu artırmayı ve belirli spektrumlara odaklanarak daha anlamlı sonuçlar elde etmeyi amaçlamıştır.

3.1.2.3.3. Spektrumları Yumuşatma

Spektrum yumuşatma, HSG verilerinin işlenmesinde kullanılan bir tekniktir. Bu teknik, spektral sinyallerdeki gürültüyü azaltmak, spektral çözünürlüğü iyileştirmek veya spektral özellikleri vurgulamak için kullanılmaktadır. Spektrum yumuşatma

yöntemleri genellikle bir dizi spektral filtreleme veya düzeltme işleminden oluşmaktadır.

Çalışma kapsamında elde edilen spektrum verileri çeşitli gürültü ve dalgalanmalar içermektedir. Bu durum, özellikle HSG veya spektroskopi uygulamalarında, doğru analiz ve yorumlama süreçlerini zorlaştırmaktadır. Bu sebeple spektrum verilerini yumuşatmak için Savitzky-Golay filtresi kullanılmıştır.

Savitzky-Golay filtresi, düzlemsel bir regresyon ve düzeltilmiş ağırlıklandırma kullanarak bir sinyalin düzleştirilmesi veya türetilmesi için kullanılan bir filtreleme tekniğidir (Kennedy, 2020). Bu filtre, özellikle sinyallerdeki gürültüyü azaltmak veya sinyalin genel eğilimini çıkarmak amacıyla yaygın olarak kullanılmaktadır.


Savitzky-Golay filtresinin temel prensibi, belirli bir pencere boyunca bir polinomun en küçük kareler regresyonu ile uyarlanmış bir eğrinin kullanılmasıdır. Bu polinom genellikle ikinci dereceden (karesel) bir polinomdur, ancak bu değer genelleştirilmektedir.

Bu filtre, verileri belirli bir pencere boyunca düzleştirmek veya türevini almak için kullanılabilir. Filtreleme işlemi, pencerenin boyutu ve polinom derecesi gibi parametrelerle kontrol edilebilir. Savitzky-Golay filtresinin genel ifadesi şu şekildedir:


$$y_k = \sum_{i=-\frac{M}{2}}^{\frac{M}{2}} c_i x_{k+i} \quad 3.2$$

Burada, y_k filtrelenmiş veri noktasına, $x_{(k+i)}$ orijinal veri noktalarına, c_i filtre katsayıları ve M pencere boyutuna karşılık gelmektedir. Filtre katsayıları, belirli bir polinomun en küçük kareler regresyonu ile belirlenir. Bu katsayılar, genellikle matematiksel hesaplamalar veya önceden hesaplanmış tablolar kullanılarak elde edilir.

Savitzky-Golay filtresi, yenidoğan HSG verilerdeki gürültüyü azaltmak ve düzenlemek amacıyla uygulanmıştır. Yapılan analizlerde, HSG verilerin yumuşatılması için polinom derecesi 2 olarak belirlenmiştir. Elde edilen sonuçlar, bu ön işleme tekniğinin, farklı hastalık grupları ile kontrol grubu arasındaki spektral farklılıkları daha belirgin hale getirerek anlamlı sonuçlar sağlamada etkili olmayı amaçlamıştır.



Şekil 3.9. Yenidoğanlardan elde edilen ham HSG veri örnekleri.



Şekil 3.10. Ön işleme adımlarından sonrası oluşturulan HSG verileri.

Bu ön işleme adımlarının titizlikle uygulanması, elde edilen HSG verilerinin daha güvenilir, odaklanmış ve anlamlı hale gelmesini sağlamıştır. Bu prosedürler, HSG verilerini analiz etme aşamasında geliştirilen involüsyon tabanlı derin öğrenme yöntemleri ile daha etkili ve doğru sonuçlar elde etmek için temel bir hazırlık aşaması oluşturmuştur. Farklı sınıflar için ham veriler ve ön işlemde geçirilmiş veriler sırasıyla Şekil 3.9 ve Şekil 3.10'da gösterilmektedir. Ön işleme adımlarının ardından, her bir yenidoğan için HSG verilerinin boyutu $10 \times 10 \times 1538$ olarak elde edilmiştir.

3.2. Yöntemler

HSG verilerinin analizi, çeşitli uygulama alanlarında önemli bir araştırma konusu haline gelmiştir. Bu tez çalışması kapsamında, HSG verilerin etkin bir şekilde işlenmesi ve yüksek boyutluluğun getirdiği zorlukların üstesinden gelinmesi için İSA'nın kullanımını araştırmaktadır. Bu bağlamda, konvolüsyon ve involüsyon tasarımları, boyut indirgeme yöntemleri ve derin öğrenme modellerinde kullanılan özel yapılar incelenerek, HSG verilerin analizinde yeni yaklaşımlar geliştirilmesi hedeflenmiştir.

3.2.1. Konvolüsyon Taslağı

İnvolüsyon kavramının tutarlılığını sağlamak ve ilerlemeye uygun bir temel oluşturmak için, involüsyonun başlangıç noktası olarak standart konvolüsyon işlemini tanıtmak gerekmektedir. HSG veri analizinde ESA tabanlı derin öğrenme yöntemlerinin kullanılması, karmaşık ve çok boyutlu veri kümelerinin işlenmesi için oldukça önemlidir. ESA'lar, çok sayıda spektral kanal arasındaki karmaşık ilişkileri öğrenerek derin özellik çıkarımı gerçekleştirir ve böylece HSG verileri içindeki spektral varyasyonların daha iyi ayırt edilmesini sağlar. Bu yöntemler, manuel özellik mühendisliği ihtiyacını ortadan kaldırarak, büyük ve karmaşık veri kümelerini daha verimli bir şekilde işleyebilmektedir. Ayrıca, geniş veri yelpazesini kapsayan eğitim modelleri için yüksek uygunluk gösterir, bu da HSG verilerinin analizinde daha doğru ve güvenilir sonuçların elde edilmesini sağlar. Ancak, bu avantajlara rağmen konvolüsyon işleminin belirli dezavantajları da vardır. Bu dezavantajları gidermek veya en aza indirmek için yenilikçi yaklaşımlar ve metodolojiler geliştirilmektedir.

HSG verilerini analiz ederken hem uzamsal hem de spektral boyutlardaki özellikleri yakalamak oldukça önemlidir. 2B konvolüsyon çekirdekleri, HSG verilerinden uzamsal özellikleri yakalayabilirken, 3B konvolüsyon çekirdekleri hem

spektral hem de uzamsal özellikleri yakalayabilir. Bu bağlamda, 2B konvolüsyon ve 3B konvolüsyon taslağı aşağıda ayrı ayrı detaylandırılmıştır.

3.2.1.1. 2B Konvolüsyon

2B-ESA'da, giriş verileri 2B çekirdeklerle konvolüsyon işlemine tabii tutulur. Konvolüsyon işlemi, giriş verileriyle çekirdek arasındaki nokta çarpımının toplanmasıyla hesaplanır. 2B Çekirdek, giriş verileri üzerinde tüm uzamsal boyutu kapsayacak şekilde kaydırılır.

$X \in \mathbb{R}^{H \times W \times C}$, giriş özellik haritasını ifade etmektedir. Burada H , W ve C sırasıyla giriş kanallarının yüksekliğine, genişliğine ve sayısına karşılık gelir. $K \times K$ sabit çekirdek boyutuna sahip bir dizi konvolüsyon filtresi $\mathcal{C}_0$, $\mathcal{F} \in \mathbb{R}^{C_0 \times C \times K \times K}$ olarak gösterilir. Burada her bir filtre $\mathcal{F}_k \in \mathbb{R}^{C \times K \times K}$, $k = 1, 2, \dots, C_0$, bir dizi konvolüsyon çekirdeğini $\mathcal{F}_{k,c} \in \mathbb{R}^{K \times K}$, $k = 1, 2, \dots, C$ temsil eder. Filtre, $Y \in \mathbb{R}^{H \times W \times C_0}$ çıkış özellik haritasını oluşturmak için eleman bazında çarpma ve toplama işlemleri gerçekleştirmek üzere giriş özellik haritası üzerinde aşağıdaki gibi bir kayan pencere kullanır.

$$Y_{k,i,j} = \sum_{\substack{c \in \{1,2,\dots,C\} \\ (u,v) \in \Delta_k}} \mathcal{F}_{c,u+\lfloor \frac{K}{2} \rfloor, v+\lfloor \frac{K}{2} \rfloor}^k X_{c,i+u,j+v} \quad 3.3$$

Merkezi piksel üzerinde gerçekleştirilen konvolüsyon düşünüldüğünde, $\Delta_k \in \mathbb{Z}^2$ komşuluktaki ofset kümesine karşılık gelmektedir. Ofset kümesi, bir pikselin çevresindeki komşu piksellere olan konum farklarını ifade eder ve aşağıdaki gibi tanımlanabilir:

$$\Delta_k = \left[-\left\lfloor \frac{K}{2} \right\rfloor, \dots, \left\lfloor \frac{K}{2} \right\rfloor \right] \times \left[-\left\lfloor \frac{K}{2} \right\rfloor, \dots, \left\lfloor \frac{K}{2} \right\rfloor \right] \quad 3.4$$

3.2.1.2. 3B Konvolüsyon

3B konvolüsyon, 3B verilerin bir 3B çekirdek ile konvolüsyon işlemine tabii tutulması ile gerçekleştirilir. Konvolüsyon katmanının özellik haritaları, giriş katmanındaki birden fazla bitişik bant üzerinde bir 3B çekirdek kullanılarak oluşturulur ve böylece spektral bilgiler yakalanır. $X \in \mathbb{R}^{C \times H \times W \times B}$, 3B konvolüsyon için giriş verisini ifade etmektedir. Burada C kanal sayısını, H ve W sırasıyla girdinin yüksekliğini ve genişliğini, B ise spektral bantların boyutunu gösterir. $X_{c,i,j,b} \in X$, girdinin bir pikselini


gösterir. $Y \in \mathbb{R}^{C_0 \times H \times W \times B}$, kayan pencere yönteminin çarpma-ekleme işleminden sonra elde edilen çıktıya karşılık gelmektedir. Burada H , W ve B dolgu yoluyla değişmeden kalmakta ve C , 3B konvolüsyon çekirdeklerinin sayısını temsil etmektedir. Bir 3B konvolüsyon çekirdeğinin boyutunun $K \times K \times D$ olduğu varsayıldığında, burada K ve D sırasıyla kanalların boyutunu ve sayısını temsil etmektedir.

$\mathcal{F}^k \in \mathbb{R}^{C \times K \times K \times D}$, $k \in \{1, 2, \dots, C_0\}$, k 'nci 3B konvolüsyon çekirdeğini gösterebilir. $\mathcal{F}_{c,i,j,d}^k \in \mathbb{R}$, k 'nci konvolüsyon çekirdeğinin c 'inci kanalındaki bir ağırlık parametresini temsil eder. Ardından, bir $Y_{k,i,j,b} \in Y$ pikseli aşağıdaki gibi tanımlanabilir:

$$Y_{k,i,j,b} = \sum_{\substack{c \in \{1, 2, \dots, C\} \\ \omega \in \Delta_d \\ (u,v) \in \Delta_k}} \mathcal{F}_{c,u+\lfloor \frac{K}{2} \rfloor, v+\lfloor \frac{K}{2} \rfloor, \omega+\lfloor \frac{D}{2} \rfloor}^k X_{c,i+u, j+v, b+\omega} \quad 3.5$$

Burada, $\Delta_k = [-K/2, \dots, K/2] \times [-K/2, \dots, K/2]$, $\times$ ile kartezyen çarpımı temsil edilmekte ve $\Delta_d = \{-D/2, \dots, D/2\}$ her ikisini de belirtmektedir. Her ikisi de merkezi piksel üzerinde gerçekleştirilen konvolüsyon işlemi ile ilgili komşu piksellere olan konum farklılıklarını ifade eden ofset kümesine karşılık gelmektedir.

Standart konvolüsyon çekirdeklerinin iki temel özelliği vardır: uzamsal-bağımsız ve kanala-özgü. Uzamsal bağımsız olma özelliği, bir konvolüsyon çekirdeğinin parametrelerini uzamsal bir alan boyunca paylaştığını ve tek bir özellik haritası üzerinde kayan pencere yaklaşımıyla tekrar tekrar kullanıldığını göstermektedir. Kanala özgü olması, her kanal için ayrı bir ağırlık kümesine sahip olması anlamına gelmektedir. Konvolüsyon çekirdeğinin şeması Şekil 3.11'de verilmiştir. Bununla birlikte, standart konvolüsyon işlemi, tek bir adımda uzun menzilli uzamsal etkileşimleri yakalamada yetersiz kalmaktadır.



Şekil 3.11. Konvolüsyon çekirdeğinin şeması. Üç farklı konvolüsyon çekirdeği kullanılmıştır.

3.2.2. İnvölüsyon Tasarımı

İnvölüsyon tasarımı, özellik haritalarının kanal boyutunda fazlalık sergileme eğiliminde olduğunu ve bu fazlalığın modelin performansını olumsuz etkileyebileceğini öne süren çalışmaların (Han ve diğ., 2020; Qiu ve diğ., 2021) bulgularına dayanmaktadır. Standart konvolüsyon çekirdekleri bu sorunu ele almakta başarısız olmakta ve konvolüsyon işlemi sırasında kanallar arasında fazlalığa yol açabilmektedir. Bu sorunların üstesinden gelmek için invölüsyon kavramı önerilmiştir. İnvölüsyon, konvolüsyonun tersi olarak uzamsal-spesifik ve kanaldan-bağımsızdır.

İnvölüsyon terimi, bu ilişkiyi açıklamak için kullanılmış ve "*ters konvolüsyon*" terimi "*invölüsyon*" olarak kısaltılmıştır (**Inverse Convolution = Involution**). Konvolüsyon işlemi, bir giriş sinyali veya görüntüsü üzerinde bir çekirdek kullanarak belirli bir matematiksel işlemi gerçekleştirmektedir. Öte yandan invölüsyon, bu işlemi tersine çevirir ve başlangıç verilerini elde etmek için çekirdek ve çıkış verisini kullanmaktadır.

Konvolüsyon filtrelerinin kanallar arasında fazlalıkları mevcuttur ve bu da konvolüsyon işlemlerinin esnekliğini etkiler (Li ve diğ., 2021). Buna karşılık, invölüsyon çekirdeği $\mathcal{H} \in \mathbb{R}^{H \times W \times K \times K \times G}$, standart konvolüsyonla karşılaştırıldığında hem uzamsal hem de kanal boyutlarında ters dönüşümler gerçekleştirmek için özel olarak tasarlanmıştır. Her bir invölüsyon çekirdeği $\mathcal{H}_{i,j,\dots,g} \in \mathbb{R}^{K \times K}, g = 1, 2, \dots, G, (i, j)$ koordinatındaki $\mathbf{X}_{i,j} \in \mathbb{R}^C$ pikseli için uyarlanır ve kanallar arasında paylaşılır. Burada G , grup sayısını gösterir ve her grup aynı invölüsyon çekirdeğini paylaşır. İnvölüsyon, giriş üzerinde eleman bazında çarpma ve toplama işlemleriyle elde edilen bir çıkış özellik haritası verir ve invölüsyon çekirdekleri aşağıdaki gibi kullanılır:

$$Y_{i,j,k} = \sum_{(u,v) \in \Delta_k} \mathcal{H}_{i,j,u+\lfloor \frac{K}{2} \rfloor, v+\lfloor \frac{K}{2} \rfloor, \lfloor \frac{kG}{C} \rfloor} X_{i+u,j+v,k} \quad 3.6$$


Konvolüsyon çekirdeklerinden farklı olarak $\mathcal{H}$ invölüsyon çekirdeklerinin şekli giriş özellik haritası $\mathbf{X}$ 'e bağlıdır. Çıkış çekirdekleri giriş tensörüne dayalı invölüsyon çekirdeklerinden üretilir ve girişle hizalanır. Böylece, çekirdek oluşturma fonksiyonu (Kernel Generation Function, KGF) ϕ ve her pozisyon (i, j) için eşleştirme fonksiyonu aşağıdaki gibi ifade edilebilir:

$$\mathcal{H}_{i,j} = \phi(X_{\Psi_{i,j}}) \quad 3.7$$

Burada $\Psi_{i,j}$, $\mathcal{H}_{i,j}$ 'nin koşullandırıldığı piksel kümesini indeksler. $\Psi_{i,j} = \{(i,j)\}$ olarak gösterilen $\phi: \mathbb{R}^C \rightarrow \mathbb{R}^{K \times K \times G}$ çekirdek oluşturma fonksiyonu aşağıdaki gibi verilir:

$$\mathcal{H}_{i,j} = \phi(X_{\Psi_{i,j}}) = W_1 \sigma(W_0 X_{i,j}) \quad 3.8$$

$W_0 \in \mathbb{R}^{\frac{C}{r} \times C}$ ve $W_1 \in \mathbb{R}^{(K \times K \times G) \times \frac{C}{r}}$ birlikte bir darboğaz yapısı oluşturan iki doğrusal dönüşümü temsil eder. Kanal azaltma, r düşürme oranıyla gerçekleştirilerek verimli işleme sağlanır. σ , yığın normalleştirme (Batch Normalization, BN) ve doğrusal olmayan aktivasyon fonksiyonlarını temsil eder. Eşitlik 3.6, somutlaştırılmış KGF ile birlikte Eşitlik 3.8'in involüsyonunu ifade eder. Algoritma 1'de sunulan sözde (psödo) kod, Şekil 3.12'de görselleştirilen involüsyonun hesaplama akışını tanımlamaktadır.



Şekil 3.12. İnvölüsyonel çekirdeğin şeması (İçerisinde spektral özellik tabanlı KGF'nin kombinasyonunu göstermektedir. Şemada, involüsyonel çekirdeğin kanalı $G=1$ olarak ayarlanmıştır ve $\otimes$ C kanalları arasında çarpma işlemini temsil ederken, $\oplus$ uzayda toplama işlemini ifade eder. $X_{i,j}, (i,j)$ konumundaki (merkez piksel) spektral özelliği temsil eder. ϕ KGF'yi temsil ederken, yeniden düzenlemeden sonra elde edilen $\mathcal{H}_{i,j}$ karşılık gelen involüsyonel çekirdeği temsil eder).

Şekil 3.12 şu şekilde açıklanabilir: İlk katman, $1 \times 1 \times C$ boyutlarında C/r konvolüsyonel çekirdekleri kapsar; burada r , özellik çıkarma ve boyut azaltma hedefleri için kullanılan düşürme oranını gösterir. Daha sonra, ikinci katman $1 \times 1 \times C/r$ boyutunda GK^2 konvolüsyonel çekirdekleri içerir. BN ve ReLU aktivasyon fonksiyonları, özellik karakterizasyonunun sağlamlığını artırmak ve modelin öğrenme kapasitesini iyileştirmek amacıyla iki konvolüsyonel katmanı (Konv) arasına yerleştirilmiştir. Son olarak, $K \times K \times G$ boyutunda bir involüsyonel çekirdek elde etmek için kanaldan-uzaya yeniden düzenleme gerçekleştirilir.

Algoritma 1: Tensoflow arka ucunu kullanan Keras'ta involüsyonun psödo kodu.

```
# H: yükseklik, W: genişlik, B: parça büyüklüğü, p: dolgu
# C: kanal sayısı, G: grup sayısı
# K: kernel boyutu, s: adım, r: düşürme oranı

# %% başlatma
stride_layer = tf.keras.layers.AveragePooling2D(s, s, p) if stride > 1 tf.identity()
kernel_gen = tf.keras.Sequential(tf.keras.layers.Conv2D(C, C//r, K = 1),
    tf.keras.layers.BatchNormization(),
    tf.keras.layers.ReLU(),
    tf.keras.layers.Conv2D(K*K*G, K = 1))
kernel_reshape = tf.keras.layers.Reshape(H, W, K*K, 1, G)
input_patches_reshape = tf.keras.layers.Reshape(H, W, K*K, C//G, G)
output_reshape = tf.keras.layers.Reshape(H, W, C)

# %% ileri geçiş
# kernel oluşturma, Eşitlik 3.8
kernel = kernel_reshape(kernel_gen(stride_layer(x))) # B,H,W,K*K,1,G
# Giriş paketlerini belirleme
input_patches = tf.image.extract_patches(x, [1, K, K, 1], [1, s, s, 1], [1, 1, 1, 1],
p) # B,H,W,K*K,C
input_patches = input_patches_reshape(input_patches) # B,H,W,K*K,C//G,G
# Çarpma-Toplama işlemi, Eşitlik 3.6
output = tf.reduce_sum(tf.multiply(kernel, input_patches), axis=3) # B,H,W,C//G,G
output = output_reshape(output) # B,H,W,C
return output, kernel
```

Eşitlik 3.6'daki özellik oluşturma süreci geliştirilmiş bir öz-dikkati andırmaktadır (Vaswani ve diğ., 2017). Öz dikkat havuzları, Q sorgularından ve K anahtarlarından elde edilen benzerlikleri kullanarak V değerlerini hesaplar.

$$Y_{i,j,k} = \sum_{(p,q) \in \Omega} (QK^T)_{i,j,p,q, \lfloor \frac{kH}{C} \rfloor} V_{p,q,k} \quad 3.9$$

Q , K ve V , X girdisinden dönüştürülmüş bileşenlerdir ve H çok-başlı öz-dikkat baş sayısını ifade eder (Vaswani ve diğ., 2017). Benzerlik, her iki operatör için Δ komşuluğunda veya Ω aralığında ağırlıklı piksel toplamını içerir. İnvolüsyon hesaplaması, uzamsal dikkat toplamına benzemektedir. Bunun tersine, öz-dikkat mekanizmasının dikkat haritası (benzerlik/yakınlık matrisi) QK^T çarpımı yoluyla bir involüsyon çekirdeği $\mathcal{H}$ olarak görülebilir.

İnvolüsyon çekirdekleri, paylaşılan konvolüsyon çekirdeklerinin aksine genellikle girdiler arasında farklılık gösterir. İnvolüsyon çekirdeği parametreleri uzamsal olarak paylaşılmaz veya geriye yayılım yoluyla güncellenmez (Lv ve diğ., 2022). Çekirdek üretiminde paylaşılmayan veya güncellenmeyen parametreler involüsyonu farklı kılar. Bu nedenle, involüsyon çekirdekleri uzamsal olarak spesifiktir ve kanaldan bağımsızdır. Uzamsal-spesifik olması, involüsyon çekirdeklerinin ayırt edici özellikler çıkarmak için ağırlık parametrelerini farklı uzamsal konumlara göre ayarladığı; kanaldan-bağımsız olması ise involüsyon

çekirdeklerinin kanallar arasında paylaşılan aynı parametrelerle işlem yaptığı anlamına gelmektedir.

3.2.3. Boyut İndirme Yöntemleri

HSG verileri genellikle piksel başına yüzlerce hatta binlerce spektral bant ile yüksek boyutluluk sergiler, bu da işlemeyi, analizi ve görselleştirmeyi zorlaştırırken hesaplama taleplerini de artırır (Liu ve diğ., 2023). Boyut indirgeme teknikleri, gürültüyü ve gereksiz bilgileri elemek suretiyle önemli veri özelliklerini vurgulayarak ve hesaplama maliyetlerini azaltarak bu zorlukların üstesinden gelmede son derece önemlidir. Bu optimizasyon, daha verimli veri işleme, gelişmiş görselleştirme ve analitik içgörü sağlayarak HSG veri kümelerini daha yönetilebilir ve bilgilendirici hale getirir. Bu noktada, çeşitli boyut indirgeme teknikleri kullanılarak İSA ile HSG için en uygun boyut azaltma yöntemlerinin tespit edilmesi hedeflenmiştir.

3.2.3.1. Spektral Gömme (SG)

SG Modeli, veriyi düşük boyutlu uzamsal temsile dönüştürmek için spektral bölünme yöntemlerini kullanmaktadır. SG için aşağıdaki adımlar takip edilir:

- İlk olarak, bir benzerlik matrisi W oluşturulur. Bu matris, verinin benzerliklerini yansıtır ve genellikle komşuluk bilgilerini içerir. Örneğin, W matrisi, iki nokta x_i ve x_j arasındaki benzerliği ölçen değerleri içerebilir.
- Ardından, derece matrisi D oluşturulur. Bu matris, her bir veri noktasının diğer tüm noktalarla olan toplam benzerliklerini yansıtır. Yani, her bir nokta i için D matrisi, o noktanın tüm diğer noktalarla olan benzerliklerinin toplamını içerir:

$$D_{ii} = \sum_j W_{ij} \quad 3.10$$

- Laplacian matrisi L oluşturulur. Bu matris, $L = D - W$ olarak hesaplanmaktadır.
- L matrisinin en küçük özdeğerlerine ve bu özdeğerlere karşılık gelen özvektörlere bakılır. Genellikle en küçük k özdeğer ve bu özdeğerlere karşılık gelen özvektörler seçilir.
- Seçilen özdeğerlere karşılık gelen özvektörler kullanılarak verinin düşük boyutlu temsili (Y) hesaplanır:

$$Y = \begin{bmatrix} y_1^1 & y_2^1 & \dots & y_k^1 \\ y_1^2 & y_2^2 & \dots & y_k^2 \\ \vdots & \vdots & \ddots & \vdots \\ y_1^m & y_2^m & \dots & y_k^m \end{bmatrix} \quad 3.11$$

Bu işlem sonucunda, Y matrisi HSG verinin spektral boyutunu koruyarak düşük boyutlu bir uzamsal temsili sağlar. Yani, veri uzamsal boyutta aynı kalırken, spektral boyutta azaltılarak temsil edilir. SG, HSG verilerini düşük boyutlu uzamsal temsillerle ifade etmek için kullanılabilir ve bu sayede verinin yapısını daha iyi anlamak ve analiz etmek için faydalı hale getirir.

3.2.3.2. Yerel Doğrusal Gömme (YDG)

YDG, veriyi yakındaki noktaların lokal doğrusal ilişkilerini koruyacak şekilde düşük boyutlu bir uzaya çekmek için kullanılır. Bu işlemi gerçekleştirmek için aşağıdaki adımları takip eder:

- Komşu Noktaların Bulunması:** Giriş HSG verisi (X) kullanılarak, her pikselin yakınındaki komşu pikselleri belirlemek için bir komşuluk grafiği oluşturulur.
- Ağırlık Matrisinin Oluşturulması:** Her pikselin komşu piksellerine olan uzaklıklara göre bir ağırlık matrisi hesaplanır. Bu ağırlıklar, her pikselin komşularıyla olan yerel doğrusal ilişkisini yansıtır.
- Düşük Boyutlu Temsilin Hesaplanması:** Ağırlık matrisi ve veri matrisi kullanılarak düşük boyutlu temsil hesaplanır. Genellikle en küçük özdeğerlere karşılık gelen özvektörler kullanılır.
- Sonuçların Yeniden İnşa Edilmesi:** Düşük boyutlu temsil kullanılarak, her pikselin yeniden inşa edilmiş uzamsal temsili hesaplanır.

Azaltılmış Boyutta Yeniden İnşa: YDG sonucunda düşük boyutlu temsiller kullanılarak, her pikselin yeniden oluşturulmuş uzamsal yapısı hesaplanır.

$$X' = [x'_1, x'_2, \dots, x'_m] \quad 3.12$$

Burada, X' azaltılmış boyutta veriyi temsil etmektedir.

YDG, HSG verilerinin spektral boyutunu korurken uzamsal boyutunu azaltmaya yardımcı olur. Bu şekilde elde edilen azaltılmış boyuttaki temsil, verinin daha anlamlı hale gelmesini sağlar ve indirgenmiş boyutta analiz edilmesine imkan tanır.

3.2.3.3. Bağımsız Bileşenler Analizi (BBA)

BBA, veriyi bağımsız bileşenlere ayırmayı amaçlayan bir modeldir. BBA ile, spektral boyutu korumak ve bağımsız bileşenleri çıkarmak için aşağıdaki matematiksel model kullanılır:

$$X = AS \quad 3.13$$

Burada X HSG veri matrisini, A karışım matrisini ve S bağımsız bileşen matrisini temsil etmektedir.

Amaç (Hata) Fonksiyonu: BBA, bir amaç fonksiyonunu optimize etmek amacıyla çalışır. Amaç fonksiyonu, verinin bağımsız bileşenlere nasıl ayrıldığını ölçer. Tipik olarak, amaç fonksiyonu, bağımsız bileşenlerin Negatif Log Olasılık Yoğunluğunu (NLOY) maksimize etmeye çalışır.

Optimizasyon: BBA'nın temel hedefi, amaç fonksiyonunu optimize ederek karışım matrisini (A) ve bağımsız bileşen matrisini (S) hesaplamaktır. Bu optimizasyon işlemi genellikle gradyan iniş gibi iteratif bir yöntem kullanılarak gerçekleştirilir. Optimizasyon işlemi sonucunda, bağımsız bileşenler (S) hesaplanır ve verinin spektral boyutu korunurken verinin yapılarına dayalı bağımsız bileşenler elde edilir.

Bu şekilde BBA, HSG verilerin spektral boyutunu korurken veriyi bağımsız bileşenlere ayırmak ve verinin yapısını incelemek için kullanılabilir.

3.2.3.4. Tekil Değer Ayrışması (TDA)

TDA, bir matrisi üç ayrı matrise ayıran matematiksel bir işlemdir; bir ortogonal matris, bir diyagonal matris ve bir diğer ortogonal matris. Veri matrisi TDA ile aşağıdaki şekilde ayrıştırılabilir:

$$X = U\Sigma V^T \quad 3.14$$

X : HSG veri matrisini ifade eder.

U : $m \times m$ boyutunda bir matristir ve bu matrisin sütunları, veri matrisinin satırlarına göre temsil edilen temel bileşenleri içerir.

Σ : $m \times n$ boyutunda bir matristir ve bu matrisin çapraz üst üçgeni, tekil değerleri içerir.

V^T : $n \times n$ boyutunda bir matristir ve bu matrisin sütunları, veri matrisinin sütunlarına göre temsil edilen temel bileşenleri içerir.

Spektral Boyutun Korunması: TDA'nın önemli bir özelliği, tekil değerlerin büyükten küçüğe sıralanmış olmasıdır. Dolayısıyla, daha az sayıda tekil değeri (yani, azaltılmış boyutta) kullanarak veri temsil edilebilir. Bu şekilde, spektral boyut korunurken, veri daha düşük boyutlu bir temsille incelenebilir.

Azaltılmış Boyutta Yeniden İnşa: İlgilenilen azaltılmış boyut sayısına göre tekil değerler ve ilgili sütunlar (U ve V) seçilir. Bu azaltılmış temel bileşenler kullanılarak orijinal veri yeniden inşa edilebilir:

$$X' = U_k \Sigma_k V_k^T \quad 3.15$$

Burada, k azaltılmış boyut sayısını temsil etmektedir.

TDA, spektral boyutun korunduğu ve uzamsal boyutta herhangi bir değişiklik yapılmadığı için HSG verilerinin analizi için kullanışlı bir yöntemdir. Azaltılmış boyutta veri temsili, gürültünün azaltılması ve veri analizi açısından avantajlar sunmaktadır.

3.2.3.5. Temel Bileşenler Analizi (TBA)

TBA, çok boyutlu verilerin boyutunu azaltmak ve temel varyasyonları ortaya çıkarmak için kullanılan istatistiksel bir yöntemdir. TBA, aşağıdaki adımlarla açıklanabilir:

Veri Hazırlığı: HSG veriler bir veri matrisi olarak temsil edildiği düşünülürse bu matris, her piksel için spektral bantların yan yana dizilmesiyle oluşturulur. Örneğin, m piksel ve n spektral bant varsa, veri matrisi X şu şekildedir:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \quad 3.16$$

Ortalama Merkezileştirme: Her spektral bandın ortalamasını çıkararak verilerin merkezileştirilmesi gerekmektedir. Bu işlem, her bir özellik veya spektral bant için yapılır. Örneğin, j 'inci bir spektral bandın ortalaması şu şekildedir:

$$\bar{x}_j = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad 3.17$$

Ortalama merkezileştirme sonucunda, her spektral bandın ortalaması sıfır olur. Burada, m toplam veri noktası sayısını temsil eder. x_{ij} , i 'inci veri noktasının j 'inci spektral noktasındaki değeridir.

Kovaryans Matrisinin Hesaplanması: Kovaryans matrisi, HSG verilerin varyansını ve korelasyonunu hesaplamak için kullanılır. Kovaryans matrisi Σ şu şekildedir:

$$\Sigma = \frac{1}{m} X^T X \quad 3.18$$

Burada, Σ kovaryans matrisini, X veri matrisini ve T transpozunu temsil etmektedir.

Özdeğer ve Özvektörlerin Hesaplanması: Kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanır. Özdeğerler büyükten küçüğe sıralanır ve ilgilenilen ilk özdeğer ve karşılık gelen özvektörler seçilir. Bu özdeğerler ve özvektörler, temel bileşenlerin hesaplanmasına yardımcı olur.

Temel Bileşenlerin Hesaplanması: Seçilen özvektörler kullanılarak temel bileşenler hesaplanır. Temel bileşenler, yeni bir boyutlu uzayda verilerin temsili olarak kullanılabilir.

$$Z = XU \quad 3.19$$

Burada, U özvektör matrisini ve Z temel bileşenler matrisini temsil etmektedir.

TBA, HSG verilerin boyutunu azaltmak ve verideki temel bileşen yapılarına odaklanmak için kullanılır. Temel bileşenler, veriyi daha az boyutta temsil ederken önemli bilgileri korumaktadır. Bu, veri analizi ve sınıflandırma gibi uygulamalarda kullanışlı olmaktadır.

3.2.3.6. Negatif Olmayan Matris Ayrışımı (NOMA)

NOMA, spektral boyutun korunduğu ve yalnızca verinin spektral bileşenlerinin yaklaşık bir temsili olan iki matrisin çarpanlarının hesaplandığı bir dizi adımdan oluşur.

NOMA, veri matrisini iki pozitif matris olan W ve H ile çarpanlarını ayıştırmaya dayalı bir modeldir. Bu çarpanlar, spektral bileşenlerin temsili olarak kullanılır.

$$X \approx WH \quad 3.20$$

Burada, W spektral bileşenleri içeren matrisi ve H karışım katsayılarını içeren matrisi temsil eder. Her iki matris de yalnızca pozitif değerler içermelidir.

Amaç (Hata) Fonksiyonu: NOMA, bir amaç fonksiyonunu minimize etmek amacıyla çalışır. Tipik olarak, bu amaç fonksiyonu, verinin orijinal matrise ne kadar iyi yakınsadığını ölçer ve aşağıdaki gibi tanımlanır:

$$\|X - WH\|^2 \quad 3.21$$

Burada, $\|X - WH\|^2$ normu hesaplar. Amaç, bu hatayı minimize ederek W ve H matrislerini bulmaktır.

Optimizasyon: NOMA'nın birçok varyasyonu vardır ve genellikle bu amaç fonksiyonunu optimize etmek için farklı yöntemler kullanılır. Tipik olarak, bu, bir iteratif yaklaşım gerektirir ve başlangıç matrisleri W ve H genellikle rastgele seçilir ve ardışık iterasyonlarla güncellenir. Optimizasyon işlemi sonucunda, W ve H matrisleri hesaplanır. W matrisi spektral bileşenleri içerirken, H matrisi her piksel için karışım katsayılarını içerir. Spektral boyut değişmez, sadece bu boyuttaki verinin temsilinin daha düşük boyutlu matrisler W ve H ile yapıldığı bir şekilde yaklaşık hale gelir. NOMA, spektral boyutun korunması gerektiği durumlarda HSG verilerin boyut indirgeme ve temsilini geliştirmek için yaygın olarak kullanılan bir tekniktir.


Yukarıda bahsedilen boyut indirgeme yöntemleri, HSG verilerinin benzerliklerini korumak ve düşük boyutlu bir temsil elde etmek için kullanılmaktadır. Bu yöntemlerden bazıları TBA, TDA ve NOMA gibi doğrusal, diğerleri ise BBA, YDG ve SG gibi doğrusal olmayan yöntemlerdir. Bu yöntemlerin uygulanması, HSG verilerinin boyutlarının azaltılmasıyla sonuçlanır ve orijinal yüksek boyutlu verileri etkili bir şekilde daha yönetilebilir ve bilgilendirici bir biçime dönüştürür. Daha sonra, en iyi yöntemi belirlemek için indirgenmiş veriler kullanılarak İSA ile sınıflandırma gerçekleştirilir.

3.2.4. Derin Öğrenme Modelleri İçerisinde Kullanılan Özel Yapılar

Derin öğrenme modellerinin performansını artırmanın temel yöntemlerinden biri, modeli daha derin ve daha kompleks hale getirmek için daha fazla katman eklemektir. Ancak bu, hesaplama karmaşıklığını artırabilir ve aşırı uyuma yol açabilir (Bejani ve Ghatee, 2021). Bu nedenle, yerel seyrekliği kullanabilen ve İSA'lar ile entegre edilebilen teknikler tercih edilebilir. HSG veriler analiz edilirken geliştirilen İSA modelleri içerisinde kullanılan özel yapılar aşağıda detaylandırılmıştır.

3.2.4.1. Artık Blok

Artık blok, gradyan kaynaklı kayıpları azaltmayı ele almak için kullanılan bir derin öğrenme yapısıdır. Girdi verileri involüsyon veya tam bağlı katmanlar aracılığıyla işlenir ve işlenen çıktı orijinal girdiyle birleştirilir. Bu ekstra bağlantılar ağ öğrenmesine ve gradyan akışına yardımcı olur. Artık bloklar, derin sinir ağı mimarilerinde performansı artırır ve öğrenmeyi hızlandırır (Amelio ve diğ., 2023). Bu yapılar ESA, ResNet ve benzer mimariler gibi modellerde yaygındır. Tez kapsamında geliştirilen bazı modellerde, artık bloklar bilgiyi korumak ve gradyan sönümlenmesi (vanishing gradient) veya patlaması (exploding gradient) gibi zorlukların üstesinden gelmek için İSA modellerine entegre edilmiştir. Darboğaz yapısının bir örneği Şekil 3.13'te gösterilmiştir.



Şekil 3.13. Artık blok için örnek bir darboğaz yapısı.

3.2.4.2. Başlangıç Modülü

HSG veriler genellikle yüksek boyutlu ve karmaşıktır, bu da geleneksel yöntemlerle işlenmesini zorlaştırır. Bununla birlikte, derin öğrenme yaklaşımları bu tür verilerin analizi için önemli bir potansiyele sahiptir. Görüntü işleme uygulamalarında


başarılı olan başlangıç modülleri, farklı boyutlarda ve mimari varyasyonlarda filtrelerle dayanmaktadır (Delibasoglu ve Cetin, 2020). Bu modüller, ağın farklı ölçeklerdeki özellikleri öğrenmesini ve daha geniş bir bilgi yelpazesine erişmesini sağlamaktadır. Sonuç olarak, HSG verilerinin derin öğrenme teknikleriyle etkili bir şekilde analiz edilmesi mümkün hale gelmektedir.

Başlangıç modülleri HSG verilerinin analizi için çeşitli açılardan değerlendirilebilir. Çok ölçekli özellik çıkarma yetenekleri, farklı dalga boylarında yüksek boyutlu spektral bilgilerin etkili bir şekilde işlenmesini sağlamaktadır. Ayrıca, farklı boyutlardaki filtreleri paralel olarak kullanarak ve bilgileri birleştirerek, HSG verilerdeki karmaşık ilişkilerin modellenmesini geliştirirler. Daha az parametre kullanarak çok çeşitli özellikleri temsil etme kapasiteleri, ağın daha hızlı eğitilmesini sağlar ve aşırı uyum riskini azaltır. Son olarak, daha az parametre ile daha geniş (düşük ve yüksek seviyeli özellikler) bir alanı kapsama yetenekleri, modelin performansını artırırken hesaplama karmaşıklığını azaltır.

Başlangıç modülü tipik olarak, genellikle “Başlangıç Bloğu” adı altında birleştirilen bir dizi alt modülden oluşur. İSA özelinde geliştirilen Temel (Naive) Başlangıç bloğu, özellik haritasının boyutunu değiştirmeden kanal sayısını artıran 1×1 involüsyon katmanı ile başlar. Daha sonra, 3×3 involüsyon katmanı orta ölçekli özelliklerin tespit edilmesine yardımcı olurken, 5×5 involüsyon katmanı daha geniş özellik alanlarını kapsar. 2×2 ortalama havuzlama katmanı, özellik haritasının boyutunu azaltır ve önemli özelliklerin belirlenmesine yardımcı olur. Son olarak, birleştirme katmanı farklı ölçeklerdeki çıktıları birleştirerek ağın geniş bir özellik kümesini öğrenmesini sağlar. Bu yapı, çeşitli ölçeklerdeki bilgileri bir araya getirerek daha etkili özellik öğrenimini kolaylaştırır.

Temel Başlangıç Modülü, farklı ölçeklerdeki uzamsal özellikleri öğrenmek için değişken filtre boyutlarına sahip involüsyon katmanlarını kullanır. Ancak bu, hesaplama maliyetinin artmasına neden olur ve başlangıç modülünü dezavantajlı duruma sokar. Bu sorunu çözmek için, 3×3 ve 5×5 involüsyon katmanlarından önce 1×1 involüsyon katmanları ve bunlardan sonra ortalama havuzlama katmanları eklenir. Bu şekilde, girdi verilerinin boyutu azaltılır ve modelin derinliği boyunca öğrenme kolaylaştırılır. Bu modül “Tam Başlangıç Modülü” olarak adlandırılır. Tam Başlangıç Modülü, boyut azaltma ve paralel involüsyon katmanlarını bir araya getirerek hesaplama maliyetini ve

eğitilebilir parametre sayısını verimli bir şekilde azaltır. Temel Başlangıç ve Tam Başlangıç modüllerinin involüsyonel versiyonları Şekil 3.14'te gösterilmiştir.




Şekil 3.14. İnvölüsyon için geliştirilen başlangıç modülleri.
(a) Temel başlangıç involüsyon modülü, (b) Tam başlangıç involüsyon modülü.

3.2.4.3. Çok Ölçekli Bağlamsal Yapı

Çok ölçekli bağlamsal yapı, derin öğrenme modellerinde kullanılan bir tekniktir. Bu teknikte, görüntüden farklı ölçeklerdeki özellikleri çıkarmak için birden fazla filtre boyutu ve ölçeklendirme katmanı kullanılır (Al-Masni ve Kim, 2021). Daha sonra, bu özellikler görüntüdeki nesnelerin ve özelliklerin daha iyi bir temsiliyi oluşturmak için modelin sonraki katmanlarına entegre edilir. Bu yapı, ağın farklı ölçeklerdeki özellikleri tanımasını ve anlamasını sağlayarak bir nesnenin hem ayrıntılarına hem de daha geniş bağlamsal yapıya odaklanabilen bir ağın tasarlanmasına olanak tanır.

HSG verileri, geniş bir spektral aralıkta yüzey özelliklerini karmaşık bir şekilde ölçen hacimli bilgiler içerir. Çok ölçekli bağlamsal yapılardan yararlanmak HSG veri analizinde önemli avantajlar sunabilir (Ding ve diğ., 2021). Bu yapılar, yüksek spektral çözünürlükleri sayesinde spektral imzaların ayrıntılı bir şekilde incelenmesini sağlayarak farklı nesneler arasındaki ayrımı artırır. Ek olarak, uzamsal ve spektral bilgilerin birleştirilmesi nesne ilişkilerinin anlaşılmasını geliştirir. Çevresel etkilerin azaltılması ve çeşitli uygulamalar için uygunluk gibi özellikleriyle çok ölçekli bağlamsal yapılar, HSG verilerin daha hassas bir şekilde analiz edilmesini sağlar. Şekil 3.15'te gösterilen Çok Ölçekli Bağlamsal Yapının involüsyonel versiyonu, giriş özellik haritasına farklı boyutlarda involüsyon filtre bankalarının uygulanmasını, özelliklerin çıkarılmasını, bir havuzlama işleminin gerçekleştirilmesini ve çıkış özellik haritasını elde etmek için ortaya çıkan çıktıların derinlemesine birleştirilmesini içerir.



Şekil 3.15. İnvölüsyon için özel olarak tasarlanmış Çok Ölçekli Bağlamsal Yapı.

3.3. Deneysel Ayarlar

Bu tez çalışması, uzaktan algılama, yeryüzü gözleme ve biyomedikal HSG veri setlerinin İSA ile analizi için geliştirilen bir metodolojinin deneysel uygulamalarını detaylı bir şekilde sunmaktadır. Bu bölümde, kullanılan deney ortamı ve araçlar ayrıntılı bir şekilde açıklanmıştır. Özellikle, her bir alanın özellikleri ve gereksinimleri dikkate alınarak performans değerlendirme ölçütleri titizlikle belirlenmiştir. Bu ölçütler, analizlerin objektif bir şekilde değerlendirilmesini ve sonuçların güvenilirliğini sağlamayı amaçlamaktadır.

3.3.1. Deney Ortamı ve Araçları

Bu tez çalışmasında, veri ön işleme ve model eğitim aşamaları 64 GB RAM ile donatılmış bir iş istasyonunda NVIDIA GeForce GTX 1080 Ti ekran kartı üzerinde yürütülmüştür. Biyomedikal görüntüleme veri seti için veri oluşturma, bilgi içeren spektrumların belirlenmesi ve Savitzky-Golay filtreleme gibi ön işleme adımları MATLAB 2022b kullanılarak gerçekleştirilmiştir. Boyut indirgeme Scikit-learn 1.0.2 kullanılarak yapılırken, geliştirilen involüsyon tabanlı modellerin eğitim ve test aşamaları Python 3.9.13 ve Keras 2.10.0 kütüphanesi kullanılarak TensorFlow 2.10.0 arka ucu ile uygulanmıştır.

3.3.2. Performans Değerlendirme Ölçütleri

Tez kapsamında, HSG verilerinin İSA ile analiz edilmesiyle elde edilen sonuçları değerlendirmek için çeşitli ölçütler kullanılmıştır. Her bir ölçüt aşağıda detaylandırılmıştır.

1) *Karmaşıklık Matrisi*: Bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir tablodur. Hem ikili sınıflı hem de çoklu sınıflı sınıflandırma uygulamaları için kullanılmaktadır. Her iki durumda da matrisin yapısı biraz farklılık göstermektedir.

a. İkili sınıflandırma uygulamaları: Karmaşıklık matrisi 2×2 boyutundadır ve şu şekilde temsil edilir:

	Tahmin Edilen Pozitif	Tahmin Edilen Negatif
Gerçek Pozitif	DP	YP
Gerçek Negatif	YN	DN

Burada:

- DP (Doğru Pozitif): Doğru pozitif tahminlerin sayısı, yani doğru şekilde pozitif olarak sınıflandırılan örneklerin sayısı.
- DN (Doğru Negatif): Doğru negatif tahminlerin sayısı, yani doğru şekilde negatif olarak sınıflandırılan örneklerin sayısı.

- YP (Yanlış Pozitif): Yanlış pozitif tahminlerin sayısı, yani negatif olarak sınıflandırılması gereken ancak pozitif olarak tahmin edilen örneklerin sayısı.
- YN (Yanlış Negatif): Yanlış negatif tahminlerin sayısı, yani pozitif olarak sınıflandırılması gereken ancak negatif olarak tahmin edilen örneklerin sayısı.

Karmaşıklık matrisi, çeşitli performans ölçütlerini hesaplamak için kullanılır.

Bazı temel ölçütler şunlardır:

Genel Doğruluk (GD): Doğru tahminlerin toplam veri sayısına oranıdır.

$$GD = \frac{(DP + DN)}{(DP + DN + YP + YN)} \quad 3.22$$

Kesinlik: Doğru pozitiflerin toplam pozitif tahmin sayısına oranıdır.

$$Kesinlik = \frac{DP}{(DP + YP)} \quad 3.23$$

Duyarlılık: Doğru pozitiflerin toplam pozitif sayısına oranıdır.

$$Duyarlılık = \frac{DP}{(DP + DN)} \quad 3.24$$

F1-Skor: Kesinlik ve Duyarlılık değerlerinin harmonik ortalamasıdır ve bir denge ölçüsü olarak kullanılır.

$$F1 - Skor = 2 \times \frac{(Kesinlik \times Duyarlılık)}{(Kesinlik + Duyarlılık)} \quad 3.25$$

Kappa (Cohen'in Kappa Katsayısı): Kappa, iki farklı tanı arasındaki tutarlılığı değerlendirmek için tıbbi uygulamada sıklıkla tercih edilen bir tekniktir (Kraemer, 1980). Bu teknik kullanılarak iki farklı olasılık hesaplanır; P_0 gözlenen doğruluk ve P_c bunun gerçekleşme olasılığıdır. İkili sınıflandırma uygulamalarında, eşit sayıda test verisi kullanıldığından $P_c = \%50$ olarak alınır.

$$Kappa = \frac{P_0 - P_c}{1 - P_c} \quad 3.26$$

Matthews Korelasyon Katsayısı (MKK): MKK, sınıflandırma modelinin performansını değerlendiren bir korelasyon ölçüsüdür ve özellikle dengesiz sınıflandırma problemlerinin performansını değerlendirmek için kullanılır (Matthews, 1975).

$$MKK = \frac{(DP \times DN) - (YP \times YN)}{\sqrt{(DP + YP) \times (DP + YN) \times (DN + YP) \times (DN + YN)}} \quad 3.27$$

MKK değeri -1 ile 1 arasında değişir. 1'e yakın bir değer mükemmel model performansını, 0'a yakın bir değer modelin rastgele tahminden daha iyi olmadığını ve -1'e yakın bir değer ise modelin tahminlerinin ters olduğunu gösterir. Tez kapsamında MKK için yüzde bazlı bir değerlendirme yapılmıştır.

b. Çoklu sınıflandırma uygulamalarında: Karmaşıklık matrisi $N \times N$ boyutundadır, burada N, sınıf sayısını temsil eder. Matrisin yapısı şu şekildedir:

		Tahmin Edilen Değerler			
Gerçek Değerler		C_{11}	C_{12}	...	C_{1N}
		C_{21}	C_{22}	...	C_{2N}
		...	...	$\ddots$	...
		C_{N1}	C_{N2}	...	C_{NN}

Burada:

- C_{ij} , gerçek sınıfı i olan örneklerin model tarafından sınıf j olarak tahmin edilen sayıdır.

Çoklu sınıflandırma durumunda, GD, kesinlik, duyarlılık, F1-skor, Kappa ve MKK metriklerini hesaplarken her sınıf için ayrı ayrı değerler kullanılır ve ardından bu değerler sınıflar arası ortalama alınarak genel performans ölçütleri elde edilir. Bu nedenle, çoklu sınıflandırmada karmaşıklık matrisi, modelin her bir sınıf için performansını daha ayrıntılı bir şekilde incelemek için önemlidir.

Ortalama Doğruluk (OD), çoklu sınıflandırma problemleri için kullanılan bir indekstir. Her bir sınıfın doğruluğunun ayrı ayrı hesaplanması ve ardından bu değerlerin ortalamasının alınmasıyla elde edilir.

2) *ROC (Alıcı İşletim Karakteristiği) eğrisi:* Farklı kesme noktalarında sınıflandırma modelinin kesinliği ve özgüllüğü arasındaki ilişkiyi gösteren bir eğridir. Bu eğri, modelin performansının görselleştirilmesidir.

Çok sınıflı ROC Eğrisi, çoklu sınıflandırma problemlerinde model performansını değerlendirmek için kullanılan bir araçtır. Her sınıf için hesaplanan doğru pozitif oranı (DPO) ve yanlış pozitif oranı (YPO) değerlerinin bir grafiğini temsil eder. Bu eğri, modelin farklı sınıfları nasıl ayırt ettiğini görselleştirir ve her sınıf için en uygun karar eşiğini belirler. Çok sınıflı ROC eğrisinde her sınıf için bir eğri bulunduğundan, bu eğrilerin karşılaştırılması karmaşık olabilir. Bu nedenle, çok sınıflı ROC eğrisi altında mikro-ortalama ROC eğrisi gibi özetleyici bir eğri kullanılmaktadır.

3) *AUC (Eğri Altındaki Alan):* AUC değeri, ROC eğrisi altındaki alanı ifade eder ve bir sınıflandırma modelinin performansını tek bir sayısal değerle ölçer. AUC değeri 0 ile 1 arasında yer alır ve 1 mükemmel bir sınıflandırma modelini temsil eder. Tez kapsamında AUC için yüzde bazlı bir değerlendirme yapılmıştır.

Çok sınıflı AUC, çoklu sınıflandırma problemlerinde ROC eğrisinin altındaki alanı temsil eder. AUC, bir modelin sınıflar arasında ayırım yapma yeteneğini ölçer. ROC eğrileri her sınıf için ayrı ayrı çizildiğinde, her eğrinin altındaki alan hesaplanır ve çok sınıflı AUC değerini elde etmek için toplanır. Çok sınıflı AUC değeri model performansının genel bir ölçüsü olarak işlev görse de mikro-ortalama AUC gibi özet metrikler sınıf bazında performansı anlamak için kullanılmaktadır.

4) *Diğer Performans Ölçütleri:* Yukarıda ifade edilen performans değerlendirme ölçütlerine ilave olarak, HSG verilerinin İSA ile analiz edilmesi sürecinde geliştirilen modellerin karmaşıklığını şekillendirmede önemli olan ve eğitim sürecinde ince ayar yapılan çeşitli hiper parametreleri (İnvölüsyon tasarımı içerisinde G ve r) de kapsamıştır. Boyut indirgeme için seçilen Temel Bileşen (TB) sayısının sınıflandırma performansı üzerindeki etkisi farklı değerler seçilerek karşılaştırılmıştır. Modellerin verimliliğini değerlendirmek için kayan nokta işlemleri (FLOP), parametre sayısı ve çıkarım süresi gibi tamamlayıcı ölçütler kullanılmıştır. FLOP hesaplama karmaşıklığının bir göstergesi olarak hizmet ederken, parametre sayısı modelin karmaşıklığı ve bellek gereksinimleri hakkında bilgi sağlamaktadır. Aynı zamanda, çıkarım süresi de tahmin hızını ölçmektedir. Ayrıca, geliştirilen modeller içerisindeki

belirli özelliklerin genel performansa bireysel katkılarını incelemek için ablastyon analizleri yapılmıştır.

Tez çalışması kapsamında, HSG verileri İSA ile analiz edilirken çeşitli uygulamalar gerçekleştirilmiş ve tüm değerlendirme ölçütlerini kullanmak yerine, her bir uygulama için uygun ve gerekli olan ölçütler belirlenmiş ve kullanılmıştır. İlgili ölçütler, uygulamanın doğasına ve amaçlarına uygun olarak seçilmiş ve uygulanmıştır. Her bir uygulama için performans değerlendirme sürecinde kullanılan ölçütler, yapılan uygulamalara ait bölümlerde belirtilmiştir.



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

HSG verilerinin İSA ile analizi, uzaktan algılama, yeryüzü gözleme ve biyomedikal görüntüleme alanlarında çeşitli uygulamalarla gerçekleştirilmiştir. Tez çalışması, yeni involüsyon tabanlı modeller geliştirerek bu modelleri belirtilen alanlarda çeşitli uygulamalarda değerlendirmiştir. Yapılan bu uygulamalar aşağıda detaylı olarak açıklanmıştır.


4.1. Uzaktan Algılama ve Yeryüzü Gözleme Deneyleri

Yüksek boyutlu uzaktan algılama ve yeryüzü gözleme HSG verilerini analiz etmek zordur. Bu bağlamda, Involutional Residual Spectral Network (IRSN) isimli derin öğrenme modeli, bu alandaki analizleri gerçekleştirmek ve HSG verilerinden anlamlı bilgiler çıkarmak amacıyla geliştirilmiştir. Bu bölümde, geliştirilen IRSN modeline ait detaylı bilgiler, modelin kullanımıyla gerçekleştirilen deneyler ve bu deneylerin sonuçları ile tartışmaları ayrıntılı olarak ele alınmıştır.

4.1.1. Involutional Residual Spectral Network (IRSN)

HSG veri küpü $\mathbf{I} \in \mathbb{R}^{H \times W \times \lambda}$ olarak ifade edilir, burada $\mathbf{I}$ giriş verisi, H uzunluk, W genişlik ve λ spektral bant sayısı veya derinliktir. $\mathbf{I}$ verisinde her bir piksel farklı dalga boylarında bilgiler içermektedir. Ayrıca her bir piksel farklı bir sınıfı temsil etmektedir. Çok boyutluluğu azaltmak ve daha anlamlı bantları kullanmak için giriş verisine ($\mathbf{I}$) TBA uygulanır. Bu sayede uzamsal boyut değişmeyecek şekilde spektral boyut azaltılmıştır. TBA sonucunda yeni verinin boyutu $\mathbf{X} \in \mathbb{R}^{H \times W \times B}$ olmuştur, burada $\mathbf{X}$, TBA sonrası elde edilmiş veri, H uzunluk, W genişlik ve B TBA sonrası spektral bant sayısıdır.

Derin öğrenme tekniklerini kullanmak için Komşuluk Çıkarma (KÇ) (Cihan ve Ceylan, 2023) yöntemi kullanılarak veri 3B parçalara bölünmüştür. Bu yöntemle $\mathbf{X}$ verisinden her bir piksel orta nokta olacak şekilde 3B komşu veriler $\mathbf{P} \in \mathbb{R}^{S \times S \times B}$ oluşturulmuş ve bu veriler önerilen modelin eğitimi için kullanılmıştır. Her bir pikselin orta nokta olabilmesi için genel çerçeve S boyutu dikkate alınarak $\mathbf{X}$ verisi $(S - 1)/2$ oranında genişletilmiş, böylece tüm piksellerin orta nokta olması sağlanmış ve veri kaybının önüne geçilmiştir.



Şekil 4.1. Önerilen Involutorial Residual Spectral Network (IRSN)

TBA: Temel Bileşenler Analizi, KÇ: Komşuluk Çıkarma, Inv: İnvolüsyon Katmanı, Sum: Toplama, AvePool: Ortalama Havuzlama, Flatten: Düzleştirme, Dropout: Unutturma, FC: Tam Bağlı Katman.

HSG verileri analiz etmek için geliştirilen IRSN modeli Şekil 4.1'de gösterilmiştir. Bu model, anlamlı HSG bilgi çıkarımını geliştirerek verilere göre uyarlanmış involüsyon çekirdeklerini kullanır. Veri odaklı olarak oluşturulan involüsyon çekirdekleri daha iyi içgörülere katkıda bulunur. İnvolüsyon katmanları, G (16) ve r (8) parametrelili 7×7 çekirdek boyutları kullanılarak IRSN modeline entegre edilmiştir. Ek olarak, bilgiyi korumak ve gradyanla ilgili zorlukları ele almak için üç artık blok eklenmiştir. Her bir artık bloğun hemen ardından doğrusal olmama durumunu artıran bir ReLU aktivasyon fonksiyonu gelmektedir. Her bir artık bloğu 2×2 ortalama havuzlama yoluyla alt örnekleme takip eder ve bu da boyut azaltma ile sonuçlanır. Üçüncü artık bloğun sonunda, bir düzleştirme işlemi uygulanarak ardışık iki tam bağlı katmanla daha fazla derinlik elde edilir. İlk tam bağlı katman 256 nöron içerirken, ikincisi 128 nöron barındırır. Aşırı uyumla mücadele etmek için, her tam bağlı katmandan sonra 0.2'lik orana sahip unutturma katmanları kullanılır. Son olarak, sınıflandırma işlemi softmax aktivasyon fonksiyonu kullanılarak tamamlanır.

Çizelge 4.1. Geliştirilen IRSN modelinin ayrıntılı katman özeti ($S=21$ için).
Son katman IP veri setine göre ayarlanmıştır.

Katman (Tipi)	Çıkış Şekli	Parametre
input_1 (GirişKatmanı)	(21, 21, 32)	0
inv_1 (İnvolüsyon)	(21, 21, 32)	1605
inv_2 (İnvolüsyon)	(21, 21, 32)	1605
add_1 (Toplam)	(21, 21, 32)	0
avepool2d_1 (OrtHavuzlama2B)	(10, 10, 32)	0
inv_3 (İnvolüsyon)	(10, 10, 32)	1605
inv_4 (İnvolüsyon)	(10, 10, 32)	1605
add_2 (Toplam)	(10, 10, 32)	0
avepool2d_2 (OrtHavuzlama2B)	(5, 5, 32)	0
inv_5 (İnvolüsyon)	(5, 5, 32)	1605
inv_6 (İnvolüsyon)	(5, 5, 32)	1605
add_3 (Toplam)	(5, 5, 32)	0
avepool2d_3 (OrtHavuzlama2B)	(2, 2, 32)	0
flatten_1 (Düzleştirme)	(128)	0
dense_1 (TamBağlı)	(256)	33024
dropout_1 (Unutturma)	(256)	0
dense_2 (TamBağlı)	(128)	32896
dropout_2 (Unutturma)	(128)	0
dense_3 (TamBağlı)	(16)	2064
Toplam Parametre: 77.614		

Çizelge 4.1, katman türü, çıktı haritası boyutu ve parametre sayısı açısından önerilen modelin bir özetini sunmaktadır. Parametre sayısı, kullanılan veri kümesine ve sınıf sayısına bağlıdır. Çizelge, uzamsal boyut (S) değeri 21 olan 16 sınıflı IP veri kümesi kullanılarak oluşturulmuştur. IP veri kümesi için IRSN modelindeki toplam parametre sayısı 77.614'tür. Tüm ağırlıklar ve bias değerleri başlangıçta rastgele seçilmiştir. Geriye yayılım algoritması olarak *Adam* optimizier kullanılmış ve kayıp fonksiyonu olarak Kategorik Çapraz Entropi tercih edilmiştir. Parça büyüklüğü 256 olarak ayarlanmış ve model 100 iterasyonda eğitilmiştir.

4.1.2. Deneysel Sonuçlar

Geliştirilen IRSN modelinin etkinliğini göstermek için dört farklı veri kümesi kullanılmıştır. 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN ve Hybrid3D/2D gibi diğer modellerle karşılaştırmalı bir analiz yapılmıştır. Bu modeller 2B-ESA tabanlı, 3B-ESA tabanlı ve 2B-3B-ESA tabanlı kategorilerine girmektedir. Değerlendirme için üç nicel ölçüt kullanılmıştır: GD, OD ve Kappa. Model etkinliğini değerlendirmek için FLOP, parametre sayısı ve çıkarım süresi gibi ek ölçütler kullanılmıştır.

4.1.2.1. Eğitim Detayları

Deneylerde, kamuya açık dört farklı HSG veri kümesi kullanılmıştır: IP, UP, SA ve KSC. Sınıflandırma sonuçlarına göre 0.001 öğrenme oranı en uygun oran olarak belirlenmiştir. Adil bir karşılaştırma yapabilmek amacıyla, farklı veri setleri için aynı uzamsal boyuta sahip girdi hacminin 3B parçaları oluşturulmuştur. Bu bağlamda, IP ile KSC veri setleri için $21 \times 21 \times 32$ boyutunda parçalar ve UP ile SA veri setleri için $21 \times 21 \times 16$ boyutlarında parçalar kullanılmıştır. Bütün veri setleri için rastgele olarak tüm verinin %10'u eğitim, geriye kalan %90'ı test için ayrılmıştır.

4.1.2.2. Deneysel Tartışma

Önerilen yöntem, 2D-CNN (Zhao ve diğ., 2021), 3D-CNN (Paoletti ve diğ., 2019), HSIC (Ahmad ve diğ., 2020), HybridSN (Roy ve diğ., 2019), MCNN-CP (Zheng ve diğ., 2021), CMR-CNN (Yang ve diğ., 2022) ve Hybrid3D/2D (Fırat ve diğ., 2023) dahil olmak üzere diğer gelişmiş HSG sınıflandırma yaklaşımlarıyla karşılaştırılmıştır. Bu karşılaştırma, önerilen yöntem kullanılarak elde edilen sonuçların doğruluğunu ve etkinliğini değerlendirmek için gerçekleştirilmiştir.

Çizelge 4.2. Tüm veri setleri üzerinde önerilen yöntem ve diğer gelişmiş yöntemler için Genel Doğruluk (%).

Yöntemler	Genel Doğruluk (%)			
	IP	UP	SA	KSC
2D-CNN	91.87 ± 1.8	99.36 ± 0.1	96.99 ± 0.6	81.60 ± 1.1
3D-CNN	98.45 ± 0.2	99.68 ± 0.1	99.97 ± 0.0	89.06 ± 0.5
HSIC	95.04 ± 1.3	98.98 ± 0.1	99.87 ± 0.0	67.35 ± 1.1
HybridSN	97.68 ± 0.9	99.68 ± 0.1	99.95 ± 0.0	88.40 ± 0.4
MCNN-CP	97.44 ± 1.4	98.42 ± 0.4	99.95 ± 0.0	75.29 ± 1.2
CMR-CNN	93.06 ± 2.3	99.63 ± 0.2	99.96 ± 0.0	70.77 ± 0.5
Hybrid3D/2D	98.65 ± 0.2	99.66 ± 0.1	99.97 ± 0.0	88.89 ± 1.6
IRSN	98.91 ± 0.2	99.86 ± 0.1	99.98 ± 0.0	98.79 ± 0.3

Çizelge 4.3. Tüm veri setleri üzerinde önerilen yöntem ve diğer gelişmiş yöntemler için Ortalama Doğruluk (%).

Yöntemler	Ortalama Doğruluk (%)			
	IP	UP	SA	KSC
2D-CNN	87.92 ± 4.5	99.27 ± 0.1	98.23 ± 0.4	75.17 ± 3.4
3D-CNN	96.77 ± 1.0	99.12 ± 0.2	99.97 ± 0.0	84.51 ± 2.3
HSIC	92.82 ± 2.2	98.33 ± 0.2	99.82 ± 0.0	53.03 ± 7.6
HybridSN	95.95 ± 2.4	99.05 ± 0.1	99.94 ± 0.0	84.64 ± 1.5
MCNN-CP	97.11 ± 1.6	95.48 ± 0.8	99.94 ± 0.0	62.88 ± 5.6
CMR-CNN	91.89 ± 4.2	99.16 ± 0.4	99.90 ± 0.0	68.55 ± 1.7
Hybrid3D/2D	98.00 ± 0.6	99.03 ± 0.2	99.94 ± 0.0	84.12 ± 3.5
IRSN	98.70 ± 0.3	99.72 ± 0.2	99.97 ± 0.0	98.13 ± 0.4

Çizelge 4.4. Tüm veri setleri üzerinde önerilen yöntem ve diğer gelişmiş yöntemler için Kappa (%).

Yöntemler	Kappa (%)			
	IP	UP	SA	KSC
2D-CNN	90.75 ± 2.5	99.15 ± 0.1	96.64 ± 0.8	79.44 ± 2.3
3D-CNN	98.23 ± 0.3	99.57 ± 0.1	99.97 ± 0.0	87.81 ± 0.9
HSIC	94.34 ± 1.8	98.64 ± 0.1	99.80 ± 0.0	63.27 ± 3.5
HybridSN	97.35 ± 1.3	99.64 ± 0.1	99.95 ± 0.0	87.07 ± 0.8
MCNN-CP	97.08 ± 1.7	97.90 ± 0.3	99.95 ± 0.0	72.16 ± 2.1
CMR-CNN	92.10 ± 3.2	99.50 ± 0.1	99.95 ± 0.0	67.55 ± 3.1
Hybrid3D/2D	98.45 ± 0.3	99.55 ± 0.1	99.97 ± 0.0	87.59 ± 1.8
IRSN	98.75 ± 0.3	99.81 ± 0.1	99.98 ± 0.0	98.65 ± 0.3

Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4, sırasıyla farklı yöntemler için çoklu denemelerden elde edilen GD, OD ve Kappa değerlerini göstermektedir. Çizelgeler incelendiğinde, geliştirilen IRSN modelinin diğer gelişmiş tekniklere kıyasla oldukça üstün sonuçlar elde ettiği açıkça görülmektedir. Önerilen IRSN modeline involüsyon katmanlarının dahil edilmesi, spektral imzalar kullanılarak veriye özgü involüsyon çekirdeklerinin oluşturulmasını ve böylece daha az parametre ile daha anlamlı


özelliklerin öğrenilmesini sağlamıştır. Ayrıca, artık blokların dahil edilmesi bilginin korunmasına ve gradyanla ilgili zorlukların azaltılmasına yardımcı olmuştur.

Sonuçlar, önerilen IRSN modelinin etkinliğini vurgulamakta ve HSG sınıflandırma görevlerinde diğer gelişmiş yöntemlerden daha iyi performans gösterme kabiliyetini ortaya koymaktadır. İnvolüsyon katmanlarının ve artık blokların kullanımı, gelişmiş özellik öğrenmeye ve genel performansın iyileştirilmesine katkıda bulunarak önerilen yaklaşımın üstünlüğünü ortaya koymaktadır.


Geliştirilen IRSN, ESA yöntemleriyle karşılaştırıldığında, dört farklı veri seti için çeşitli değerlendirme ölçütlerinde üstün performans göstermiş, özellikle UP ve SA veri kümelerinde tüm sınıflar için yüksek doğruluk oranları elde etmiştir. Karmaşık IP ve KSC veri kümeleri üzerinde oldukça etkili olan IRSN modeli, alternatif yöntemlerden sürekli olarak daha iyi performans göstermiştir. 3B-ESA yöntemleri, spektral ve uzamsal bilgilerden yararlanmaları nedeniyle genellikle 2B muadillerinden daha iyi performans sergilerken, IRSN modeli daha az parametre ile daha yüksek doğruluk elde ederek öne çıkmıştır.

IP, UP, SA ve KSC'nin HSG için sınıflandırma haritaları 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN, Hybrid3D/2D ve geliştirilen IRSN yöntemleri kullanılarak sırasıyla Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te gösterilmiştir. Özellikle, 3D-CNN, Hybrid3D/2D ve önerilen IRSN önemli bir başarı sergilemektedir. Bu yöntemler karşılaştırıldığında, Hybrid3D/2D, 3D-CNN'den daha yüksek bir kalite sergilerken, önerilen IRSN modeli görsel kalite açısından her ikisini de geride bırakmaktadır. Geliştirilen IRSN modeli, dikkate değer bir şekilde daha kompleks bir yapıya sahip olan KSC veri setinde elde ettiği başarılı tespitler ile üstün performansını ispatlamıştır.


Çizelge 4.5, Çizelge 4.6, Çizelge 4.7 ve Çizelge 4.8, sırasıyla IP, UP, SA ve KSC'nin sınıf bazlı sınıflandırma sonuçlarını göstermektedir. Bu çizelgelerdeki sonuçlara bakılarak, geliştirilen IRSN modelinin sınıf bazında da yüksek başarı elde ettiği söylenebilir. SA veri seti için neredeyse tüm sınıfları doğru tespit etmiş daha kompleks KSC veri setinde ise diğer yöntemlere kıyasla oldukça başarılı sonuçlar vermiştir.




Şekil 4.2. IP veri kümesi için sınıflandırma haritaları. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c-j) Sırasıyla 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN, Hybrid3D/2D ve geliştirilen IRSN için tahmin edilen sınıflandırma haritaları.



Şekil 4.3. UP veri kümesi için sınıflandırma haritaları. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c-j) Sırasıyla 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN, Hybrid3D/2D ve geliştirilen IRSN için tahmin edilen sınıflandırma haritaları.



Şekil 4.4. SA veri kümesi için sınıflandırma haritaları. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c-j) Sırasıyla 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN, Hybrid3D/2D ve geliştirilen IRSN için tahmin edilen sınıflandırma haritaları.



Şekil 4.5. KSC veri kümesi için sınıflandırma haritaları. (a) Sahte Renk görüntüsü, (b) Kesin Referans görüntüsü, (c-j) Sırasıyla 2D-CNN, 3D-CNN, HSIC, HybridSN, MCNN-CP, CMR-CNN, Hybrid3D/2D ve geliştirilen IRSN için tahmin edilen sınıflandırma haritaları.

Çizelge 4.5. IP veri seti için sınıf bazlı sınıflandırma doğrulukları.

Sınıflar	Eğitim/Test	2D-CNN	3D-CNN	HSIC	HybridSN	MCNN-CP	CMR-CNN	Hybrid3D/2D	IRSN
Alfalfa	4/37	85.37	90.24	73.17	87.81	92.68	100	95.12	100
Corn-no till	129/1156	64.59	95.02	92.22	94.63	93.23	88.67	94.47	96.81
Corn-min till	75/672	99.60	99.87	92.91	98.93	97.72	93.31	100	100
Corn	21/192	93.43	87.33	83.10	92.96	100	88.26	100	100
Grass-pasture	44/391	99.77	98.62	98.39	98.16	97.01	94.48	100	100
Grass-trees	66/591	98.78	99.09	98.78	97.72	99.70	99.85	98.94	99.09
Grass-pasture-mowed	3/22	100	100	100	100	100	100	100	100
Hay-windrowed	43/387	98.61	100	100	100	100	95.81	100	100
Oats	2/16	0	88.89	72.22	88.89	94.44	88.89	94.44	94.44
Soybean-no till	88/787	93.60	98.97	95.54	97.94	97.83	88.46	97.94	98.86
Soybean-min till	221/1989	95.57	99.73	94.12	98.55	98.42	93.71	100	100
Soybean-clean	53/481	96.44	97.94	91.76	94.76	92.14	88.39	96.63	96.82
Wheat	19/166	99.46	100	99.46	99.46	95.68	93.51	100	100
Woods	114/1025	99.91	100	99.47	100	99.91	99.82	100	100
Buildings-Grass-Trees-Drives	35/312	81.56	99.71	95.10	99.71	98.56	91.64	100	100
Stone-Steel-Towers	8/76	100	92.86	98.81	85.71	96.43	65.48	90.48	97.62
GD	925/8300	91.87	98.45	95.04	97.68	97.44	93.06	98.65	98.91
Kappa		90.75	98.23	94.34	97.35	97.08	92.10	98.45	98.75
OD		87.92	96.77	92.82	95.95	97.11	91.89	98.00	98.70

Çizelge 4.6. UP veri seti için sınıf bazlı sınıflandırma doğrulukları.

Sınıflar	Eğitim/Test	2D-CNN	3D-CNN	HSIC	HybridSN	MCNN-CP	CMR-CNN	Hybrid3D/2D	IRSN
Asphalt	597/5371	99.36	99.97	99.16	100	100	99.88	100	100
Meadows	1678/15106	99.98	99.95	99.89	99.99	99.92	100	100	100
Gravel	189/1700	98.52	99.89	94.44	99.21	97.19	97.99	99.47	99.21
Trees	276/2482	99.86	98.73	97.14	99.53	89.56	98.62	99.31	99.89
Painted metal sheets	121/1090	100	100	100	100	99.92	100	99.84	100
Bare Soil	453/4073	97.57	100	98.72	100	100	100	100	100
Bitumen	120/1077	100	99.67	98.66	100	99.17	99.33	99.33	100
Self-Blocking Bricks	331/2983	98.10	99.13	98.28	99.40	99.25	99.03	98.58	99.46
Shadows	85/767	100	94.72	98.71	93.31	74.30	97.54	94.72	99.06
GD	3850/34649	99.36	99.68	98.98	99.68	98.42	99.63	99.66	99.86
Kappa		99.15	99.57	98.64	99.64	97.90	99.50	99.55	99.81
OD		99.27	99.12	98.33	99.05	95.48	99.16	99.03	99.72


Çizelge 4.7. SA veri seti için sınıf bazlı sınıflandırma doğrulukları.

Sınıflar	Eğitim/Test	2D-CNN	3D-CNN	HSIC	HybridSN	MCNN-CP	CMR-CNN	Hybrid3D/2D	IRSN
Brocoli green weeds 1	181/1627	100	100	100	99.78	100	100	100	100
Brocoli green weeds 2	335/3019	100	100	100	100	100	100	100	100
Fallow	178/1601	100	100	100	100	100	100	99.94	100
Fallow rough plow	126/1129	99.32	100	99.76	100	100	99.04	99.44	100
Fallow smooth	241/2169	99.14	100	99.46	99.25	99.54	99.88	100	99.50
Stubble	356/3207	99.63	99.97	100	100	99.94	100	100	100
Celery	322/2899	100	100	100	100	99.91	99.91	100	100
Grapes untrained	1014/9130	99.87	100	99.75	100	100	100	100	100
Soil vinyard develop	558/5025	100	100	100	100	100	100	100	100
Corn senesced green weeds	295/2655	98.14	99.97	99.86	99.93	100	100	100	100
Lettuce romaine 4wk	96/865	96.95	100	100	100	100	100	99.69	100
Lettuce romaine 5wk	173/1561	100	100	100	100	99.83	100	100	100
Lettuce romaine 6wk	83/742	99.54	100	100	100	100	99.64	100	100
Lettuce romaine 7wk	96/867	99.90	100	100	100	99.79	100	100	100
Vinyard untrained	654/5887	80.02	99.94	99.39	100	99.97	99.99	99.99	100
Vinyard vertical trellis	163/1463	99.19	100	99.75	100	100	100	100	100
GD	4871/43846	96.99	99.97	99.87	99.95	99.95	99.96	99.97	99.98
Kappa		96.64	99.97	99.80	99.95	99.95	99.95	99.97	99.98
OD		98.23	99.97	99.82	99.94	99.94	99.90	99.94	99.97

Çizelge 4.8. KSC veri seti için sınıf bazlı sınıflandırma doğrulukları.

Sınıflar	Eğitim/Test	2D-CNN	3D-CNN	HSIC	HybridSN	MCNN-CP	CMR-CNN	Hybrid3D/2D	IRSN
Scrub	69/616	99.71	94.31	96.93	91.68	94.45	23.50	96.20	100
Willow swamp	22/197	52.51	73.06	25.57	83.11	56.62	44.29	69.41	95.43
CP hammock	23/207	57.39	95.65	11.30	88.70	2.61	78.26	93.04	96.09
Slash pine	23/204	35.68	45.38	18.50	55.51	32.16	49.78	53.30	88.11
Oak Broadleaf	15/130	66.90	84.83	69.66	99.31	100	100	99.31	100
Hardwood	21/185	74.76	84.95	8.25	78.64	16.02	41.26	71.36	97.57
Swamp	9/85	91.49	71.28	5.32	63.83	0	45.75	60.64	100
Graminod marsh	39/349	48.45	94.33	49.74	97.17	92.01	87.89	88.92	98.45
Spartina marsh	47/421	98.93	98.72	94.87	86.54	35.90	60.68	78.63	100
Cattail marsh	36/328	79.12	71.43	55.77	68.68	93.41	72.80	90.11	100
Salt marsh	38/339	98.14	99.74	93.63	90.45	100	100	95.76	100
Mud flats	45/408	74.17	84.99	38.63	98.01	94.26	86.98	96.91	100
Water	83/751	100	100	99.52	98.68	100	100	100	100
GD	470/4220	81.60	89.06	67.35	88.40	75.29	70.77	88.89	98.79
Kappa		79.44	87.81	63.27	87.07	72.16	67.55	87.59	98.65
OD		75.17	84.51	53.03	84.64	62.88	68.55	84.12	98.13

Şekil 4.6, farklı eğitim veri yüzdelerinde IP ve KSC veri setleri üzerinde çeşitli yöntemler için deneysel sonuçları göstermektedir. Daha yüksek oranlar HSG sınıflandırmasında doğruluğun artmasına neden olurken IP için %15'te minimum farklar görülmektedir. CMR-CNN ve 3D-CNN %1'de düşerken, IRSN düşük eğitim veri yüzdelerinde (%1 veya %5) üstünlük sağlayarak sınırlı eğitim örnekleriyle etkinliğini göstermektedir. KSC veri setinde hem düşük hem de yüksek eğitim veri yüzdelerinde diğer yöntemlerden daha iyi performans sergilemektedir. Çizelge 4.9, IP veri kümesi üzerindeki ablasyon çalışmalarını özetlemekte, önerilen modeldeki her bir bileşenin etkinliğini değerlendirmekte ve genel performansa katkılarını ortaya koymaktadır.



Şekil 4.6. IP (solda) ve KSC (sağda) veri setleri üzerinde farklı sayıda eğitim örneği ile çeşitli yöntemlerin Genel Doğrulukları.

Çizelge 4.9. IRSN modeli içerisinde bulunan farklı ağ yapılarının ablasyon çalışması.

Yöntem	Kappa	OD	GD
Temel Model	94.50	91.96	95.19
Temel Model + Artık Bloklar	96.82	95.79	97.21
Temel Model + Artık Bloklar + Ortalama Havuzlama (IRSN)	98.75	98.70	98.91

Çizelge 4.10'da önerilen yöntem ve diğer yaklaşımlar için parametre sayıları, FLOP değerleri ve çıkarım süreleri karşılaştırılmıştır. Önerilen yöntem en düşük parametre sayısına ve önemli ölçüde daha düşük FLOP değerlerine sahiptir, bu da daha az güçlü donanımlarda daha hızlı sonuçlar alınabileceğini göstermektedir. 3D-CNN ve HSIC gibi ESA tabanlı yöntemler, NVIDIA'nın CUDA teknolojisi aracılığıyla konvolüsyon işlemleri için GPU'ları optimize etmesi nedeniyle daha hızlı çıkarım süreleri göstermektedir. NVIDIA'nın sağladığı ilerlemelerle, optimize edilmiş çekirdeklerin kullanılması doğrultusunda konvolüsyon işlem sürelerinde gelecekte daha fazla iyileştirme beklenmektedir.

Çizelge 4.10. Tüm veri setleri üzerinde diğer gelişmiş yöntemler ve geliştirilen yöntem kullanılarak elde edilen parametre sayıları, FLOP değerleri ve çıkarım süreleri.
M: milyon, G: giga ve dk: dakika anlamına gelmektedir.

Yöntemler	IP Veri Seti			UP Veri Seti			SA Veri Seti			KSC Veri Seti		
	Parametre (M)	FLOP (G)	Çıkarım Süresi (dk)	Parametre (M)	FLOP (G)	Çıkarım Süresi (dk)	Parametre (M)	FLOP (G)	Çıkarım Süresi (dk)	Parametre (M)	FLOP (G)	Çıkarım Süresi (dk)
2D-CNN	0.66	1.29	0.28	0.65	1.26	0.80	0.66	1.27	0.27	0.65	1.29	0.23
3D-CNN	1.81	54.57	1.04	1.80	54.57	4.09	1.81	54.57	5.45	1.80	54.57	0.59
HSIC	1.00	5.16	0.26	1.00	5.16	0.90	1.00	5.16	1.12	1.00	5.16	0.18
HybridSN	5.12	124.5	2.37	4.85	23.63	2.81	4.85	23.63	3.31	5.12	124.5	1.25
MCNN-CP	0.37	137.1	2.49	0.12	25.72	2.81	0.12	25.72	3.53	0.37	137.1	1.33
CMR-CNN	0.93	118.6	3.87	0.74	118.6	16.3	0.93	118.6	20.8	0.85	118.6	2.03
Hybrid3D/2D	1.26	3038	11.6	1.26	3038	48.4	1.26	3038	61.4	1.26	3038	6.07
IRSN	0.08	1.64	2.05	0.06	1.17	9.26	0.06	1.17	11.7	0.08	1.64	1.35

Modelin performansı üzerindeki etkilerini değerlendirmek amacıyla involüsyon tasarımındaki çeşitli bileşenler, *kernel_boyutu*, *G* ve *r* dahil olmak üzere incelenmiştir. Bu sayede modelin performansı farklı parametre ayarlarında test edilebilmiştir. Çizelge 4.11, Çizelge 4.12, Çizelge 4.13 ve Çizelge 4.14, değişen *G* değerleri, *r* değerleri ve *kernel_boyutu* değerleri için tüm veri setleri kullanarak parametre sayılarını, FLOP değerlerini ve Top-1 GD değerlerini göstermektedir. Bu çizelgeler incelendiğinde, en iyi sonuçların *G*=16, *r*=8 ve *kernel_boyutu*=7 ile elde edildiği görülmektedir. Özellikle, FLOP değerleri bu durumlarda parametre sayısı ile artmaktadır. Ayrıca, farklı uzamsal boyutların (*S*) performanstaki rolünü değerlendirmek için deneyler yapılmıştır. Çizelgeler incelendiğinde en iyi sonuçların *S*=21 için elde edildiği görülmüştür.

4.1.4. Araştırma Bulguları

HSG sınıflandırması için involüsyon kavramını içeren yenilikçi bir sinir ağı modeli önerilmiştir. Amaç, sınıflandırma doğruluğunu artırırken konvolüsyon tabanlı HSG sınıflandırma yöntemlerini kullanmanın hesaplama maliyetini azaltmaktır. Bunu başarmak için, sadece modelin ayırt edici kapasitesini ve ifade gücünü artırmakla kalmayan, aynı zamanda kendi kendine dikkat mekanizmaları ile hesaplama maliyetini azaltan bir involüsyon yaklaşımı benimsenmiştir. DeneySEL sonuçlar, geliştirilen IRSN modelinin sınıflandırma doğruluğu ve hesaplama verimliliği açısından üstün performans sergilediğini göstermektedir. Önerilen yöntem HSG veri setleri için oldukça uygundur.

Çizelge 4.11. IP veri seti için farklı involüsyon hiper parametreleri ve S değerleri için elde edilen sonuçlar.

Çeşitli G değerleri için elde edilen sonuçlar			
G	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.069	1.005	98.55
4	0.071	1.133	98.36
8	0.073	1.303	98.87
16	0.078	1.644	98.91
Farklı r değerleri kullanılarak elde edilen sonuçlar			
r	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.112	4.961	98.22
2	0.092	3.066	98.37
4	0.083	2.118	98.35
8	0.078	1.644	98.91
Farklı kernel_boyutu değerleri için elde edilen sonuçlar			
kernel_boyutu	Parametre (M)	FLOP (G)	Top-1 GD (%)
3×3	0.070	0.346	98.70
5×5	0.073	0.865	98.52
7×7	0.078	1.644	98.91
9×9	0.084	2.683	98.55
Çeşitli S değerleri ile elde edilen sonuçlar			
S×S	Parametre (M)	FLOP (G)	Top-1 GD (%)
19×19	0.078	1.337	98.40
21×21	0.078	1.644	98.91
23×23	0.078	1.954	98.24
25×25	0.078	2.345	98.74

Çizelge 4.12. UP veri seti için farklı involüsyon hiper parametreleri ve S değerleri için elde edilen sonuçlar.

Çeşitli G değerleri için elde edilen sonuçlar			
G	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.051	0.533	99.66
4	0.053	0.661	99.09
8	0.056	0.831	99.66
16	0.060	1.172	99.73
Farklı r değerleri kullanılarak elde edilen sonuçlar			
r	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.094	4.424	99.63
2	0.075	2.565	99.66
4	0.065	1.636	99.68
8	0.060	1.172	99.73
Farklı kernel_boyutu değerleri için elde edilen sonuçlar			
kernel_boyutu	Parametre (M)	FLOP (G)	Top-1 GD (%)
3×3	0.053	0.244	99.62
5×5	0.056	0.615	99.63
7×7	0.060	1.172	99.73
9×9	0.066	1.952	99.51
Çeşitli S değerleri ile elde edilen sonuçlar			
S×S	Parametre (M)	FLOP (G)	Top-1 GD (%)
19×19	0.060	0.953	99.60
21×21	0.060	1.172	99.73
23×23	0.060	1.392	99.58
25×25	0.081	1.666	99.57

Çizelge 4.13. SA veri seti için farklı involüsyon hiper parametreleri ve S değerleri için elde edilen sonuçlar.

Çeşitli G değerleri için elde edilen sonuçlar			
G	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.052	0.533	99.97
4	0.054	0.661	99.95
8	0.056	0.831	99.96
16	0.061	1.172	99.98
Farklı r değerleri kullanılarak elde edilen sonuçlar			
r	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.095	4.424	99.87
2	0.076	2.566	99.94
4	0.066	1.637	99.93
8	0.061	1.172	99.98
Farklı kernel_boyutu değerleri için elde edilen sonuçlar			
kernel_boyutu	Parametre (M)	FLOP (G)	Top-1 GD (%)
3×3	0.054	0.245	99.97
5×5	0.057	0.616	99.97
7×7	0.061	1.172	99.98
9×9	0.067	1.914	99.85
Çeşitli S değerleri ile elde edilen sonuçlar			
S×S	Parametre (M)	FLOP (G)	Top-1 GD (%)
19×19	0.061	0.954	99.95
21×21	0.061	1.172	99.98
23×23	0.061	1.393	99.95
25×25	0.082	1.667	99.95

Çizelge 4.14. KSC veri seti için farklı involüsyon hiper parametreleri ve S değerleri için elde edilen sonuçlar.

Çeşitli G değerleri için elde edilen sonuçlar			
G	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.068	1.005	93.05
4	0.070	1.133	92.32
8	0.073	1.303	95.18
16	0.077	1.644	98.79
Farklı r değerleri kullanılarak elde edilen sonuçlar			
r	Parametre (M)	FLOP (G)	Top-1 GD (%)
1	0.112	4.961	71.37
2	0.092	3.065	85.35
4	0.082	2.118	94.67
8	0.077	1.644	98.79
Farklı kernel_boyutu değerleri için elde edilen sonuçlar			
kernel_boyutu	Parametre (M)	FLOP (G)	Top-1 GD (%)
3×3	0.070	0.346	92.69
5×5	0.073	0.865	94.22
7×7	0.077	1.644	98.79
9×9	0.083	2.683	95.40
Çeşitli S değerleri ile elde edilen sonuçlar			
S×S	Parametre (M)	FLOP (G)	Top-1 GD (%)
19×19	0.077	1.337	93.77
21×21	0.077	1.644	98.79
23×23	0.077	1.954	96.65
25×25	0.118	2.345	98.74

4.2. Biyomedikal Görüntüleme Deneyleri

HSG teknolojisinin sağlık alanında kullanımı son yıllarda oldukça artmıştır. Özellikle, HSG verilerinin analizi, yenidoğan hastalıklarının erken teşhisi ve tedavisi için yeni ve etkili yöntemlerin geliştirilmesinde önemli bir rol oynamaktadır. Bu bağlamda, involüsyon tabanlı sinir ağlarının kullanımıyla biyomedikal HSG verilerinin analizi odak noktası olarak ele alınmıştır. Yenidoğan hastalıklarının tanımlanmasında HSG verilerinin involüsyon tabanlı derin öğrenme modelleriyle nasıl işlenebileceği ve yüksek hassasiyetle tanımlanabileceği ayrıntılı olarak incelenmiştir. Yapılan çalışmalar, biyomedikal görüntüleme deneylerinde involüsyon tabanlı sinir ağlarının etkinliğini değerlendirerek, HSG verilerin doğru bir şekilde analiz edilmesi için yeni bir yaklaşım sunmaktadır.


4.2.1. İnvolüsyon Tabanlı HarmonyNet: Yenidoğan Sağlık Durumunun Otomatik Tespiti için Verimli Bir Hiperspektral Görüntüleme Modeli

Yenidoğan sağlığı, bebeklerin hassas ilk dönemlerinde refahlarının izlenmesi ve gerekli müdahalelerin hızla uygulanması açısından büyük önem taşımaktadır. HSG, yenidoğanların sağlık durumunu hızlı ve doğru bir şekilde tespit etme potansiyeline sahip kritik bir araç olarak öne çıkmıştır. Bu çalışmada önerilen involüsyon tabanlı HarmonyNet modelinin, HSG kullanarak yenidoğanların sağlık durumunu otomatik olarak tespit etme yeteneği araştırılmıştır. Bu araştırmanın grafiksel özeti EK-2'de yer almaktadır.

4.2.1.1. HarmonyNet

HSG kullanarak yenidoğan sağlık durumunu otomatik olarak tespit etmek için involüsyon ve artık blokları entegre eden HarmonyNet modeli geliştirilmiştir. Bu model, çeşitli öğrenme mekanizmalarını birleştirerek etkili bir çözüm sunmayı amaçlamaktadır. Geliştirilen modelin yapısı Şekil 4.7'de gösterilmektedir.

Tez çalışmasında geliştirilen HarmonyNet modeli toplam 36 katmandan oluşmaktadır. Veriye dayalı involüsyon çekirdekleri, daha derin ve anlamlı özelliklerin çıkarılmasına katkı sağlamaktadır. HarmonyNet modelinde $G=16$ ve $r=4$ hiper parametrelerine sahip involüsyon çekirdekleri entegre edilmiştir. Ayrıca, bilgiyi korumak ve gradyanla ilgili zorlukları gidermek için her iki involüsyon katmanından sonra artık bloklar eklenmiştir. Model içerisinde bulunan involüsyon çekirdeği boyutları 3×3 ve 7×7 olarak ayarlanmıştır.



Şekil 4.7. İnvölüsyon ve Artık Bloklar ile HarmonyNet Modeli

6. ve 14. involüsyon katmanlarının ardından, veri boyutu 2×2 boyutunda bir maksimum havuzlama ile yarıya indirilmiştir. Daha sonra, son involüsyon katmanından sonra, 2×2 ortalama havuzlama katmanı eklenmiştir. Daha sonra, ardışık üç tam bağlı katmanla daha fazla derinlik elde etmek için düzleştirme işlemi gerçekleştirilmiştir. İlk tam bağlı katman 128, ikincisi 64 ve üçüncüsü 32 nörondan oluşmaktadır. Son olarak, çıkış katmanında 2 nöron kullanılarak Softmax aktivasyon fonksiyonu ile sınıf tahmini gerçekleştirilmiştir.

Çizelge 4.15. Önerilen HarmonyNet modelinin ayrıntılı katman özeti. Son katman, temel bileşen sayısı 64 olarak ayarlanarak hasta ve sağlıklı yenidoğanlar arasında ayırım yapacak şekilde yapılandırılmıştır.

Katman (tipi)	Katman Boyutu	Çıkış Şekli	Parametre
input_1 (GirişKatmanı)	$10 \times 10 \times 64$	(10, 10, 64)	0
res_1 (ArtıkBlok)	3×3	(10, 10, 64)	1140
res_2 (ArtıkBlok)	3×3	(10, 10, 64)	1140
res_3 (ArtıkBlok)	3×3	(10, 10, 64)	1140
max_pooling2d_1 (MaksHavuzlama2B)	2×2	(5, 5, 64)	0
res_4 (ArtıkBlok)	3×3	(5, 5, 64)	1140
res_5 (ArtıkBlok)	3×3	(5, 5, 64)	1140
res_6 (ArtıkBlok)	3×3	(5, 5, 64)	1140
res_7 (ArtıkBlok)	3×3	(5, 5, 64)	1140
max_pooling2d_2 (MaksHavuzlama2B)	2×2	(2, 2, 64)	0
res_8 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_9 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_10 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_11 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_12 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_13 (ArtıkBlok)	7×7	(2, 2, 64)	4980
res_14 (ArtıkBlok)	3×3	(2, 2, 64)	1140
res_15 (ArtıkBlok)	3×3	(2, 2, 64)	1140
res_16 (ArtıkBlok)	3×3	(2, 2, 64)	1140
ave_pooling2d_1 (OrtHavuzlama2B)	2×2	(1, 1, 64)	0
flatten_1 (Düzleştirme)	64	(64)	0
dense_1 (TamBağlı)	128	(128)	8320
dense_2 (TamBağlı)	64	(64)	8256
dense_3 (TamBağlı)	32	(32)	2080
dense_4 (TamBağlı)	2	(2)	66
Toplam Parametre: 60.002			

Çizelge 4.15, katman türü, katman boyutu, çıktı haritası boyutu ve parametre sayısı açısından önerilen modelin bir özetini sunmaktadır. Parametre sayısı yenidoğan HSG veri setine, temel bileşen sayısına ve sınıf sayısına bağlıdır. Çizelge, 64 temel bileşen değeri ile hasta ve sağlıklı bireyleri birbirinden ayıran 2 sınıflı bir HSG veri seti kullanılarak oluşturulmuştur. Yenidoğan veri kümesi için HarmonyNet modelindeki toplam parametre sayısı 60.002'dir.

Tüm ağırlıklar ve bias değerleri başlangıçta rastgele seçilmiştir. Geriye yayılma algoritması olarak *Adam* optimizier ve kayıp fonksiyonu olarak ise Kategorik Çapraz

Entropi kullanılmıştır. Parça büyüklüğü 256 olarak ayarlanmış ve model 500 iterasyon için eğitilmiştir.

4.2.1.2. Deneysel Sonuçlar

Yenidoğan sağlık durumunu otomatik olarak tespit etmek ve önerilen HarmonyNet modelinin etkinliğini göstermek için çalışma kapsamında oluşturulan HSG veri seti kullanılmıştır. Bu çerçevede 2D-CNN (Makantasis ve diğ., 2015), SSRN (Zhong ve diğ., 2017), Contextual-CNN (Lee ve Kwon, 2017), 3D-CNN (Paoletti ve diğ., 2019), HybridSN (Roy ve diğ., 2019), HSIC (Ahmad ve diğ., 2020), CBW 2D-CNN (Zhao ve diğ., 2021), MCNN-CP (Zheng ve diğ., 2021), CMR-CNN (Yang ve diğ., 2022) ve Hybrid3D/2D (Fırat ve diğ., 2023) gibi gelişmiş yöntemlerle karşılaştırmalı analizler gerçekleştirilmiştir. Bu modeller 2B-ESA tabanlı, 3B-ESA tabanlı ve 2B-3B-ESA tabanlıdır.

4.2.1.2.1. HarmonyNet'in Eğitim Aşaması

HarmonyNet modelinin eğitimi sırasında, öğrenme oranı başlangıçta 10^{-3} olarak yapılandırılmıştır. Buna ek olarak, öğrenme hızı düşüşünü düzenlemek için, düşüş değeri 10^{-6} olarak ayarlanmış ve eğitim ilerledikçe öğrenme hızı kademeli olarak azaltılarak ince ayar kolaylaştırılmıştır. Diğer yöntemlerle adil bir karşılaştırma yapabilmek için, ön işleme adımlarının ardından temel bileşen sayısı 64'e sabitlenmiş, böylece $10 \times 10 \times 64$ boyutlarında yenidoğan HSG verileri elde edilmiştir.

Eğitim setinde üç farklı hastalık için veri mevcuttur: RDS, PTX ve AORT. Ayrıca bir kontrol grubu kullanılmıştır. Bu çalışmada, 110 hasta ve 110 sağlıklı veri yer almaktadır. Hastalıklardan 37'si RDS, 36'sı PTX ve geri kalan 37'si AORT hastalara aittir. Tüm bu hastalıklar gövde bölgesinde olduğu için kontrol grubu, yenidoğanların gövde bölgesinden alınan 110 veriyi içermektedir.

Tez çalışmasında veri kümesi rastgele bölünmüş ve verilerin %70'i eğitim amaçlı kullanılırken kalan %30'luk kısım test için ayrılmıştır. Model genellemesini geliştirmek ve güvenilir sonuçlar elde etmek için 10-çoklu-deneme stratejisi uygulanmıştır. Bu yaklaşım, HarmonyNet modelinin performansının daha kapsamlı bir şekilde değerlendirilmesine katkıda bulunan eğitim ve test sürecinin on kez gerçekleştirilmesini içermektedir.

4.2.1.2.2. Sonuçlar ve Analiz

Yenidoğan sağlık durumunun tespiti otomatikleştirmek ve önerilen yöntemin performansını değerlendirmek için bazı deneyler yapılmıştır. Tez çalışmasında geliştirilen HarmonyNet modeli, literatürde yer alan konvolüsyon tabanlı yöntemlerle karşılaştırılmıştır.


Çizelge 4.16, çeşitli yöntemlerin performans değerlendirme ölçütlerine göre sonuçlarını sunmaktadır. Önerilen involüsyon tabanlı HarmonyNet modeli, HSG veriler kullanılarak hasta ve sağlıklı yenidoğanların sınıflandırılmasında gelişmiş konvolüsyon tabanlı yöntemlere kıyasla üstün performans sergilemektedir. HarmonyNet hem hasta hem de sağlıklı yenidoğanları yüksek doğruluk ve hassasiyetle tanımlamada dikkate değer bir başarı göstererek en etkili yöntem olarak öne çıkmaktadır.

Çizelge 4.16. Önerilen HarmonyNet modeli ve literatürde yer alan güncel modellerin yenidoğan HSG veri kümesi üzerindeki sınıflandırma doğruluklarının karşılaştırılması.

Yöntemler	Kesinlik	Duyarlılık	F1-Skor	AUC	Kappa	MKK	GD
2D-CNN	86.73	85.69	86.21	96.33	72.73	72.76	86.06
SSRN	86.20	89.40	87.77	95.96	75.76	76.32	88.03
Contextual-CNN	85.60	90.10	87.79	97.43	78.79	78.82	88.79
3D-CNN	86.20	88.70	87.43	97.06	75.76	76.32	87.27
HybridSN	87.40	90.30	88.83	97.80	81.82	81.97	89.85
HSIC	88.60	87.20	87.89	97.80	75.76	76.32	87.58
CBW 2D-CNN	88.30	88.90	88.60	96.88	75.76	75.76	88.33
MCNN-CP	88.00	85.60	86.78	96.14	72.73	72.76	86.36
CMR-CNN	82.12	87.65	84.80	96.69	69.70	69.83	85.00
Hybrid3D/2D	86.80	89.40	88.08	97.43	75.76	75.76	88.03
HarmonyNet	90.91	90.91	90.91	98.99	84.62	83.21	90.91

HarmonyNet en iyi performansını birkaç temel ölçütte sergilemekte, özellikle kesinlik ve duyarlılık değerlerinin dengeli bir birleşimi olan F1-skorunda üstünlük sağlamaktadır. Ayrıca HarmonyNet, modelin ayırt edici yeteneğinin kritik bir göstergesi olan AUC değerinde en yüksek yeterliliği göstermektedir. Uyum oranını ölçmek için kriter olarak kullanılan Kappa ve MKK değerlerinde de HarmonyNet en iyi sonucu elde etmiştir. Tüm sınıflar arasında doğru sınıflandırma oranını temsil eden GD değerine dayalı değerlendirmeler, HarmonyNet'in en iyi performans gösteren yöntem olduğunu kesin olarak ortaya koymaktadır. HarmonyNet'in ardından ikinci en iyi sonuç, spektral-uzamsal özellikleri çıkarmak için hem 2B hem de 3B konvolüsyon katmanlarından yararlanan HybridSN tarafından elde edilmiştir.


DP ve YP oranları arasındaki ilişkiyi aydınlatmak için AUC değerleri incelendiğinde, önerilen HarmonyNet modelinin %98.99'luk bir AUC değerine ulaşarak diğerlerinden daha iyi performans gösterdiği görülmektedir (Şekil 4.8). Bu bulgular, HarmonyNet'in farklı sınıfları en doğru şekilde tahmin eden yöntem olarak öne çıktığını ve yenidoğan sağlık durumu sınıflandırmasındaki performansını vurgulamaktadır.



Şekil 4.8. Önerilen HarmonyNet modeli ve diğer yöntemler için ROC Eğrisi ve AUC değerleri.

Şekil 4.9'da, önerilen HarmonyNet modelinin ve diğer yöntemlerin çeşitli yüzdelik seviyelerde (eğitim veri sayısı) üç farklı değerlendirme ölçütünde (Kappa, MKK ve GD) karşılaştırmalı bir analizi sunulmaktadır. HarmonyNet tüm metriklerde istikrarlı ve yüksek performans sergilemekte ve her yüzdelik dilimde diğer yöntemlerden daha iyi sonuçlar vermektedir. Özellikle HarmonyNet, sınırlı miktarda eğitim verisi ile eğitildiğinde bile üstün performansını sürdürmüş ve farklı veri koşulları altında sağlamlığını ve verimliliğini kanıtlamıştır. Bu sonuçlar, HarmonyNet'in farklı senaryolarda güvenilir ve yüksek performans sunma konusundaki kapasitesini ve adaptasyon yeteneğini göstermektedir.

Çizelge 4.17, çeşitli HSG sınıflandırma yöntemlerinin performansını değerlendirmek için kullanılan diğer önemli ölçütleri sunmaktadır. Eğitim parametrelerinin sayısı, FLOP değerleri, çıkarım süresi, katman sayısı ve katman başına çıkarım süresi gibi temel ölçütleri vurgulayarak her bir yöntemin performansına ilişkin içgörüler sağlamaktadır. Bu kapsamlı bilgiler, her bir yöntemin güçlü ve zayıf yönlerini ayırt etmek için değerli bir kaynak görevi görerek karşılaştırmalı avantaj ve dezavantajlarının ayrıntılı bir şekilde anlaşılmasına yardımcı olmuştur.




Şekil 4.9. Yenidoğan HSG veri seti üzerinde farklı eğitim örneği sayılarıyla farklı yöntemlerin Kappa, MKK ve GD değerleri

Çizelge 4.17. Önerilen HarmonyNet ve diğer yöntemlerin parametre sayısı (M), hesaplama maliyetini ölçen FLOP (G), çıkarım süresi (dk), katman sayısı ve katman başına çıkarım süresi (s) gibi kritik performans ölçütleri açısından karşılaştırılması

Yöntemler	Parametre (M)	FLOP (G)	Çıkarım süresi (dk)	Katman sayısı	Katman başına çıkarım süresi (s)
2D-CNN	9.071	3.257	0.39	4	5.85
SSRN	2.691	10.098	3.64	12	18.20
Contextual-CNN	0.480	0.904	2.08	12	10.40
3D-CNN	1.340	22.823	0.51	4	7.65
HybridSN	1.078	14.616	0.31	7	2.66
HSIC	3.386	19.960	0.31	7	2.66
CBW 2D-CNN	1.431	1.968	0.31	5	3.72
MCNN-CP	0.924	20.934	0.32	7	2.74
CMR-CNN	0.807	55.213	1.63	15	6.52
Hybrid3D/2D	1.327	2751.676	5.79	19	18.28
HarmonyNet	0.060	0.583	1.57	36	2.62

Çizelge 4.17'ye ek olarak, aynı metrikleri daha anlaşılır bir şekilde ifade etmek için Şekil 4.10'da bar grafikler oluşturulmuştur. Bu analizlerden çıkan kritik noktalar şu şekildedir: SSRN, yüksek FLOP ve uzun çıkarım süresi ile hesaplama açısından yoğun

bir seçenek olarak öne çıkmaktadır. Bu da modelin hesaplama maliyetinin yüksek olduğunu ve işlemlerin uzun sürebileceğini göstermektedir. HybridSN ve HSIC düşük parametrelerle verimli ve hızlı bir şekilde performans göstermektedir. Bu modeller, daha az kaynak kullanımı ile yüksek verimlilik sağlar. MCNN-CP, düşük parametrelerle yüksek FLOP değerleri ve kısa çıkarım süresi ile karakterize edilir. Yoğun hesaplama gücüne sahip olmasına rağmen, hızlı çıkarım süresi ile verimli bir performans sergilemektedir. Hybrid3D/2D yüksek parametrelere ve uzun çıkarım süresine sahip FLOP değerlerine sahiptir, dolayısıyla kaynak ve işlem gücü yoğun bir seçenek olarak öne çıkmaktadır. Önerilen HarmonyNet, düşük parametre sayısı (0.060M) ve düşük FLOP değerleri (0.583G) ile karakterize edilir. Karmaşıklığını düşük tutarak, modeli hafif ve hesaplama açısından verimli hale getirmektedir. Böylece, daha az güçlü donanımlarda bile hızlı sonuçlar elde edilebileceğini göstermektedir.



Şekil 4.10. Eğitim parametre sayıları, GFLOP, çıkarım süresi ve katman başına çıkarım süreleri için bar grafikler. GFLOP grafiği, ayrıntıları yakalamak için logaritmik ölekte oluşturulmuştur. Önerilen HarmonyNet modeli grafikte kırmızı renkle vurgulanmıştır.

HarmonyNet'te bazı yöntemlere kıyasla gözlemlenen daha yüksek çıkarım süresi, NVIDIA'nın CUDA teknolojisi aracılığıyla konvolüsyon işlemlerini optimize etmesinin etkisine bağlanabilir. Bazı yöntemler, NVIDIA'nın CUDA teknolojisi ile iş birliği içinde GPU'lardan verimli bir şekilde yararlanarak, özellikle konvolüsyon işlemleri gibi hesaplama açısından yoğun görevlerde hızlı çıkarım süreleri elde etmelerini sağlar. HarmonyNet'in nispeten daha yüksek çıkarım süresi, bu tür optimize edilmiş çekirdeklerin kullanılmamasından veya belirli GPU mimarileriyle uyumluluk sorunlarından kaynaklanıyor olabilir. Gelecekte HarmonyNet'in çıkarım sürelerinde beklenen iyileştirmeler, NVIDIA'nın CUDA teknolojisini içeren geliştirmeleri içerebilir, böylece performansı optimize edilebilir ve GPU için optimize edilmiş metodolojilerde gözlemlenen verimlilikle uyumlu hale getirilebilir.

İnvolüsyon tasarımındaki çeşitli bileşenlerin, yani hiper parametrelerin (G , r ve $kernel_boyutu$) etkileri, önerilen HarmonyNet modelinin performansı üzerindeki sonuçları değerlendirmek için incelenmiştir. Bu inceleme, modelin performansının farklı parametre ayarlarıyla dinamik olarak nasıl değiştiğine dair içgörü sağlamıştır. Çizelge 4.18-4.20, yenidoğan HSG veri setinden yararlanarak parametre sayılarının, FLOP değerlerinin ve doğruluk değerlerinin ayrıntılı bir dökümünü sunmaktadır. Bu çizelgeler, modelin G değerleri, r değerleri ve $kernel_boyutu$ değerlerindeki değişikliklere karşı duyarlılığını göstermekte, bu hiper parametrelerin HarmonyNet'in performansını nasıl etkilediğine dair kapsamlı bir görünüm sunmakta ve belirli uygulamalar için en uygun yapılandırmayı belirlemeye yardımcı olmaktadır.

Çizelge 4.18'de gösterildiği gibi, G 'nin yükselmesi hem parametre sayısında hem de işlem yükünde artışa yol açmıştır. Genel olarak, daha yüksek G değerleri daha iyi doğrulukla ilişkilidir, ancak performans aşırı yüksek G değerleriyle sınırlı hale gelmiştir. Çizelge 4.19, r 'nin ayarlanmasının hem parametre sayısını hem de işlem yükünü etkilediğini ortaya koymaktadır. r için en uygun seçimler model doğruluğunun artmasıyla sonuçlanmış ve uygun bir r değeri seçmenin önemini vurgulamıştır. Çizelge 4.20'de, $kernel_boyutu$ değerinin artırılması hem parametre sayısında hem de FLOP değerlerinde artışla ilişkilendirilmiştir. Ancak bu artışa rağmen doğruluk oranları düşüş göstermiştir. Bu gözlem, daha küçük bir $kernel_boyutu$ 'nun daha etkili olduğunu, daha büyük bir $kernel_boyutu$ 'nun ise performanstan ödün verebileceğini göstermektedir. Bu bilgiler, HarmonyNet modelindeki G , r ve $kernel_boyutu$ hiper parametrelerinin kullanımının optimize edilmesi için önemli çıkarımlardır.

Çizelge 4.18. Farklı grup sayıları (G) için HarmonyNet performansı

G	Parametre (M)	FLOP (G)	Doğruluk (%)
1	0.025	0.395	77.27
2	0.028	0.408	81.67
4	0.032	0.433	84.76
8	0.042	0.483	86.36
16	0.060	0.583	90.91
32	0.097	0.783	86.36

Çizelge 4.19. Düşürme oranı (r) varyasyonuna dayalı HarmonyNet performansı

r	Parametre (M)	FLOP (G)	Doğruluk (%)
1	0.147	1.239	86.36
2	0.089	0.802	84.85
4	0.060	0.583	90.91
8	0.046	0.474	89.39
16	0.046	0.474	83.33
32	0.046	0.474	84.85

Çizelge 4.20. HarmonyNet modeli için farklı $kernel_boyutu$ değerlerine dayalı analiz

$kernel_boyutu$	Parametre (M)	FLOP (G)	Doğruluk (%)
3x3	0.037	0.481	89.39
5x5	0.062	1.224	89.39
7x7	0.098	2.338	87.88
9x9	0.148	3.824	87.88
11x11	0.209	5.681	80.30
HarmonyNet	0.060	0.583	90.91

Önerilen HarmonyNet modeli, özellikle 3×3 ve 7×7 çekirdek boyutlarının stratejik bir şekilde bir araya getirilmesi yoluyla düşük parametre ve hesaplama maliyetlerini korurken yüksek doğruluk elde ederek dikkate değer bir performans göstermiştir. Modelin genel etkinliği, G , r ve $kernel_boyutu$ dahil olmak üzere çeşitli hiper parametrelerin titizlikle seçilmesine bağlı görünmektedir. Çizelge 4.18-4.20, G : 16'ya, r : 4'e ve $kernel_boyutu$: 3,7'ye ayarlandığında en iyi sonuçların elde edildiğini göstermektedir. Bu özel hiperparametre ayarları HarmonyNet için en etkili kombinasyonlar olarak ortaya çıkmakta ve modelin performansını optimize etmede özenli hiperparametre ayarlamasının kritik rolünün altını çizmektedir.

Çizelge 4.21, temel bileşen sayısının doğruluk üzerindeki etkisini değerlendirmektedir. Genel olarak, temel bileşen sayısı arttıkça modelin doğruluğu da

artma eğilimindedir. Özellikle 64 temel bileşenli model, diğer konfigürasyonlara kıyasla %90.91 gibi yüksek bir doğruluk oranıyla öne çıkmaktadır. Bununla birlikte, 32 ila 96 temel bileşen arasında doğruluk artışları sınırlı kalmakta ve bir denge noktasına ulaşılmaktadır. Bu gözlem, temel bileşen sayısını artırarak modelin karmaşıklığını artırmanın, belirli bir noktadan sonra doğruluk üzerinde iyileştirme sağlamadığını göstermektedir. Bulgular, optimum performans için model karmaşıklığı ve doğruluk arasındaki dengenin optimize edilmesinin önemini vurgulamaktadır.

Analizlere göre, temel bileşen sayısının belirli bir seviyeden sonra doğruluğu artırma üzerinde sınırlı bir etkiye sahip olduğu görülmektedir. Doğruluk artışı ve model karmaşıklığı arasında bir denge kurmak için en uygun temel bileşen sayısını belirlemek çok önemli hale gelmektedir. Bu bağlamda, 64 temel bileşenin en yüksek doğruluğu sağladığı ve daha fazla eklemenin iyileşmeyi sınırladığı gözlemi, optimum model performansı için uygun sayıda temel bileşen seçmenin önemini altını çizmektedir. Bu içgörü, doğruluk ve karmaşıklık arasında en iyi dengeyi elde etmek için modele ince ayar yapmak açısından değerlidir.

Çizelge 4.21. Temel bileşen sayısının doğruluk üzerindeki etkisi.

Temel Bileşen Sayısı	16	32	48	64	80	96
Doğruluk (%)	83.18	86.06	86.82	90.91	89.85	89.55

Çizelge 4.22, önerilen HarmonyNet modeli için yenidoğan HSG verileri üzerinde gerçekleştirilen ablasyon çalışmasını göstermektedir. Çalışma, çeşitli ağ yapılarındaki performansını değerlendirerek modelin sınıflandırma kabiliyetini anlamayı amaçlamaktadır. Bu yapılar, involüsyon katmanlarının varlığı, artık blokların dahil edilmesi ve maksimum havuzlama ve ortalama havuzlama kullanımı dahil olmak üzere farklı özellik kombinasyonlarından türetilmiştir. Elde edilen sonuçlar, ağ yapısındaki değişikliklerin sınıflandırma performansı üzerindeki etkisini vurgulamaktadır. Bu kapsamlı analiz, her bir bileşenin önemine ve yenidoğan sağlık durumu sınıflandırması bağlamında HarmonyNet modelinin genel performansına olan katkılarına ışık tutmaktadır.

Sadece involüsyon katmanlarının etkinleştirildiği ve diğer özelliklerin devre dışı bırakıldığı başlangıç ağ yapısında, elde edilen AUC (%90.55), Kappa (%66.67), MKK (%70.71) ve GD (%83.33) değerleri modelin başlangıç performansını göstermektedir. Özellikle, artık blokların eklenmesiyle tüm ölçütlerde önemli bir iyileşme gözlenmiştir.


AUC değeri %93.94'e yükselirken, Kappa (%75.76), MKK (%76.32) ve GD (%87.88) değerlerinde de kayda değer artışlar gözlenmiştir. Bu sonuçlar, artık blokların dahil edilmesiyle elde edilen sınıflandırma performansındaki önemli artışın altını çizmekte ve HarmonyNet modelinin genel etkinliği üzerindeki olumlu etkilerini vurgulamaktadır.

Ağ yapısına maksimum havuzlamanın eklenmesi, sınıflandırma performansında daha fazla iyileşme sağlamıştır. Bu senaryoda elde edilen AUC (%96.05), Kappa (%78.79), MKK (%78.82) ve GD (%89.39) değerleri dikkat çekicidir. Ortalama Havuzlama katmanı ile birlikte ise AUC değeri %98.99'a yükselmiş, buna Kappa (%84.62), MKK (%83.21) ve GD (%90.91) değerlerine yansıyan yüksek doğruluk ve güvenilirlik seviyeleri eşlik etmiştir. Bu sonuçlar, yenidoğan HSG verileri üzerinde farklı ağ yapılarını araştıran ablasyon çalışmasının, modelin performansını önemli ölçüde artırdığını ve farklı bileşenlerin model üzerindeki etkilerini net bir şekilde ortaya koyduğunu göstermektedir. Önerilen HarmonyNet modelinin, çeşitli özellikler birlikte kullanıldığında en yüksek sınıflandırma performansına ulaştığını ve yenidoğan sağlık durumu sınıflandırmasında esneklik ve güvenilirlik sunduğunu vurgulamaktadır.

Çizelge 4.22. Farklı ağ yapılarının ablasyon çalışması. Yenidoğan HSG verileri üzerinde AUC, Kappa, MKK ve GD değerleri (%).

İnvölüsyon Katmanları	Artık Bloklar	Maksimum Havuzlama	Ortalama Havuzlama	AUC	Kappa	MKK	GD
✓	✗	✗	✗	90.55	66.67	70.71	83.33
✓	✓	✗	✗	93.94	75.76	76.32	87.88
✓	✓	✓	✗	96.05	78.79	78.82	89.39
✓	✓	✓	✓	98.99	84.62	83.21	90.91

Şekil 4.11'de ablasyon analizi sırasında çeşitli kombinasyonlar için elde edilen eğitim performansı eğrileri gösterilmektedir. Yalnızca involüsyonu içeren temel modelde gözlemlenen belirgin dalgalanmalar, modelin eğitim zorluklarına karşı hassas olduğunu göstermektedir. Bununla birlikte, temel modele artık blokların eklenmesi performansta belirgin bir iyileşme sergilemektedir. Bu gelişme, artık blokların önerilen HarmonyNet modelinin daha karmaşık ilişkileri öğrenmesini sağlamadaki rolünün altını çizmekte ve yenidoğan sağlık durumu sınıflandırmasının karmaşıklıklarını ele almada genel sağlamlığına ve etkinliğine katkıda bulunmaktadır.



Şekil 4.11. Ablasyon çalışmasında kullanılan farklı ağ yapılarının eğitim performans eğrileri.

Sonuç aşamasında, HarmonyNet modeli, ek maksimum havuzlama ve ortalama havuzlama katmanlarının dahil edilmesiyle hızlandırılmış öğrenme göstermektedir. Eklenen bu katmanlar daha verimli öğrenmeye katkıda bulunmuş ve eğitim performansındaki dalgalanmaları azaltmaya yardımcı olmuştur. Bu gözlemler, HarmonyNet modelinin yenidoğanların sağlık durumunu tespit ederken, özellikle önerilen özellik kombinasyonları ile desteklendiğinde daha istikrarlı ve etkili bir öğrenme süreci sergilediğini göstermektedir. Artan kararlılık ve performans, modelin yenidoğan sağlık durumu sınıflandırmasında çeşitli özellikleri kullanarak daha yüksek doğruluk ve güvenilirlik elde etme konusundaki başarısını göstermektedir.

4.2.1.2.3. Tartışma

Bu çalışma, yenidoğan sağlık durumunun (hasta ve sağlıklı) otomatik olarak tespit edilmesi için önerilen HarmonyNet modelinin etkinliğini araştırmaktadır. Bulgular, HarmonyNet'in bu konudaki üstün performansını vurgulamakta ve HSG aracılığıyla yenidoğan sağlık durumunun otomatik olarak tespit edilmesinde yüksek doğruluk sergilemektedir. HarmonyNet bu yüksek performans seviyesine involüsyon, artık bloklar, maksimum havuzlama ve ortalama havuzlama gibi özelliklerin bir kombinasyonunu kullanarak ulaşmaktadır. Özellikle, doğruluğu ve güvenilirliği,

literatürde yer alan konvolüsyon tabanlı yöntemlerin doğruluğunu ve güvenilirliğini aşmaktadır.

Özellikle HarmonyNet hem hasta hem de sağlıklı yenidoğanları yüksek doğrulukla tanımlamada üstündür ve diğer gelişmiş yöntemlere kıyasla daha yüksek doğruluk elde etmiştir. Bu durum, modelin HSG verilerini etkili bir şekilde işleyerek yenidoğan sağlık durumunun daha doğru bir şekilde tespit edilmesini sağladığını göstermektedir. Ayrıca HarmonyNet, düşük parametre sayısı ve hesaplama maliyeti özellikleriyle öne çıkmakta, hesaplama verimliliği ve hızlı performans sergilemektedir. HarmonyNet'te diğer yöntemlere kıyasla gözlemlenen daha yüksek çıkarım süresi, NVIDIA'nın CUDA teknolojisinin kullanımına bağlanmaktadır. Gelecekteki geliştirmelerin HarmonyNet'in çıkarım sürelerini ele alıp iyileştirmesi ve genel performansını daha da artırması beklenmektedir.

Bu çalışmada HarmonyNet modeli, özellikle sınırlı eğitim verisi koşulları altında diğer yöntemlere kıyasla üstün başarı göstermiştir. Bu durum, modelin kısıtlı verilerle karşılaştığında bile güvenilir sonuçlar elde etme kapasitesinin altını çizmekte ve verimli öğrenme ve özellik çıkarma yeteneklerini vurgulamaktadır. HarmonyNet'in gelişmiş genelleme yeteneklerine sahip olduğu gözlemi, onu diğer yöntemlerden belirgin şekilde ayırarak farklı senaryolardaki uyarlanabilirliğini ve güçlü performansını vurgulamaktadır.

Ayrıca, HarmonyNet'in G , r ve $kernel_boyutu$ dahil olmak üzere hiper parametrelerinin titizlikle seçilmesi, modelin genel etkinliğini şekillendirmede çok önemli bir rol oynamaktadır. Yapılan analiz, modelin performansını artırmada optimum hiperparametre ayarlarının kritik önemini vurgulamaktadır. Bu, mümkün olan en iyi sonuçları elde etmek için bu parametrelerde ince ayar yapmanın önemini vurgulamakta ve HarmonyNet'in performansının bu hiper parametrelerde yapılan seçimlere olan duyarlılığının altını çizmektedir.

Yapılan ablasyon çalışması, HarmonyNet modelinin ağ yapısındaki değişikliklerin sınıflandırma performansı üzerinde önemli etkileri olduğunu ortaya koymuştur. Artık bloklar, maksimum havuzlama ve ortalama havuzlama dahil olmak üzere ek özelliklerin dahil edilmesi, modelin sınıflandırma yeteneğini önemli ölçüde artırmıştır. Bu sonuçlar, HarmonyNet'in çeşitli özelliklerin entegrasyonu yoluyla en yüksek sınıflandırma performansına ulaşan bir model olarak öne çıktığını teyit

etmektedir. Çalışma, yenidoğan sağlık durumlarının sınıflandırılmasında modelin etkinliğini optimize etmede bu yapısal unsurların öneminin altını çizmektedir.

HarmonyNet modelinin bu başarıları, yenidoğanların erken teşhisi ve tedavisi için önemli bir potansiyel sunmaktadır. Yüksek doğruluk, az sayıda parametre ve düşük hesaplama maliyeti kombinasyonu, modelin klinik uygulamalardaki potansiyel kullanılabilirliğini artırmaktadır. Bu çalışma, HSG teknolojisinin yenidoğan sağlığı alanında değerli bir araç olabileceğini ve HarmonyNet modelinin bu alanda kayda değer bir katkı sağladığını göstermektedir. Modelin yetenekleri, gelişmiş tanısal hassasiyet ve verimlilik yoluyla yenidoğanlar için sağlık sonuçlarının iyileştirilmesine katkıda bulunma konusunda umut vaat etmektedir.

4.2.1.3. Araştırma Sonuçları

Bu çalışma, yenidoğan sağlık durumunu değerlendirmek için involüsyona dayalı HarmonyNet modelinin kapsamlı bir analizini gerçekleştirmiş ve bu alanda önemli bir ilerlemeye işaret etmiştir. 110 hasta ve 110 sağlıklı vakayı kapsayan, yenidoğanlardan elde edilmiş HSG veri seti içerisindeki veriler kullanılmıştır. Bu veriler, HarmonyNet modelinin genel performansının güçlendirilmesinde çok önemli bir rol oynamış ve yüksek doğruluk, güvenilirlik ve düşük hesaplama maliyeti dahil olmak üzere modelin faydalarını açıklamıştır. Ablasyon çalışması, HarmonyNet'in başarısının ağ yapısı içindeki çeşitli özelliklerin uyumlu bir şekilde entegrasyonundan kaynaklandığını doğrulayan değerli bilgiler sağlamıştır. Bu, modelin çok yönlülüğünün ve yenidoğan sağlığı alanında geniş çapta uygulanabilirliğinin altını çizmektedir. Bulgular toplu olarak HarmonyNet'i yenidoğan sağlığını değerlendirmek ve geliştirmek için güçlü ve etkili bir araç olarak konumlandırmış ve tıbbi teşhis alanında daha geniş uygulama potansiyeli sunmuştur.

Modelin yüksek doğruluk ve güvenilirlik ile düşük hesaplama maliyeti hedeflerine ulaşmak için, yalnızca modelin ayırt etme kapasitesini ve ifade etme gücünü artırmak değil, aynı zamanda öz-dikkat mekanizmaları yoluyla hesaplama maliyetlerini azaltmak için tasarlanan bir iç içe geçme yaklaşımı benimsenmiştir. Bu stratejik uygulama, HarmonyNet'in olağanüstü performansını desteklemekle kalmamış, aynı zamanda onu yenidoğan sağlığı alanındaki pratik uygulamalara daha uygun hale getirmiştir. Bu bulgular, HSG teknolojisinin yenidoğan sağlığında değerli bir araç olarak potansiyelini vurgulamış ve HarmonyNet'in bu alanda dikkate değer bir yenilik

olarak konumunu ortaya koymuştur. Modelin performans ile hesaplama verimliliğini dengeleme konusundaki yetkinliği, yenidoğan sağlık hizmetleri uygulamalarının geliştirilmesinde önemli katkılar sağlayabileceğini göstermektedir.


4.2.2. Hiperspektral Görüntüleme ile Yenidoğan Hastalığı Teşhisi için MC-I²Net: Çok Ölçekli Bağlamsal Yapı ve Başlangıç Modülü ile İnvolüsyon Tabanlı Derin Öğrenme Yaklaşımı

HSG verileri, farklı hastalıklar için farklı spektral özellikler gösterebilir. Bu doğrultuda, yenidoğan hastalıklarını tespit etmek için başlangıç modülü ve çok ölçekli bağlamsal yapıyı içeren MC-I²Net adlı involüsyon tabanlı bir derin öğrenme modeli geliştirilmiştir. Tez kapsamında yapılan bu çalışma, HSG verileri için çoklu sınıflandırma yaklaşımı sağlamak üzere geliştirilen MC-I²Net modeline odaklanmaktadır. Önerilen modele ait detaylar ve bu model kullanılarak elde edilen sonuçlar ve tartışmalar aşağıda detaylandırılmıştır. Bu çalışmaya ait grafiksel özet EK-3'te verilmiştir.

4.2.2.1. MC-I²Net

Geliştirilen MC-I²Net modelindeki farklı yapıların (başlangıç modülü ve çok ölçekli bağlamsal yapı) entegrasyonu, modelin daha geniş bir özellik yelpazesi üzerinde etkili bir şekilde çalışmasını sağlamaktadır. Bu yapılar sayesinde model daha karmaşık ve çeşitli görevleri iyi bir şekilde yerine getirebilir, özellikle karmaşık yapılara sahip hacimsel HSG verileri üzerinde başarılı sonuçlar elde edebilir. Geliştirilen MC-I²Net modelinin yapısı Şekil 4.12'de gösterilmektedir. Bu model, literatürde geliştirilen ilk tam involüsyonel ağ modelini temsil etmektedir. Bu özellik, modele daha geniş bağlamsal bölgeleri kapsama yeteneği ve daha az parametre kullanma avantajı sağlayarak HSG veri analizi alanında etkili bir çözüm sunmaktadır.

Önerilen MC-I²Net modeli bir başlangıç modülünden ve hemen ardından eklenen çok ölçekli bir bağlamsal yapıdan oluşmaktadır. $I \in \mathbb{R}^{H \times W \times \lambda}$ olarak gösterilen HSG verileri, H yüksekliği, W genişliği ve λ spektral bantları temsil eden giriş verilerinden oluşmaktadır. Her piksel, farklı sınıfları temsil eden dalga boyları boyunca veri tutar. Anlamlılığını artırmak için I 'ya ön işleme adımları ve TBA uygulanmıştır. Ön işleme ve TBA'nın ardından, H 'nin yüksekliği, W 'nin genişliği ve B 'nin spektral bantları gösterdiği yeni $X \in \mathbb{R}^{H \times W \times B}$ verisi elde edilir.



Şekil 4.12. Başlangıç modülü ve çok ölçekli bağlamsal yapı içeren involüsyon tabanlı geliştirilmiş MC-I²Net modelinin yapısı.

Çizelge 4.23. Önerilen MC-I²Net modelinin detaylı katman özeti. Temel Bileşen sayısı 96 olarak ayarlanmıştır ve son katman, beş hastalık ve bir kontrol grubu göz önünde bulundurularak yenidoğanlarda hastalık tespiti yapmak üzere yapılandırılmıştır.

Katman (Tipi)	Boyut	Aktivasyon Fonksiyonu	Çıkış Şekli	Parametre	İle Bağlantılı	Diğer Parametreler
input_1 (GirişKatmanı)	H×W×B		(10, 10, 96)	0	-	
Başlangıç Modülü	inv_1 (İnvölüsyon)	1×1	(5, 5, 96)	250	input_1	Adım = 2
	inv_2 (İnvölüsyon)	1×1	(10, 10, 96)	250	input_1	
	inv_3 (İnvölüsyon)	3×3	(5, 5, 96)	634	inv_2	Adım = 2
	inv_4 (İnvölüsyon)	1×1	(10, 10, 96)	250	input_1	
	inv_5 (İnvölüsyon)	5×5	(5, 5, 96)	1402	inv_4	Adım = 2
	avg_pool_2d_1 (Orthavuz2B)	2×2	(5, 5, 96)	0	input_1	Aynı dolgu
	inv_6 (İnvölüsyon)	1×1	(5, 5, 96)	250	avg_pool_2d_1	
Çok Ölçekli Bağlamsal	concat_1 (Birleştirme)	-	ReLU (5, 5, 384)	0	inv_1, inv_3, inv_5, inv_6	
	inv_7 (İnvölüsyon)	3×3	(5, 5, 384)	1210	concat_1	
	max_pool_2d_1 (MaksHavuz2B)	2×2	(2, 2, 384)	0	inv_7	
	inv_8 (İnvölüsyon)	5×5	(5, 5, 384)	1978	concat_1	
	max_pool_2d_2 (MaksHavuz2B)	2×2	(2, 2, 384)	0	inv_8	
	inv_9 (İnvölüsyon)	7×7	(5, 5, 384)	3130	concat_1	
	max_pool_2d_3 (MaksHavuz2B)	2×2	(2, 2, 384)	0	inv_9	
Düzleştirme	concat_2 (Birleştirme)	-	ReLU (2, 2, 1152)	0	max_pool_2d_1, max_pool_2d_2, max_pool_2d_3	
	flatten_1 (Düzleştirme)	-	(4608)	0	concat_2	
	dense_1 (TamBağlı)	C	Softmax (6)	27654	flatten_1	
Toplam Parametre: 37.008						

Üretilen $X \in \mathbb{R}^{H \times W \times B}$ verileri Tam Başlangıç modülüne beslenir. Başlangıç modülü, bilgi çıkarma kapasitesini artırmak için aynı anda farklı involüsyon boyutlarına sahip filtreler kullanır. Bilginin aynı ölçekte paralel olarak işlenmesi, modelin hem düşük hem de yüksek seviyeli özellikleri öğrenmesine yardımcı olur. Birleştirme işleminin ardından, elde edilen özellik haritaları çok ölçekli bağlamsal yapıya aktarılır. Çok ölçekli bağlamsal yapı, farklı ölçeklerdeki bağlamların anlaşılmasına yardımcı olur. Çok ölçekli yaklaşım, farklı ölçeklerde özellik haritaları oluşturmayı ve birleştirmeyi kapsar ve modelin yenidoğan HSG verilerindeki küçük ayrıntılardan büyük bağlamlara kadar geniş bir bilgi yelpazesini kavramasını sağlar. Bu noktada, 3×3, 5×5 ve 7×7

olmak üzere farklı ölçeklerde involüsyon katmanları kullanılmakta ve her birinin ardından 2×2 maksimum havuzlama kullanılarak veri boyutu azaltılmaktadır. Son aşamada derin entegrasyon, ağın farklı ölçeklerdeki özellikleri tanımasını ve anlamasını sağlar. Tüm involüsyon katmanları için sırasıyla 16 ve 4 olarak ayarlanan G ve r hiper parametreleri kullanılmıştır. MC-I²Net modeli tamamen involüsyonel bir ağdır. Çok ölçekli bağlamsal yapının ardından, düzleştirilmiş veriler softmax aktivasyon fonksiyonu kullanılarak doğrudan sınıflandırılır. Burada, C sınıf sayısını göstermektedir.

Çizelge 4.23, önerilen modelin katman türü, boyutu, aktivasyon fonksiyonu, çıktı haritası boyutu, parametre sayısı, bağlanabilirlik ve diğer parametreler açısından kapsamlı bir özetini sunmaktadır. Parametre sayısı, oluşturulan yenidoğan HSG veri setine, temel bileşen sayısına ve sınıf sayısına bağlıdır. Çizelge, beş hastalık grubunu ve 96 temel bileşene sahip bir kontrol grubunu ayıran altı sınıflı HSG veri kümesi kullanılarak oluşturulmuştur. Yenidoğan veri kümesi için MC-I²Net modelindeki toplam parametre sayısı 37.008'dir.

Tüm ağırlıklar ve bias değerleri başlangıçta rastgele seçilmiştir. Geriye yayılma algoritması olarak *Adam* optimizier tercih edilmiş ve kayıp fonksiyonu olarak sınıfları temsil etmek için tamsayı indeksleri kullanan Seyrek Kategorik Çapraz Entropi seçilmiştir. Parça büyüklüğü 256 olarak ayarlanmış ve eğitim verileri 256 boyutunda bir karıştırma arabelleği ile karıştırılmıştır. Model 100 iterasyon için eğitilmiştir.

4.2.2.2. Deneysel Sonuçlar ve Tartışma

Çalışmada yenidoğan hastalıklarını tespit etmek ve önerilen MC-I²Net modelinin etkinliğini göstermek için her sınıftan 40 tane olmak üzere 240 veriden oluşan 6 sınıflı (RDS, PTX, ICH, AORT, NEC ve Kontrol Grubu) bir HSG veri kümesi kullanılmıştır. Modelin etkinliğini değerlendirmek için, iki farklı konvolüsyon tabanlı derin öğrenme modelini karşılaştırmak üzere model içindeki konvolüsyon katmanları 2B konvolüsyon ve 3B konvolüsyon katmanları ile değiştirilmiştir. Bu modeller MC-I2dCNet ve MC-I3dCNet modelleri olarak adlandırılmıştır.

4.2.2.2.1. Eğitim Detayları

Önerilen MC-I²Net modelinin eğitimi sırasında, *Adam* optimizier içindeki öğrenme oranı başlangıçta 0.001 olarak yapılandırılmıştır. Diğer yöntemlerle adil bir

karşılaştırma yapılabilmesi için, ön işleme adımlarından sonra temel bileşen sayısı 96 olarak sabitlenmiş ve böylece $10 \times 10 \times 96$ boyutlarında yenidoğan HSG verileri oluşturulmuştur.

Veri kümesi rastgele bir bölme işleminden geçirilmiş; verilerin %80'i eğitim amacıyla kullanılırken kalan %20'si test için ayrılmıştır. Modelin genelleme kabiliyetini artırmak ve güvenilir sonuçlar elde etmek için 5-katlamalı çapraz-doğrulama ve 10-çoklu-deneme stratejisi benimsenmiştir. Bu yaklaşım, MC-I²Net modelinin performansının daha kapsamlı bir şekilde değerlendirilmesine katkıda bulunmak amacıyla eğitim ve test verilerinin beş bölüme ayrılmasını ve sürecin her bölüm için on kez tekrarlanmasını içermektedir.


4.2.2.2.2. Sınıflandırma Performansı

Bu bölümde, yenidoğan hastalıklarının tespiti amacıyla geliştirilen MC-I²Net modelinin sınıflandırma performansı değerlendirilmiştir. Çalışmada kullanılan 6 sınıflı HSG veri kümesinden elde edilen 240 veri, modelin etkinliğini göstermek için temel oluşturmaktadır. Modelin performansını değerlendirmek üzere involüsyon katmanları içeren MC-I²Net modeli, bu katmanların sırasıyla 2B konvolüsyon tabanlı ve 3B konvolüsyon tabanlı yapılara dönüştürülmesiyle oluşturulan MC-I2dCNet ve MC-I3dCNet olmak üzere iki farklı derin öğrenme modeliyle karşılaştırılmıştır.

Çizelge 4.24'te involüsyon, 2B konvolüsyon tabanlı ve 3B konvolüsyon tabanlı yöntemleri değerlendirmek için kullanılan indekslerin sonuçları sunulmaktadır. Burada, MC-I2dCNet genel olarak iyi performans sergilemektedir; ancak, diğer iki yöntemle kıyasla bazı ölçütlerde biraz daha düşük değerlere sahiptir. Özellikle AUC, Kappa ve GD değerleri biraz daha düşüktür, bu da sınıflandırma modeli için dengeli performans elde etmede potansiyel zorluklara işaret etmektedir. MC-I3dCNet, MC-I2dCNet'e kıyasla daha yüksek performans göstermektedir. Özellikle, Kappa ve GD değerleri daha yüksektir, bu da modelin dengeli sınıflandırma için gelişmiş yeteneğini gösterir. MC-I²Net hem GD hem de diğer endekslerde en yüksek performansı sergilemektedir. Yüksek AUC, MKK, OD, Kappa ve GD değerleri, geliştirilen involüsyon tabanlı modelin yenidoğan HSG hastalık tespit görevlerinde etkili olduğunu ortaya koymaktadır.

Çizelge 4.24. Yenidoğan hastalıklarının tespiti için geliştirilen involüsyonel ve konvolüsyonel tabanlı yöntemlerin performanslarının karşılaştırılması.

Yöntemler	Performans Değerlendirme Ölçütleri (%)				
	AUC	MKK	OD	Kappa	GD
MC-I2dCNet	99.24	90.31	91.76	89.92	91.63
MC-I3dCNet	99.64	91.19	92.60	90.82	92.38
MC-I²Net	99.85	92.11	93.16	91.82	93.21




Şekil 4.13. AORT, ICH, NEC, PTX, RDS ve kontrol grubu (Healthy) HSG verileri üzerinde involüsyon tabanlı MC-I²Net ve konvolüsyon tabanlı modellerin ayırt edici performansını gösteren karmaşıklık matrisleri.

Şekil 4.13, beş farklı hastalığı ve bir kontrol grubunu ayırt etmedeki performanslarını karşılaştırmayı amaçlayan üç farklı modelin karmaşıklık matrislerini göstermektedir. Bu matrisler, 5-katlamalı çapraz-doğrulama ve 10-çoklu-deneme stratejisinin ardından toplam test verisi sayısına göre oluşturulmuştur. İnvolüsyon tabanlı MC-I²Net modeli diğer iki modelle karşılaştırıldığında genel olarak en yüksek performansı sergilemiştir. MC-I²Net modeli, MC-I3dCNet'e kıyasla AORT ve ICH hastalarını etkili bir şekilde ayırt ederken, MC-I2dCNet modeli en düşük performansa sahip model olarak belirlenmiştir. Her üç model de PTX, RDS ve sağlıklı sınıflarını oldukça başarılı bir şekilde ayırt edebilmiş; ancak AORT, ICH ve NEC sınıflarını ayırt etmede daha az başarılı olmuşlardır. Kendi aralarında değerlendirildiğinde, involüsyon

tabanlı MC-I²Net modeli, hasta verilerini tespit etmede %93.21'lik GD oranıyla konvolüsyon tabanlı MC-I2dCNet (%91.63) ve MC-I3dCNet (%92.38) modellerinden daha iyi performans gösterirken, sağlıklı sınıfını tespit etmede de benzer bir başarı elde etmiştir.

Şekil 4.14, geliştirilen involüsyon tabanlı MC-I²Net ve diğer modellerin performansını karşılaştırmak için ROC eğrilerini ve sınıf bazında AUC değerlerini sunmaktadır. Çok sınıflı AUC değeri model performansının genel bir ölçüsü olarak hizmet etse de sınıf düzeyindeki performansı anlamak için mikro-ortalama AUC değeri de hesaplanmıştır. MC-I²Net modeli diğer iki modele kıyasla belirgin bir şekilde daha yüksek performans göstermektedir. Mikro-ortalama AUC değeri %99.85 ile oldukça yüksekken, sınıf 0 hariç tüm sınıflar için AUC değerleri en üst seviyededir (%100.00). MC-I3dCNet modeli genel olarak iyi performans sergilerken, MC-I2dCNet'te sınıf 0 ve sınıf 1 için düşük AUC değerleri göz önüne alındığında, bu modelin performansının daha az güvenilir olduğu görülmektedir.



Şekil 4.14. Çoklu sınıf senaryoları için genişletilmiş ROC eğrilerini içeren grafikler, üç farklı modelin göreceli etkinliğini göstermektedir. Bu grafikler ROC eğrisi altındaki mikro-ortalama alanı (AUC) ve sınıfların şu şekilde tanımlandığı her sınıf için AUC değerlerini içerir:

0 → AORT, 1 → ICH, 2 → NEC, 3 → PTX, 4 → RDS ve 5 → Healthy.

Ayrıca, yanlış pozitif oran ile gerçek pozitif oran arasındaki ilişkiyi gösteren ROC eğrilerini de kapsamaktadır.

Çizelge 4.25, model performansını etkileyen üç temel endeksi göstermektedir. Çizelgedeki karşılaştırmaya göre, MC-I²Net diğer yöntemlere kıyasla önemli ölçüde daha az eğitilebilir parametre (37.008) ve FLOP değeri (0.601G) ile ölçülen daha düşük bir hesaplama maliyeti sergilemektedir. MC-I²Net, 3B konvolüsyon işlemlerinin hesaplama açısından yoğun olduğu MC-I3dCNet modelinden daha iyi performans göstermesine rağmen, MC-I2dCNet'in çıkarım süresi daha iyidir. MC-I2dCNet (12,39s) ile karşılaştırıldığında MC-I²Net'in (22,63s) daha yüksek çıkarım süresi, yüksek eğitim parametreleri ve FLOP değerlerine sahip MC-I3dCNet (41,86s) ile çıkarım süresinde çok fazla fark olmamasına rağmen, NVIDIA'nın CUDA teknolojisi aracılığıyla konvolüsyon işlemlerinin optimizasyonuna bağlanabilir. Bazı yöntemler, özellikle NVIDIA'nın CUDA teknolojisiyle birleştiğinde, GPU'lardan verimli bir şekilde yararlanarak konvolüsyonel işlemler gibi hesaplama açısından yoğun görevlerde hızlı çıkarım süreleri sağlar. MC-I²Net'in nispeten daha yüksek çıkarım süresi, bu tür optimize edilmiş çekirdeklerin kullanılmamasından veya belirli GPU mimarileriyle uyumluluk sorunlarından kaynaklanıyor olabilir. MC-I²Net'in çıkarım sürelerinde gelecekte yapılacak iyileştirmeler, NVIDIA'nın CUDA teknolojisini içeren ve böylece performansı optimize eden ve GPU için optimize edilmiş metodolojilerle uyumluluğu sağlayan geliştirmeleri içerebilir. Bu aşamada, geliştirilen MC-I²Net modeli hız ve doğruluk arasında en iyi dengeyi kurmaktadır.

Çizelge 4.25. Önerilen MC-I²Net ile diğer yöntemlerin eğitim parametrelerinin sayısı, FLOP cinsinden hesaplama maliyeti ve çıkarım süresi gibi kritik performans ölçütleri açısından karşılaştırılması.

Yöntemler	Eğitim Parametre Sayısı	FLOP (G)	Çıkarım Süresi (sn)
MC- I2dCNet	101.142	1.4	12,39
MC-I3dCNet	389.718	338.983	41,86
MC-I ² Net	37.008	0.601	22,63

Çizelge 4.26, üç farklı modelin (MC-I2dCNet, MC-I3dCNet ve MC-I²Net) performansını farklı eğitim/test oranlarını dikkate alarak OD (%), Kappa (%) ve GD (%) indeksleri açısından değerlendirmektedir. Genel eğilim, daha fazla eğitim verisi kullanıldıkça performansta bir iyileşme olduğunu göstermektedir. MC-I²Net modeli tüm eğitim/test oranlarında tutarlı bir şekilde yüksek performans göstererek yüksek OD, Kappa ve GD indeksleri sergilemektedir. Özellikle daha yüksek eğitim/test oranlarında MC-I²Net, MC-I3dCNet ve MC-I2dCNet'e göre önemli bir üstünlük sergilemekte ve son ikisi arasındaki performans farkı nispeten daha az olmaktadır. Modelin başarısı,

veriler analiz edilerek oluşturulan ve parametrelerin dikkatlice optimize edilmesiyle elde edilen çekirdekler sayesinde ortaya çıkmaktadır. Bu optimize edilmiş çekirdekler, MC-I²Net modelinin konvolüsyon tabanlı modellere kıyasla daha az eğitim verisiyle bile yüksek doğruluk elde etmesine yol açmıştır. Dolayısıyla, involüsyon tabanlı MC-I²Net modeli, konvolüsyon tabanlı modellere kıyasla daha az karmaşık yapısı ve daha düşük hesaplama gereksinimleri nedeniyle daha pratik ve kullanılabilir olarak ortaya çıkmaktadır. Bu özellikler, MC-I²Net'i yüksek performans, pratiklik ve kullanılabilirlik arasında ideal bir denge kurarak tercih edilen bir model haline getirmektedir.

Çizelge 4.26. Önerilen MC-I²Net ile diğer yöntemlerin eğitim parametrelerinin sayısı, FLOP cinsinden hesaplama maliyeti ve çıkarım süresi gibi kritik performans ölçütleri açısından karşılaştırılması.

Yöntemler	OD (%)				Kappa (%)				GD (%)			
	0.2/0.8	0.4/0.6	0.6/0.4	0.8/0.2	0.2/0.8	0.4/0.6	0.6/0.4	0.8/0.2	0.2/0.8	0.4/0.6	0.6/0.4	0.8/0.2
MC-I2dCNet	39.18	56.81	74.58	91.76	27.59	48.59	69.08	89.92	38.12	57.78	73.34	91.63
MC-I3dCNet	41.00	58.86	76.92	92.60	28.32	50.36	70.09	90.82	40.20	58.89	76.25	92.38
MC-I ² Net	43.30	62.82	78.76	93.46	31.60	53.20	72.25	91.82	43.23	61.11	77.50	93.21

Çizelge 4.27'de, temel bileşen sayısının yenidoğan hastalıklarının teşhisinde involüsyon tabanlı MC-I²Net modelinin doğruluğu üzerindeki etkisi incelenmiştir. Sonuçlar, temel bileşen sayısının artmasıyla doğruluk oranlarında bir artış olduğunu göstermektedir. Örneğin, temel bileşen sayısı 16 olduğunda doğruluk oranı %57.09 iken, 96'ya çıkarıldığında doğruluk oranı %93.21'e yükselmiştir. Bu bulgular, temel bileşen sayısı arttıkça modelin performansının arttığını ve dolayısıyla yenidoğan hastalıklarını tespit etmedeki etkinliğini göstermektedir. Bununla birlikte, 96 bileşenli modelle en yüksek doğruluk oranına ulaşmanın daha fazla veri ve hesaplama gücü gerektirdiği unutulmamalıdır. Daha az temel bileşen kullanmak modeli basitleştirebilir ve daha hızlı çalışmasını sağlayabilir. Optimum temel bileşen sayısı, farklı uygulamalarda veri kümesi, model karmaşıklığı ve hesaplama gücü gibi faktörlere göre seçilmelidir.

Çizelge 4.27. Temel Bileşen sayısının involüsyon temelli MC-I²Net modelini kullanarak yenidoğan hastalıklarını tespit etme doğruluğu üzerindeki etkisi.

Temel Bileşen Sayısı	16	32	48	64	80	96
GD (%)	57.09	60.42	68.33	74.58	90.83	93.21

Çeşitli bileşenlerin, özellikle de grup sayısı (G) ve düşürme oranı (r) gibi hiper parametrelerin involüsyon tabanlı tasarımların performansına olan etkisini değerlendirmek için bir araştırma yapılmıştır. Bu araştırma, önerilen MC-I²Net model performansının farklı parametre ayarlarıyla nasıl değişebileceğine dair önemli bilgiler sağlamayı amaçlamaktadır. Çizelge 4.28 ve Çizelge 4.29, yenidoğan HSG veri kümesinden elde edilen sonuçlarla birlikte parametre sayıları, FLOP değerleri, çıkarım süreleri ve doğruluk değerlerinin ayrıntılı bir özetini sunmaktadır. Bu çizelgeler, modelin G ve r gibi hiper parametrelerdeki değişikliklere karşı hassasiyetini gösterirken, MC-I²Net'in performansının bu hiper parametrelerden nasıl etkilendiğine dair kapsamlı bir görünüm de sunmaktadır. Bu, çeşitli uygulamalar için modelin yapılandırmasının optimize edilmesine yardımcı olabilir.

Çizelge 4.28. Farklı Grup Sayıları (G) ile geliştirilen MC-I²Net modelinin performansı.

G	Eğitim Parametre Sayısı	FLOP (G)	Çıkarım Süresi (sn)	GD (%)
1	31.563	0.540	23.394	91.66
2	31.926	0.544	24.412	91.67
4	32.652	0.552	23.893	92.50
8	34.104	0.568	23.107	92.92
16	37.008	0.601	23.248	93.21
32	42.816	0.666	23.961	91.25

Çizelge 4.29. Farklı Düşürme Oranları (r) ile geliştirilen MC-I²Net modelinin performansı.

r	Eğitim Parametre Sayısı	FLOP (G)	Çıkarım Süresi (sn)	GD (%)
1	59.262	0.935	24.260	91.67
2	44.426	0.712	23.449	92.50
4	37.008	0.601	22.400	93.21
8	33.299	0.545	22.824	91.25
16	33.299	0.545	23.005	90.83
32	33.299	0.545	22.593	90.83

Çizelge 4.28'e göre, grup sayısındaki artış, eğitim sırasında parametre ve FLOP değerlerinde artışa neden olmaktadır. Bu artış genellikle doğrulukta bir iyileşme ile sonuçlanırken, çıkarım sürelerinde önemli bir iyileşme anlamına gelmemektedir. En yüksek doğruluk oranı olan %93.21, $G=16$ olduğunda elde edilmiştir. Özellikle, $G=32$ 'de, eğitim sırasında parametre ve FLOP değerlerinde önemli bir artış olmasına rağmen, doğrulukta bir düşüş gözlenmektedir (%91.25). Bu durum, aşırı karmaşıklığın modelin genelleme yeteneğini azaltabileceğini göstermektedir.

Çizelge 4.29'a göre, düşürme oranındaki bir artış, eğitim sırasında parametre ve FLOP değerlerinde bir azalmaya neden olmaktadır. Düşürme oranı arttıkça, eğitim sırasındaki parametre ve FLOP değerleri azalırken, çıkarım sürelerinde genellikle önemli bir değişiklik gözlenmemektedir. Özellikle, düşürme oranının 4 olduğu konfigürasyonda en yüksek doğruluk oranı (%93.21) elde edilirken, daha yüksek düşürme oranları (16 ve 32) doğrulukta düşüşe (%90.83) neden olmaktadır. Bu sonuçlar, model eğitimi sırasında aşırı uyumu kontrol etmede düşürme oranının etkinliğini vurgulamakta ve optimum dengeyi sağlama ihtiyacının altını çizmektedir.

Sonuç olarak, involüsyon içindeki grup sayısı ve düşürme oranı gibi yapılandırma parametrelerinin MC-I²Net modelinin performansını önemli ölçüde etkilediği açıktır. En iyi sonuçların $G=16$ ve $r=4$ olduğunda elde edildiği görülmektedir. Bu çizelgeler, modelin optimize edilmesi ve en iyi performansın elde edilmesi için değerli bir kılavuz sağlamaktadır.

4.2.2.2.3. Ablasyon Analizi

Ablasyon çalışması, bir modelden belirli mimari özellikleri veya katmanları kaldırarak yapılan bir analizdir. Ablasyon çalışmaları genellikle bir modelde hangi özelliklerin veya katmanların daha önemli olduğunu belirlemek, aşırı uyuma veya ezberlemeye yol açabilecek bölgeleri tespit etmek veya bir modelin karar verme sürecini anlamak için yapılır. Bu bölümde, geliştirilen involüsyon tabanlı MC-I²Net modelinde bulunan sinir ağı yapılarının performans üzerindeki etkisi araştırılmıştır.

Çizelge 4.30, geliştirilen MC-I²Net modelindeki farklı sinir ağı mimari kombinasyonları için ablasyon çalışmasının sonuçlarını göstermektedir. Bu çizelgede, farklı mimari özelliklerin (Temel Model, Başlangıç Modülü ve Çok Ölçekli Bağlamsal Yapı) modelin performansı üzerindeki etkisi incelenmiştir. "Temel Model", başlangıç modülü ve çok ölçekli bağlamsal yapı içinde birleştirme aşamasının olmadığı senaryoyu ifade etmekte ve katmanların sırayla bağlandığı bir modeli temsil etmektedir. "Başlangıç Modülü" ve "Çok Ölçekli Bağlamsal Yapı" özellikleri ek mimari geliştirmeleri temsil etmektedir.

Sonuçlar incelendiğinde, Başlangıç Modülü ve özellikle Çok Ölçekli Bağlamsal özelliklerin eklenmesinin modelin performansını önemli ölçüde artırdığı görülmektedir. Özellikle tüm bileşenler birlikte kullanıldığında AUC, MKK, OD, Kappa ve GD değerlerinin oldukça yüksek olduğu görülmektedir. Bu bulgular, MC-I²Net modelinin

yenidoğan HSG verileri kullanılarak hastalık tespiti için etkili bir seçenek sunduğunu göstermektedir.

Çizelge 4.30. Geliştirilen MC-I²Net modeli içerisindeki çeşitli sinir ağı mimarisi kombinasyonları üzerinde yapılan ablasyon çalışmasının sonuçları. Yenidoğan HSG verileri kullanılarak hastalık tespiti için AUC, MKK, OD, Kappa ve GD değerlerini (%) içeren değerlendirme metriklerini içermektedir.

Temel Model	Başlangıç Modülü	Çok Ölçekli Bağlamsal Yapı	AUC	MKK	OD	Kappa	GD
✓	✗	✗	50.26	0.00	16.67	0.00	14.16
✓	✓	✗	97.89	76.44	79.33	74.97	79.16
✓	✓	✓	99.85	92.11	93.16	91.82	93.21

4.2.2.3. Elde Edilen Bulgular

Bu çalışma, yenidoğan hastalıklarının tespiti için geliştirilen involüsyon tabanlı MC-I²Net modelinin etkinliğini değerlendirmeyi amaçlamaktadır. Yapılan deneyler ve analizler, önerilen MC-I²Net modelinin altı sınıflı 240 örnekten oluşan bir HSG veri kümesi üzerinde önemli bir performans sergilediğini göstermektedir. Benzer yapıdaki diğer konvolüsyon tabanlı modellerle karşılaştırıldığında, MC-I²Net modeli daha yüksek AUC, MKK, OD, Kappa ve GD değerlerine ulaşmaktadır. Özellikle, involüsyon tabanlı MC-I²Net'in karmaşıklık matrisi, ROC eğrisi ve çok sınıflı AUC değerleri, diğerlerine kıyasla hastalıkları etkili bir şekilde ayırt etme yeteneğini vurgulamaktadır.

Ayrıca, eğitim parametrelerinin sayısı, FLOP değerleri ve çıkarım süresi gibi performans ölçütleri değerlendirilmiştir. Diğer yöntemlere kıyasla daha az parametre ve FLOP değerlerine sahip olmasına rağmen MC-I²Net modeli, konvolüsyon tabanlı MC-I2dCNet modelinden daha uzun çıkarım süresi sergilemektedir. Involüsyon tabanlı MC-I²Net modeli, MC-I2dCNet gibi konvolüsyon tabanlı modeller kadar optimize edilmemiştir. NVIDIA'nın CUDA'sı gibi özel optimizasyon teknikleri konvolüsyon işlemlerini hızlandırarak MC-I2dCNet'in çıkarım süresini kısaltır. Farklı eğitim/test oranlarının ve temel bileşen sayısının doğruluk üzerindeki etkisi incelenmiş ve MC-I²Net'in daha az eğitim verisiyle bile yüksek performans elde edebileceği gösterilmiştir. Ayrıca, grup sayısı ve düşürme oranı gibi involüsyona özgü yapılandırma parametrelerinin modelin performansını önemli ölçüde etkilediği gözlemlenmiştir. Sonuçlar, MC-I²Net modelinin bu parametrelere duyarlı olduğunu ve en iyi performansın $G=16$ ve $r=4$ olduğunda elde edildiğini göstermektedir. En uygun parametrelerin seçilmesi optimum performans için çok önemlidir. Farklı sinir ağı

mimarisi kombinasyonlarının modelin performansı üzerindeki etkisini araştırmak için bir ablasyon çalışması yapılmıştır. Başlangıç modülünün ve çok ölçekli bağlamsal yapının modelin performansını önemli ölçüde artırdığı gözlemlenmiştir.

Sonuç olarak, geliştirilen involüsyon tabanlı MC-I²Net modeli, HSG ile yenidoğan hastalıklarının tespiti için etkili bir araç olarak ortaya çıkmaktadır. Daha az hesaplama gücü gerektirmesi ve yüksek performansı onu pratik uygulamalar için uygun bir seçenek olarak konumlandırmaktadır. Modelin yüksek doğruluk ve AUC değerleri, yenidoğan HSG verileri kullanılarak hastalık tespiti için umut verici potansiyelini göstermektedir. Çok sınıflı büyük bir HSG veri kümesiyle gerçekleştirilen bu çalışma, MC-I²Net modelinin klinik uygulamalara uyarlanması amacıyla farklı hastalık grupları eklenerek ve veri hacmi artırılarak daha büyük veri setleri üzerinde gelecekte yapılacak değerlendirmeler için zemin hazırlamaktadır. Bu araştırma, yenidoğan sağlık hizmetlerinde erken teşhis ve tedaviye katkıda bulunmak için önemli bir potansiyel sunmaktadır.

4.2.3. Hiperspektral Görüntüleme ve Kan Biyobelirteçleri Kullanılarak Yenidoğan Hastalığının Tanımlanması için 2B/3B Konvolüsyon ve İnvolüsyon Tabanlı HybridCISN Modeli

Bu çalışmada, HSG ve kan biyobelirteçleri kullanılarak yenidoğan hastalıklarının tanımlanması için yeni bir yaklaşım sunulmuştur. Bu amaçla HybridCISN (Hybrid Convolutional and Involutional Spectral Network) modeli geliştirilmiştir. Bu model 2B/3B konvolüsyon ve involüsyon katmanlarını içermektedir. HSG verilerinin sağladığı spektral ve uzamsal bilgilerden yararlanılarak, 2B/3B konvolüsyon ve involüsyon işlemleri bu modele entegre edilmiştir. Ayrıca, teşhis performansını artırmak için kan biyobelirteç verileri - hemoglobin ve bilirubin seviyeleri - modele dahil edilmiştir. Bu yaklaşımın etkinliğini göstermek için iki tür deney yapılmıştır: hasta ve sağlıklı yenidoğanları ayırt etmek için ikili sınıflandırma ve belirli yenidoğan hastalıklarını tanımlamak için çoklu sınıflandırma.

Bu çalışmanın önemli katkıları, yenidoğan hastalıklarının teşhisinde gelişmiş görüntüleme teknolojisi, kan biyobelirteç analizi ve derin öğrenme tekniklerinin entegrasyonunu kapsamaktadır. Önerilen yaklaşım, çeşitli bilgi kaynaklarını bir araya getirerek yenidoğan sağlık hizmetlerinin doğruluğunu, verimliliğini ve erişilebilirliğini artırma potansiyeline sahiptir. Nihayetinde bu, yenidoğanların sağlık durumlarının

iyileştirilmesine katkıda bulunmaktadır. Bu çalışmaya ait grafiksel özet EK-4'te verilmiştir.

Çalışma kapsamında dört farklı hasta grubu (RDS, PTX, NEC ve ICH) ve bir kontrol grubu (Healthy) olmak üzere toplam 5 sınıflı HSG veri kümesi kullanılmıştır. Dört farklı hasta grubunun her birinden 40 veri ve kontrol grubundan 110 veri olmak üzere toplam 270 veri bulunmaktadır. Bu veriler yenidoğan sağlık durumlarını temsil etmektedir.

Elde edilen spektrumların yanı sıra yenidoğanların hemoglobin ve bilirubin seviyelerine ilişkin bilgiler de bu çalışmaya dahil edilmiştir. Hemoglobin ve bilirubin gibi kan biyobelirteçlerinin seviyelerindeki değişiklikler yenidoğan bebeklerin sağlığının değerlendirilmesinde önemli bir rol oynamaktadır. Kan biyobelirteçlerinin spektrumlarla birlikte değerlendirilmesi yenidoğanın sağlık durumu hakkında kapsamlı bilgi sağlar ve potansiyel sağlık sorunlarının erken tespit ve tedavisine yardımcı olabilir. Bu nedenle, hemoglobin ve bilirubin seviyelerinin yanı sıra spektrumların izlenmesi ve değerlendirilmesi çok önemlidir. Bu çalışmada spektrumlar Hemoglobin (Hgb) ve Bilirubin (Bil) parametreleriyle birlikte değerlendirilmiştir. Çizelge 4.31'de her sınıf için üç farklı yenidoğanın fiziksel karakteristik bilgileri ve kan biyobelirteçleri sunulmaktadır.

Çizelge 4.31. Farklı sınıfların fiziksel özellikleri ve kan biyobelirteçleri.

Denek	Doğum Ağırlığı (g)	Doğum haftası + Günü	Hgb (g/dL)	Bil (mg/dL)
ICH_1	1370	30 + 0	10.9	7.45
ICH_2	1575	33 + 2	13.2	2.74
ICH_3	2285	33 + 6	13.9	2.55
NEC_1	655	24 + 6	10.1	4.33
NEC_2	1400	30 + 3	15.8	5.18
NEC_3	1800	32 + 6	16.8	6.10
PTX_1	825	29 + 3	11.7	3.32
PTX_2	1805	32 + 0	10.7	3.42
PTX_3	2865	39 + 0	14.7	3.97
RDS_1	635	26 + 1	9.6	2.79
RDS_2	1515	30 + 1	16.3	4.62
RDS_3	2050	34 + 4	18.6	5.25
Healthy_1	1240	28 + 1	16.0	3.15
Healthy_2	1370	30 + 0	15.6	6.63
Healthy_3	1525	34 + 1	17.8	1.21


4.2.3.1. HybridCISN

HybridCISN (Hybrid Convolutional and Involutorial Spectral Network) modeli, HSG verilerinden geleneksel yöntemlere kıyasla daha kesin ve etkili özellikler çıkarmak için hibrit bir derin öğrenme yaklaşımını benimsemektedir. Bu model hem 2B konvolüsyon hem 3B konvolüsyon hem de involüsyon katmanları içermektedir. 2B ve 3B konvolüsyon operatörleri, spektral ve uzamsal özellikleri aynı anda yakalayarak modelin doğruluğunu artırmaktadır. Involüsyon operatörü ise giriş verilerine bağlı olarak ve belirli ağırlık kümeleri kullanarak daha ayrıntılı ve duyarlı özelliklerin çıkarılmasını sağlamaktadır. Bu, HSG verilerindeki karmaşık ve ince yapısal farklılıkların daha doğru bir şekilde tanımlanmasını ve analiz edilmesini mümkün kılmakta, böylece modelin tanı doğruluğunu ve genel performansını artırmaktadır.

Önerilen model, uzamsal bilgileri yakalamada 2B-ESA'ların ve hem uzamsal hem de spektral bilgileri işlemede 3B-ESA'ların güçlü yönlerinden yararlanmaktadır. Ancak, her iki yaklaşımın da kendi sınırlamaları vardır. Örneğin, 2B-ESA'lar spektral bilgileri yeterince işleyemezken, 3B-ESA'lar hesaplama açısından maliyetli olabilir ve büyük veri kümeleri için uygun olmayabilir. HybridCISN modeli, 2B-ESA ve 3B-ESA'ların en iyi özelliklerini birleştirerek sağlam bir çerçeve oluşturarak bu sınırlamaların üstesinden gelmek için tasarlanmıştır. Model iki ana bileşenden oluşmaktadır:

- 1) *Spektral ve Uzamsal İşleme Bloğu*: Bu blok, 2B ve 3B konvolüsyonları kullanarak spektral bilgilere odaklanır ve uzamsal bilgileri etkili bir şekilde işler.
- 2) *Dikkat Mekanizması*: Bu mekanizma iki bloktan gelen bilgileri birleştirir, involüsyon operatörlerini kullanarak verilere dikkatle odaklanır ve anlamlı özellikler çıkarmak için özel olarak tasarlanmış çekirdekler kullanır. Bu yaklaşım daha yüksek sınıflama doğruluğu sağlar.

HybridCISN modeli hız, doğruluk ve verimlilik açısından çeşitli avantajlar sunmaktadır. Geleneksel 3B-ESA modellerine kıyasla daha hızlı çalışması, onu büyük veri kümeleri için daha uygun hale getirmektedir. Ayrıca 2B, 3B ve Hibrit ESA'lara göre daha yüksek sınıflandırma doğruluğu elde edebilir. Bu model, daha az parametre kullanarak ve daha az bellek gerektirerek daha verimli çalışır. Geliştirilen modelin yapısı Şekil 4.15'te gösterilmektedir.



Şekil 4.15. 2B konvolüsyon, 3B konvolüsyon ve involüsyon katmanlarını içeren HybridCISN modelinin yapısı.

HSG veriler, $I \in \mathbb{R}^{H \times W \times \lambda}$ olarak gösterilen H yüksekliği, W genişliği ve D spektral bantlarını temsil eden ham giriş verilerinden oluşur. Her piksel, farklı sınıfları temsil eden dalga boyları arasında veri içerir. Verilerin anlamlılığını artırmak için, uzamsal boyutlar korunurken ön işleme adımları ve TBA kullanılarak spektral boyutlar azaltılır. Elde edilen yeni $X \in \mathbb{R}^{H \times W \times B}$ verisi, ön işleme ve TBA sonrasında H 'nin yüksekliği, W 'nin genişliği ve B 'nin spektral bantları temsil ettiği şekilde ifade edilir.

HybridCISN çerçevesinde, 3B konvolüsyon çekirdeğinin boyutu $8 \times 3 \times 3 \times 7$ 'dir (yani, Şekil 4.15'te $K_1^1 = 3, K_2^1 = 3, K_3^1 = 7$), bu da $3 \times 3 \times 7$ boyutunda 8 çekirdeğin (iki uzamsal ve bir spektral boyut) uygulanmasıyla 8 hacimsel özellik haritası elde edildiğini göstermektedir. Daha sonra, 2B konvolüsyon uygulamak için, 3B özellik haritaları 2B'ye indirgenmek üzere yeniden şekillendirilmiştir. Hemen ardından gelen 2B konvolüsyon çekirdeğinin boyutu $64 \times 3 \times 3$ 'tür (yani, Şekil 4.15'te $K_1^2 = 3, K_2^2 = 3$), burada özellik haritaları elde etmek için 3×3 boyutunda 64 çekirdek uygulanmıştır. 3B ve 2B konvolüsyonlar uygulanarak hem uzamsal hem de spektral özellikler elde edilmiştir. 2B konvolüsyon katmanının ardından, boyutu yarıya indirmek için 2×2 boyutunda bir maksimum havuzlama katmanı (yani, Şekil 4.15'te $MP_1^1 = 2, MP_2^1 = 2$) kullanılmıştır. Daha sonra, özellik haritalarında kanallar arasındaki korelasyonları yakalamak için iki ardışık involüsyon katmanı eklenmiştir. Bu involüsyon katmanları için grup sayısını temsil eden G^1 ve G^2 değerleri 16'ya ve düşürme oranına karşılık gelen r^1 ve r^2 azaltma oranları 4'e ayarlanmıştır. KGF'den sonra involüsyon katmanları için üretilen çekirdeklerin boyutu 3×3 olarak belirlenmiştir (yani, Şekil 4.15'te $K_1^3 = K_1^4 = 3, K_2^3 = K_2^4 = 3$). 2B konvolüsyondan sonra bilgiyi korumak ve gradyan iniş problemlerini önlemek için bir artık blok eklenmiştir. Veriler daha sonra tam bağlı katmanlara (FC) girdi olarak verilmek üzere düzeltilmiştir. Ağı derinleştirmek için üç tam bağlı katman eklenmiştir. Tam bağlı katmanlar sırasıyla 64, 32 ve 16 nöron içermektedir (yani, Şekil 4.15'te $FC^1 = 64, FC^2 = 32, FC^3 = 16$). Modelin son katmanı (Sınıflandırma), C olarak gösterilen sınıf sayısını temsil etmektedir.

Çizelge 4.32, katman türü, katman boyutu, çıktı haritası boyutu ve parametre sayısı açısından önerilen modelin bir özetini sunmaktadır. Parametre sayısı yenidoğan HSG veri setine, temel bileşen sayısına ve sınıf sayısına bağlı olarak değişmektedir. Çizelge, 96 temel bileşen değeri ile hasta ve sağlıklı yenidoğanlar arasında ayırım yapan 2 sınıflı ($C=2$) HSG veri kümesi kullanılarak oluşturulmuştur. Yenidoğan veri kümesi için HybridCISN modelindeki toplam parametre sayısı 456.006 olarak belirlenmiştir.

Çizelge 4.32. HybridCISN modelinin önerilen tasarımı ayrıntılı bir katman özetiyle birlikte sunulmuştur. Bu modelin son katmanı 96 temel bileşen içerecek şekilde yapılandırılmış ve hasta ve sağlıklı yenidoğanları tespit etmek için $C=2$ olarak alınmıştır.

Katman (Tipi)	Çıkış Şekli	Parametre
input_1 (GirişKatmanı)	(10, 10, 96, 1)	0
conv_3d_1 (Konv3B)	(8, 8, 90, 8)	512
reshape_1 (YenidenŞekillendirme)	(8, 8, 720)	0
conv_2d_1 (Konv2B)	(6, 6, 64)	414784
max_pooling2d_1 (MaksHavuz2B)	(3, 3, 64)	0
inv_1 (İnvolüsyon)	(3, 3, 64)	570
inv_2 (İnvolüsyon)	(3, 3, 64)	0
add_1 (Toplam)	(3, 3, 64)	0
flatten_1 (Düzleştirme)	(576)	0
dense_1 (TamBağlı)	(64)	36928
dense_2 (TamBağlı)	(32)	2080
dense_3 (TamBağlı)	(16)	528
dense_4 (TamBağlı)	($C=2$)	34
Toplam Parametre: 456.006		

4.2.3.2. Deneysel Sonuçlar


Bu çalışmada, HSG spektrumları ve kan biyobelirteçleri kullanılarak geliştirilen HybridCISN derin öğrenme modelinin yenidoğanların sağlık durumunu belirlemedeki etkinliğini değerlendirmek için dört farklı deney gerçekleştirilmiştir. Bu deneyler iki farklı yaklaşımdan ve her yaklaşım iki farklı denemeden oluşmaktadır.

4.2.3.2.1. Eğitim Detayları

HybridCISN modelinin eğitimi sırasında, tüm yaklaşımlar ve deneyler için öğrenme oranı başlangıçta 0.001 olarak ayarlanmış ve kayıp fonksiyonu olarak Seyrek Kategorik Çapraz Entropi kullanılmıştır. Adil bir karşılaştırma için, spektrum ön işleminden sonra temel bileşen sayısı 96'ya sabitlenmiş ve $10 \times 10 \times 96$ boyutlarında yenidoğan HSG verileri elde edilmiştir. Tüm ağırlıklar ve bias değerleri başlangıçta rastgele seçilmiş, geriye yayılma algoritması olarak *Adam* optimizier kullanılmış ve parça büyüklüğü 32 olarak ayarlanmıştır. Modeller toplam 100 iterasyon için eğitilmiştir. Son olarak, sınıflandırma softmax aktivasyon fonksiyonu kullanılarak gerçekleştirilmiştir.

4.2.3.2.2. Deneyler ve Sonuçlar

Çalışma kapsamında kullanılan iki farklı yaklaşım ve bu yaklaşımların blok diyagramları Şekil 4.16'da gösterilmiştir. İlk yaklaşımda, yenidoğanların spektral verileri ön işlemden geçirilmekte ve geliştirilen HybridCISN modeli kullanılarak sınıflandırılmaktadır. İkinci yaklaşımda ise amaç hem spektrumları hem de kan biyobelirteçlerini birlikte kullanmaktır. Burada spektrumlardan özellikler çıkarıldıktan sonra düzleştirme aşamasında verilere hemoglobin ve bilirubin değerleri eklenmektedir. Tüm bu özellikler, HybridCISN modeliyle aynı Tam Bağlı katman yapısına sahip Yapay Sinir Ağı (YSA) ve çeşitli makine öğrenimi algoritmaları - Lineer Diskriminant Analizi (LDA), k-En Yakın Komşu (k-EYK), Destek Vektör Makinaları (DVM) ve Naive Bayes (NB) - kullanılarak sınıflandırılır. Bu, spektral ve kan biyobelirteçlerinin birlikte değerlendirilmesine olanak tanımıştır.



Şekil 4.16. Çalışma kapsamında uygulanan iki farklı yaklaşımı gösteren blok diyagramı.

Her bir yaklaşım için iki farklı deney gerçekleştirilmiştir. İlk deney, HSG ve kan biyobelirteçlerini kullanarak yenidoğanın hasta mı yoksa sağlıklı mı olduğunu belirlemeyi amaçlayan ikili bir sınıflandırma deneyidir. İkinci deney, hastalık tespitini de içerecek şekilde kapsamı genişletmektedir. Burada, spektrumlar ve kan biyobelirteçleri kullanılarak ICH, NEC, PTX, RDS ve kontrol grubu (Healthy) arasında ayırım yapılmaktadır.

4.2.3.2.2.1. İkili Sınıflandırma Deneyi

Bu deneyde toplam 220 HSG veri örneği kullanılmıştır. Bunlardan 110'u sağlıklı yenidoğanlara, geri kalan 110'u ise hasta yenidoğanlara aittir. Hasta sınıflar, 30 NEC, 40 PTX ve 40 RDS'li yenidoğanlardan alınan örneklerden oluşmaktadır. Sağlıklı sınıflar için 80 örnek gövde bölgesinden, 30 örnek ise alt karın bölgesinden elde edilmiştir.

Veri kümesi için rastgele bir bölme işlemi gerçekleştirilmiş, verilerin %70'i eğitim amacıyla kullanılmış ve kalan %30'luk kısım test için ayrılmıştır. Modelin genelleme kabiliyetini artırmak ve güvenilir sonuçlar elde etmek için 10-katlamalı çapraz-doğrulama stratejisi uygulanmıştır. Bu yaklaşım, HybridCISN modelinin performansını kapsamlı bir şekilde değerlendirmek için eğitim ve test sürecinin on kez tekrarlanmasını içermektedir.

Çizelge 4.33'te, sadece spektral verileri kullanarak yenidoğanların sağlık durumunu tespit etmeyi amaçlayan *Yaklaşım #1* için HybridCISN modelinin değerlendirme sonuçları verilmiştir. Modelin performansı şu şekildedir: Kesinlik (%82.3), Duyarlılık (%94.00), F1-skor (%87.85), AUC (%97.24), MKK (%77.31), Kappa (%76.41) ve GD (%88.73). Bu sonuçlara göre, hasta sınıflar sağlıklı sınıflara kıyasla daha düşük doğrulukla tanımlanmıştır.

Çizelge 4.33. Sadece spektral veriler kullanılarak geliştirilen HybridCISN modeli ile elde edilen ikili sınıflandırma sonuçları.


Yöntem	AUC	MKK	Kappa	F1-Skor	Kesinlik	Duyarlılık	GD
HybridCISN (sadece spektrumlar)	97.24	77.31	76.41	87.85	82.30	94.00	88.73

Çizelge 4.34'te, spektral veriler ve kan biyobelirteçleri kullanılarak oluşturulan *Yaklaşım #2* için farklı sınıflandırma yöntemleri karşılaştırılmıştır. Her yöntem için AUC, MKK, Kappa, F1-Skor, Kesinlik, Duyarlılık ve GD ölçümleri verilmiştir. Sonuç olarak, YSA modeli (HybridCISN) diğer yöntemlere kıyasla daha yüksek performans göstermiştir. Özellikle yüksek AUC değeri, modelin sınıflar arasında ayırım yapma kabiliyetinin yüksek olduğunu göstermektedir. Bu durum, spektral verileri ve kan biyobelirteçlerini birleştiren bu modelin yenidoğanların sağlık durumunu tespit etmek için etkili bir araç olabileceğini göstermektedir.

Çizelge 4.34. Spektral veriler ve kan biyobelirteçleri kullanılarak *Yaklaşım #2* için elde edilen ikili sınıflandırma sonuçları.

Yöntem	AUC	MKK	Kappa	F1-Skor	Kesinlik	Duyarlılık	GD
NB	84.71	70.72	74.97	85.76	78.37	94.38	84.39
k-EYK	87.53	76.16	74.71	88.29	82.21	95.94	87.27
DVM	87.99	77.22	75.61	88.71	82.51	96.56	87.73
LDA	88.87	78.74	77.40	89.38	83.58	96.56	88.63
YSA	98.55	87.79	87.27	93.65	90.60	96.67	93.64

Şekil 4.17'de, *Yaklaşım #2* için HybridCISN modelinden elde edilen karmaşıklık matrisi verilmiştir. Model, 330 sağlıklı yenidoğandan 319'unu ve 330 hasta yenidoğandan 299'unu doğru sınıflandırmıştır. Yalnızca 11 sağlıklı yenidoğanı ve 31 hasta yenidoğanı yanlış sınıflandırmıştır. Bu sonuçlar, önerilen hibrit modelin sağlıklı yenidoğanları doğru bir şekilde tanımlamada oldukça başarılı olduğunu göstermektedir.



Şekil 4.17. İkili sınıflandırma deneyi ve *Yaklaşım #2* için elde edilen karmaşıklık matrisi.

Çizelge 4.35, farklı grup sayıları (G) ve düşürme oranları (r) altında HybridCISN modelinin performansını göstermektedir. Grup sayısı arttıkça performansın başlangıçta genel olarak iyileştiği, ancak daha yüksek grup sayılarının performansı olumsuz etkileyebildiği görülmektedir. Düşürme oranları performansta değişkenlik göstermektedir; artış bazı durumlarda performansı artırırken, diğerlerinde performansı düşürmektedir. Her hiper parametre seti için performanstaki önemli değişkenlik, modelin belirli hiper parametreler altında dengesiz veya kararsız olabileceğini ve daha iyi performans elde etmek için bu parametrelerin daha dikkatli ayarlanması gerektiğini göstermektedir. Bu analiz, HybridCISN modelindeki involüsyon katmanlarını optimize etmek için uygun hiper parametrelerin seçilmesi konusunda rehberlik sağlamaktadır. Bu deney için en iyi sonuç $G=16$ ve $r=4$ ile elde edilmiştir.

Çizelge 4.35. HybridCISN'in farklı grup sayıları (G) ve düşürme oranları (r) için performansı.

Hiper parametreler	1	2	4	8	16	32
G	89.39	89.70	90.30	91.21	93.64	91.52
r	91.82	91.21	93.64	91.51	90.00	89.70

Çizelge 4.36'da temel bileşen sayısının doğruluk üzerindeki etkisi gösterilmektedir. TBA kullanılarak boyut azaltma işlemi gerçekleştirilmiş ve farklı temel bileşen sayıları için elde edilen GD sunulmuştur. Sonuçlar incelendiğinde, temel bileşen sayısı arttıkça doğruluk oranlarının genel olarak iyileştiği görülmektedir. Özellikle, temel bileşen sayısı 16'dan 96'ya çıktığında, GD %87.22'den %93.64'e yükselmektedir. Bu, daha fazla temel bileşen kullanmanın modelin veri setindeki önemli bilgileri daha iyi temsil etmesini ve böylece performansını artırmasını sağladığını göstermektedir. Dolayısıyla, TBA'nın uygun şekilde uygulanması ve doğru sayıda temel bileşenin seçilmesi, sınıflandırma modelinin performansını artırarak doğruluk oranlarının yükselmesini sağlayabilir.

Çizelge 4.36. Temel bileşen sayısının doğruluk üzerindeki etkisi.

Temel Bileşen Sayısı	16	32	48	64	80	96
GD (%)	87.22	87.55	88.19	90.30	91.60	93.64

Çizelge 4.37, farklı katmanların (3B konvolüsyon, 2B konvolüsyon, involüsyon, tam bağlı katman) modelin performansı üzerindeki etkisini göstermektedir. Her bir özellik kombinasyonu için AUC, MKK, Kappa, F1-Skor, Duyarlılık, Kesinlik ve GD gibi bir dizi metrik bu çizelgede sunulmaktadır. Çizelge incelendiğinde, 3B konvolüsyon ve involüsyon katmanlarının modelin performansı için en önemli katmanlar olduğu görülmektedir. Bu katmanlar AUC, MKK, Kappa, F1-Skor, Duyarlılık ve Kesinlik üzerinde önemli bir etkiye sahiptir. Tam bağlı katmanda önemlidir ancak 2B konvolüsyon katmanından daha az kritiktir. En yüksek AUC değeri (%98.83) involüsyon ve tam bağlı katmanları özellik kombinasyonuna dahil edildiğinde elde edilmiştir. Bu da involüsyon katmanının model üzerinde olumlu bir etkisi olduğunu göstermektedir. Özellikle, tüm katmanlar birleştirildiğinde, ortaya çıkan model AUC, MKK, Kappa, F1-Skor ve GD gibi metriklerde diğerlerinden daha iyi performans göstermektedir. Bu durum, farklı katman türlerinin bir araya getirilmesinin modelin daha iyi performans göstermesini sağladığını ortaya koymaktadır. Özellikle, modelin tüm katmanları dahil edildiğinde elde edilen sonuçlar daha iyi genelleme kabiliyetine ve daha yüksek doğruluk seviyelerine işaret etmektedir.

Çizelge 4.37. Farklı ağ mimarilerinin ablasyon çalışması. Yenidoğan HSG verileri ve kan biyobelirteçleri üzerinde AUC, MKK, Kappa, F1-Skor, Duyarlılık, Kesinlik ve GD değerleri (%).

Konvolüsyon 3B	Konvolüsyon 2B	İnvolüsyon	Tam Bağlı Katman	AUC	MKK	Kappa	F1-Skor	Duyarlılık	Kesinlik	GD
✓	✗	✗	✗	97.83	80.00	79.50	88.67	94.50	82.50	89.14
✗	✓	✗	✗	97.67	82.50	82.50	90.33	93.00	87.00	89.65
✗	✗	✓	✗	98.00	83.67	83.00	90.50	96.50	84.00	89.90
✗	✗	✗	✓	97.50	79.67	79.00	88.33	92.50	84.00	87.88
✓	✓	✗	✗	97.67	83.17	82.00	90.00	97.50	82.00	89.39
✓	✗	✓	✗	97.17	78.50	78.00	88.00	93.50	82.00	87.37
✓	✗	✗	✓	98.83	85.50	85.00	91.50	96.50	86.00	90.15
✗	✓	✓	✗	97.83	84.67	84.50	91.17	95.00	87.00	90.65
✗	✓	✗	✓	98.00	84.00	84.00	91.17	93.00	88.50	90.40
✗	✗	✓	✓	98.83	84.00	83.00	90.50	97.50	83.00	90.91
✓	✓	✓	✗	97.83	84.17	83.50	90.83	95.00	86.00	90.75
✓	✓	✓	✓	98.55	87.79	87.27	93.65	98.20	90.40	93.64

4.2.3.2.2. Çoklu Sınıflandırma Deneyi

Bu deneyde, 5 farklı sınıfa ayrılmış toplam 200 veri kullanılmıştır: ICH, NEC, PTX, RDS ve bir kontrol grubu (Healthy). Her sınıf 40 HSG verisinden oluşmaktadır. Sağlıklı sınıf için 40 veri noktasının 20'si gövde bölgesinden, 10'ar tanesi ise alt karın ve baş bölgelerinden elde edilmiştir. Hasta verileri, ilgili hastalıklara karşılık gelen vücut bölgelerinden alınmıştır.

Veri kümesi, uygulamanın çok sınıflı doğası nedeniyle, ikili sınıflandırma deneyinden farklı olarak, verilerin %80'inin eğitim amacıyla kullanıldığı ve kalan %20'sinin test için ayrıldığı rastgele bölünmeye tabi tutulmuştur. Model genellemesini iyileştirmek ve güvenilir sonuçlar elde etmek için bu işlem 10 kez tekrarlanarak çapraz doğrulama stratejisi uygulanmıştır.

Çizelge 4.38'de yer alan sonuçlar, HybridCISN modelinin yalnızca spektrum verilerini kullanarak çoklu sınıflandırmadaki performansını göstermektedir. Bu değerlendirme yalnızca spektrum verilerinden elde edilen performansı yansıtmaktadır. Elde edilen bulgulara göre, HybridCISN modeli sadece spektrum kullanarak iyi bir performans sergilemektedir. AUC değeri %98.53 olarak hesaplanmıştır ve modelin yüksek sınıflandırma kabiliyetine işaret etmektedir. MKK ve Kappa değerleri sırasıyla %81.53 ve %80.37 olarak hesaplanmıştır. Bu, modelin dengeli ve güvenilir

sınıflandırma yapabildiğini göstermektedir. GD değeri ise %84.50 olup modelin genel performansını göstermektedir. Bu sonuçlar, HybridCISN modelinin yenidoğan spektrum verilerini etkili bir şekilde sınıflandırabildiğini ve potansiyel olarak uygulama alanında yararlı bir araç olarak kullanılabileceğini göstermektedir.

Çizelge 4.38. Spektrum verileri ile geliştirilen HybridCISN modeli kullanılarak elde edilen çoklu sınıflandırma sonuçları.


Yöntem	AUC	MKK	Kappa	GD
HybridCISN (sadece spektrumlar)	98.53	81.53	80.37	84.50

Çizelge 4.39, farklı sınıflandırma yöntemlerinin (k-EYK, DVM, LDA, NB, YSA) performansını değerlendirmek için kullanılan çeşitli kriterlere dayalı sonuçları sunmaktadır. Her bir yöntemin sınıflandırma performansını değerlendirmek için MKK, Kappa ve GD kriterleri kullanılmıştır. YSA yöntemi (yani HybridCISN), AUC (%98.36), MKK (%87.27), Kappa (%87.77) ve GD (%90.25) için en yüksek değerleri sergileyerek diğer yöntemlere kıyasla üstün sınıflandırma başarısı göstermiştir. LDA, k-EYK, DVM ve NB yöntemleri benzer sonuçlar verirken, YSA'nın bu yöntemlerden daha başarılı olduğu belirlenmiştir. Sonuç olarak, YSA yöntemi bu veri kümesi için en etkili sınıflandırma yöntemi olarak öne çıkmaktadır; ancak diğer yöntemler de genel olarak kabul edilebilir bir performans sergilemektedir.

Çizelge 4.39. Spektrum verileri ve kan biyobelirteçleri kullanılarak *Yaklaşım #2* için elde edilen çoklu sınıflandırma sonuçları.

Yöntem	AUC	MKK	Kappa	GD
k-EYK	91.57	83.53	83.13	86.50
DVM	91.88	84.12	83.75	87.00
LDA	92.03	84.60	84.06	87.25
NB	92.35	85.14	84.69	87.75
YSA	98.36	87.27	87.77	90.25

Şekil 4.18, *Yaklaşım #2* kullanılarak çoklu sınıflandırma deneyinden elde edilen karmaşıklık matrisini göstermektedir. Model, 80 ICH örneğinden 65'ini, 80 NEC örneğinden 73'ünü, 80 PTX örneğinin tamamını, 80 RDS örneğinden 71'ini ve 80 sağlıklı örnekten 72'sini doğru sınıflandırmıştır. Ayrıca, model 10 ICH örneğini sağlıklı olarak yanlış sınıflandırmıştır. Genel olarak, önerilen HybridCISN modeli hem hasta hem de sağlıklı örnekleri başarıyla sınıflandırmıştır.



Şekil 4.18. Çoklu sınıflandırma deneyi ve *Yaklaşım #2* için elde edilen karmaşıklık matrisi.

Çizelge 4.40'da, HybridCISN modelinin involüsyon katmanları için farklı hiperparametre değerleri ile performansı ölçülmüştür. Modelin performans değerleri grup sayısı (G) ve düşürme oranı (r) için sunulmuştur. En yüksek performans, G için 16 hiperparametre değeri ile elde edilmiş, ancak diğer hiperparametre değerleri ile de benzer performans seviyeleri gözlemlenmiştir. Düşürme oranı (r) için en yüksek performans $r=4$ ile elde edilmiştir. Bu çizelge, farklı hiper parametrelerin model performansı üzerindeki etkisini göstermektedir.

Çizelge 4.40. HybridCISN'in farklı grup sayıları (G) ve düşürme oranları (r) için performansı.

Hiper parametreler	1	2	4	8	16	32
G	89.00	89.25	89.25	89.75	90.25	88.00
r	89.75	89.25	90.25	90.00	88.50	89.50

Çizelge 4.41, farklı temel bileşen sayılarının (16, 32, 48, 64, 80 ve 96) sınıflandırma doğruluğu üzerindeki etkisini göstermektedir. Genel olarak, doğruluk oranları temel bileşen sayısı arttıkça artma eğilimindedir. Başlangıçta, 16 temel bileşen kullanıldığında, sınıflandırma doğruluğu %86.63'tür ve bileşen sayısı arttıkça doğruluk da artmaktadır. 96 temel bileşen kullanıldığında doğruluk oranı %90.25'e yükselmektedir. Bu, daha fazla bileşen kullanmanın veriler arasındaki varyansı daha iyi açıklamaya yardımcı olduğunu ve böylece sınıflandırma doğruluğunu artırdığını göstermektedir. Ancak, sınıflandırma doğruluğundaki artışın yavaşladığı ve nihayetinde

durduğu bir nokta olabilir. Bu nedenle, en uygun bileşen sayısını belirlemek için modelin karmaşıklığı ve veri kümesinin özellikleri dikkate alınmalıdır.

Çizelge 4.41. Temel bileşen sayısının doğruluk üzerindeki etkisi.

Temel Bileşen Sayısı	16	32	48	64	80	96
GD (%)	86.63	87.38	88.25	88.63	89.13	90.25

Çizelge 4.42. Yenidoğan HSG verileri üzerinde çoklu sınıflandırma deneyi için farklı ağ mimarilerinin ablasyon çalışması. AUC, MKK, Kappa ve GD değerleri (%).

Konvolüsyon 3B	Konvolüsyon 2B	İnvolüsyon	Tam Bağlı Katman	AUC	MKK	Kappa	GD
✓	✗	✗	✗	93.72	83.33	83.13	85.50
✗	✓	✗	✗	94.15	80.30	80.16	83.13
✗	✗	✓	✗	94.21	83.42	83.33	85.70
✗	✗	✗	✓	93.07	77.99	77.78	81.23
✓	✓	✗	✗	93.98	83.84	83.72	85.98
✓	✗	✓	✗	94.59	84.50	84.31	86.45
✓	✗	✗	✓	94.89	84.31	83.72	85.98
✗	✓	✓	✗	93.94	83.87	83.72	85.98
✗	✓	✗	✓	93.31	83.51	83.31	85.45
✗	✗	✓	✓	95.21	84.34	84.20	86.43
✓	✓	✓	✗	94.19	84.55	84.41	86.65
✓	✓	✓	✓	98.36	87.27	87.77	90.25

Çizelge 4.42'de, farklı sinir ağı bileşenlerinin (3B konvolüsyon, 2B konvolüsyon, involüsyon, tam bağlı katman) ve bunların kombinasyonlarının sınıflandırma performansını ölçen çeşitli metrikler üzerindeki etkisini gösteren bir ablasyon analizi sunulmaktadır. Çizelgede her bir bileşen veya bileşen kombinasyonu için AUC, MKK, Kappa ve GD değerleri verilmektedir. Veriler, farklı ağ mimarilerinin ve katmanlarının varlığının veya yokluğunun, yenidoğan HSG verileri üzerinde yapılan çoklu sınıflandırma deneylerinde model performansını önemli ölçüde etkilediğini göstermektedir. Özellikle, tüm katmanlar birlikte kullanıldığında optimum performans elde edilirken, yalnızca tam bağlı katman mevcut olduğunda performans önemli ölçüde düşmektedir. Bu bulgular, modelin sınıflandırma kabiliyetinin ağ yapısındaki katmanların doğru kombinasyonuna bağlı olduğunu göstermektedir. Ayrıca, involüsyon ve 3B konvolüsyon gibi belirli katmanları içeren kombinasyonlar daha yüksek performans sağlamaktadır. Bu sonuçlar, yenidoğan HSG verileri için doğru bir

sınıflandırma modeli geliştirmek üzere ağ yapısının dikkatle seçilmesinin önemini vurgulamaktadır.

Sunulan ablasyon analizi çizelgesinde involüsyonun sinir ağı bileşeni belirgin bir şekilde öne çıkmaktadır. İnvolüsyon bileşeni, diğer bileşenlere kıyasla sınıflandırma doğruluğunu artırmada daha etkili bir performans göstermektedir. Örneğin, involüsyon bileşeni tek başına kullanıldığında GD %85.70 olarak elde edilmiştir. Diğer bileşenlerle birleştirildiğinde involüsyonun etkisi artmakta ve sınıflandırma performansında daha yüksek bir artışa neden olmaktadır. Bu sonuçlar, involüsyonun sınıflandırma modelinde önemli bir rol oynadığını ve diğer bileşenlerle birlikte kullanıldığında daha iyi performans elde ettiğini göstermektedir. En yüksek performans tüm bileşenler birlikte kullanıldığında gözlemlenmektedir. Bu bulgular, sinir ağı bileşenlerinin kombinasyonunun ve etkileşiminin sınıflandırma performansı üzerindeki değişen etkilerini vurgulamaktadır.

4.2.3.3. Tartışma

Bu tez çalışması, yenidoğanların sağlık durumunu tespit etmek için spektral verileri ve kan biyobelirteçlerini birleştirmek ve bu birleşik yapıyı hibrit bir modelle analiz etmeye odaklanmıştır. İlk yaklaşım sadece spektral verileri kullanarak sınıflandırmayı içerirken, ikinci yaklaşım hem spektral verileri hem de kan biyobelirteçlerini model değerlendirmesine dahil etmektedir. Önerilen hibrit model, bu iki veri kaynağını entegre ederek sınıflandırma performansını artırmayı ve yenidoğanların sağlık durumunu belirlemek için daha kapsamlı bir yöntem sağlamayı amaçlamaktadır.

Yenidoğan sağlığı alanındaki araştırmalar, HSG verilerinin kan biyobelirteçleri ile birleştirilmesinin yenidoğanların sağlık durumunun belirlenmesinde etkili bir yöntem olabileceğini göstermektedir. İlk yaklaşımda sadece HSG verilerini kullanan HybridCISN modelinin performansı değerlendirilirken, ikinci yaklaşımda HSG verilerinin kan biyobelirteçleri ile birlikte kullanılmasıyla elde edilen sonuçlar incelenmiştir.

İkili sınıflandırma deneylerinde, spektral verilere kan biyobelirteçlerinin eklenmesinin modelin performansını ve yenidoğan sağlık durumu tespitini önemli ölçüde artırdığı gözlemlenmiştir. Hasta verilerin doğru sınıflandırılmasında önemli bir iyileşme söz konusudur. Bu durum, spektral verilere kan biyobelirteçlerinin

eklenmesinin, yenidoğan sağlığıyla ilgili teşhis ve tarama uygulamalarında önemli bir gelişme sunabileceğini belirtmektedir.

Çoklu sınıflandırmada da benzer bir eğilim gözlenmektedir. Model yalnızca spektral verileri kullanarak yüksek doğruluk elde etse de kan biyobelirteçlerinin eklenmesi doğruluk oranlarında önemli bir artışa neden olmaktadır. Bu durum, kan biyobelirteçlerinin sınıflandırma sürecinde değerli bir bilgi kaynağı olduğunu göstermekte ve model performansını artırmak için bu tür ek verilerin kullanılmasının önemini vurgulamaktadır.

Ayrıca, ablasyon çalışmaları, model bileşenlerinin değerlendirilmesinde involüsyon katmanının belirleyici olduğunu göstermektedir. Farklı sinir ağı mimarileri ve hiper parametrelerin incelenmesiyle, modelin performansının artırılmasının mümkün olduğu açıktır. Bu durum, gelecekteki çalışmalarda gerçek dünya uygulamaları için modelin daha fazla optimizasyonuna ihtiyaç duyulduğunun altını çizmektedir.

Yukarıda yer alan değerlendirmelere ek olarak, bu çalışmaların bazı kısıtlamaları da göz önünde bulundurulmalıdır. Özellikle, veri setinin nispeten küçük olması ve modelin karmaşıklığından kaynaklanan yorumlanabilirlik ve klinik uygulanabilirlik zorlukları, gelecekteki çalışmalarda ele alınması gereken hususlardır. Ayrıca, kan biyobelirteçlerinin ölçümünün invaziv doğası, pratik uygulanabilirliği sınırlandıran bir faktördür.

4.2.3.4. Sonuç Değerlendirmesi

Bu çalışma hem spektral verileri hem de kan biyobelirteçlerini birleştiren ve geliştirilen hibrit bir modelin yenidoğan sağlığı teşhisinde etkili bir araç olabileceğini göstermektedir. Geliştirilen HybridCISN modeli, spektral verileri ve kan biyobelirteçlerini entegre ederek yenidoğanların sağlık durumunu belirlemek için kapsamlı bir yaklaşım sunmaktadır.

Çalışma, yenidoğanların sağlık durumunun belirlenmesinde hem spektral verilerin hem de kan biyobelirteçlerinin potansiyelini göstermektedir. Ayrıca, hibrit modelin katmanlarının ablasyon analizi, her bir bileşenin sınıflandırma performansına katkısının anlaşılmasında yardımcı olmuştur. Özellikle involüsyon katmanının öne çıktığı ve diğer bileşenlere kıyasla sınıflandırma doğruluğunu artırmadaki etkinliği gözlemlenmiştir.

HybridCISN modeli hem ikili hem de çoklu sınıflandırma deneylerinde yüksek performans göstermiş ve YSA yöntemi diğer sınıflandırma yöntemlerine kıyasla daha iyi sonuçlar vermiştir. Bu durum, önerilen hibrit modelin etkinliğini ve pratik uygunluğunu vurgulamaktadır.

Sonuç olarak, bu çalışma yenidoğan sağlığı teşhisinde hibrit modellerin kullanılmasının önemini ve potansiyelini vurgulamaktadır. Spektral verilerin ve kan biyobelirteçlerinin entegrasyonu daha doğru ve güvenilir bir sağlık teşhis sistemi sağlayabilir. Bu hibrit modelin klinik uygulanabilirliğini ve yaygın kullanımını değerlendirmek için daha fazla araştırmaya ihtiyaç vardır. Bu çalışma yenidoğan sağlığı teşhis ve izleme süreçlerinde önemli bir adım olabilir ve gelecekteki araştırmalara ilham verebilir.

4.3. Boyut İndirme Tekniklerinin Etkisinin Değerlendirilmesi


Bu araştırma, yenidoğan sağlığını değerlendirmek için İSA kullanarak çeşitli boyut indirgeme tekniklerini değerlendirmektedir. HSG boyutluluğunun azaltılması veri analizini kolaylaştırır, hesaplama karmaşıklığını azaltır ve sınıflandırma doğruluğunu artırır. Amaç, İSA ile entegre edildiğinde HSG için farklı boyut indirgeme yaklaşımlarının etkinliğini değerlendirmektir. Bu kapsamda SG, YDG, BBA, TDA, TBA ve NOMA yöntemlerinin karşılaştırmalı analizleri yapılmıştır. Boyut indirgeme yöntemleri değerlendirilirken biyomedikal HSG verileri kullanılmıştır.

4.3.1. İnvolüsyonel Sinir Ağı Modeli

Veriye özgü involüsyon çekirdekleri aracılığıyla ayırt edici kabiliyete ve ifade gücüne öncelik veren verimli boyut indirgeme için yeni bir İSA modeli geliştirilmiştir. Bu yöntem, doğru HSG veri analizi için çok önemli olan kanal korelasyonlarını vurgulayarak, daha az çekirdekle anlamlı özellikleri etkili bir şekilde çıkarmayı amaçlamaktadır.

Bu çalışma kapsamında geliştirilen İSA modeli Şekil 4.19'da gösterilmektedir. İlk olarak, HSG verilerine ön işleme adımları uygulanmıştır. Ön işlemenin ardından, uzamsal boyutu değiştirmeden spektral boyutu azaltmak için boyut indirgeme teknikleri kullanılmıştır. Bu işlemten sonra spektral boyut 32 olarak belirlenmiştir. Böylece, $10 \times 10 \times 2018$ boyutlarındaki ham veriler ön işleme adımlarıyla $10 \times 10 \times 1538$ 'e, daha sonra boyut indirgeme teknikleri kullanılarak $10 \times 10 \times 32$ olarak ele alınmıştır. Daha

sonra, veriler özellik çıkarımı için modele girdi olarak verilmiştir. Model mimarisi toplam 6 involüsyon katmanından oluşmaktadır. İlk olarak 3×3 involüsyon işlemi uygulanmış, ardından daha büyük ölçekli 5×5 involüsyon işlemi gerçekleştirilmiş ve sonrasında 2×2 ortalama havuzlama ile alt örnekleme yapılmıştır. Bu işlemler sırayla modeldeki 3 yapı içerisinde de yer almaktadır (Şekil 4.19'a bakınız). Her ilk involüsyon katmanından sonra ReLU aktivasyon fonksiyonu kullanılmıştır. Bu adımları takiben, özellikler çıkarılmış ve tam bağlı katmanlara girdi olarak verilmiştir. Her biri sırasıyla 128, 64 ve 32 nöron içeren toplam 3 farklı tam bağlı katman bulunmaktadır. Bu aşamada, modelin aşırı uyumunu önlemek için her tam bağlı katmanından sonra 0.25'lik bir bırakma oranı ile unutturma katmanları eklenmiştir. Karar aşamasında softmax aktivasyon fonksiyonu kullanılarak sınıflandırma tamamlanmıştır.



Şekil 4.19. Geliştirilen İnvolüsyonel Sinir Ağı Modeli

Çizelge 4.43. Geliştirilen İSA modelinin ayrıntılı katman özeti.

Katman Tipi	Boyut	Aktivasyon Fonksiyonu / Unutturma	Çıkış Şekli	Parametre
GirişKatmanı	-	-	(10×10×32)	0
İnvolüsyonKatmanı1	3×3	ReLU	(10×10×32)	506
İnvolüsyonKatmanı2	5×5	-	(10×10×32)	1274
OrtHavuz1	2×2	-	(5×5×32)	0
İnvolüsyonKatmanı3	3×3	ReLU	(5×5×32)	506
İnvolüsyonKatmanı4	5×5	-	(5×5×32)	1274
OrtHavuz2	2×2	-	(5×5×32)	0
İnvolüsyonKatmanı5	3×3	ReLU	(2×2×32)	506
İnvolüsyonKatmanı6	5×5	-	(2×2×32)	1274
OrtHavuz3	2×2	-	(1×1×32)	0
Düzleştirme	-	-	(32)	0
TamBağlı1	128	Unutturma (0.25)	(128)	4224
TamBağlı2	64	Unutturma (0.25)	(64)	8256
TamBağlı3	32	Unutturma (0.25)	(32)	2080
ÇıkışKatmanı	2	Softmax	(2)	66

G ve r olmak üzere iki ayrı hiper parametre, modelde kullanılan involüsyonel katmanlarla ilişkilendirilmiştir. Önceki çalışmalardan elde edilen sonuçlar göz önünde bulundurularak en uygun G ve r değerleri sırasıyla 16 ve 4 olarak belirlenmiştir. Model eğitimi esnasında toplam verinin %70'i kullanılmış, kalan %30'luk kısım ise eğitilen modelin test edilmesi için ayrılmıştır. Çizelge 4.43'te, model katmanlarının ayrıntılı bir özeti verilmiştir.

4.3.2. DeneySEL Sonuçlar

Deneylerde, hasta bireylerden 110 ve sağlıklı bireylerden 110 örnek olmak üzere toplam 220 yenidoğan HSG verisi kullanılmıştır. Başlangıçta, 500 nm ve 1000 nm'lik gürültüsüz dalga boyu aralığında 1538 spektrum ele alınmış ve bunlar daha sonra yumuşatmak için ön işleme tabi tutulmuştur. Daha sonra, spektral boyutu 32'ye düşürmek için boyut indirgeme teknikleri kullanılmış ve bu işlenmiş veriler geliştirilen İSA modeli için girdi olarak kullanılmıştır. İSA modeli *Adam* optimizier kullanılarak eğitilmiş ve veriler ağı 32 parça büyüklüğünde gönderilmiştir. İlk öğrenme oranı 0.001 olarak ayarlanmış ve öğrenme oranını azaltmak için 10^{-6} 'lık bir düşüş değeri kullanılmıştır. Kayıp fonksiyonu olarak Seyrek Çapraz Entropi seçilmiş ve tüm modeller 100 iterasyon için eğitilmiştir. Modellerin genelleme kabiliyetini artırmak için K-katlamalı çapraz-doğrulama yöntemi kullanılmış ve K değeri 10'a ayarlanarak değerlendirmeler buna göre yapılmıştır. Sonuçları değerlendirmek için farklı performans ölçütleri kullanılmıştır.

Çizelge 4.44. Boyut İndirgeme Yöntemlerinin Performans Karşılaştırması

Yöntemler	Performans Değerlendirme Ölçütleri (%)							BİS (sn)
	GD	Kesinlik	Duyarlılık	F1-Skor	Kappa	MKK	AUC	
SG	82.33	73.60	90.70	82.25	64.85	66.72	93.59	3.78
YDG	84.55	79.60	89.80	84.45	69.09	69.80	92.39	5.54
TDA	85.61	81.40	90.10	85.55	71.22	71.71	91.93	2.79
BBA	85.76	84.40	87.40	84.70	71.52	71.99	94.60	25.00
TBA	87.42	84.22	90.91	87.02	75.15	75.59	96.88	2.82
NOMA	88.33	91.00	85.90	88.35	76.67	77.01	92.84	8.39

Çizelge 4.44, çeşitli boyut indirgeme tekniklerinin ayrıntılı bir karşılaştırmasını sunmakta ve sınıflandırma modellerini iyileştirmedeki etkinliklerini vurgulamaktadır. NOMA, birden fazla değerlendirme ölçütünde en iyi performans gösteren yöntem olarak öne çıkmaktadır. Dengeli sınıflandırma performansını sürdürme, NOMA'nın tüm yöntemler arasında en yüksek Kappa ve MKK puanlarını elde etmesiyle belirginleşir. Tahmin edilen ve gözlemlenen sınıflandırmalar arasında güçlü bir uyum sergiler. Ayrıca, NOMA hasta verileri doğru bir şekilde tahmin etmede rekabetçi bir hassasiyet göstermekte, pozitif örnekler için duyarlılık ve F1-Skor açısından en yüksek puanları elde etmekte ve kesinlik ile duyarlılık arasında dengeli bir denge sağlarken hasta örnekleri doğru bir şekilde tanımlamaktadır. Bu durum, NOMA'nın HSG verilerdeki karmaşık örüntüleri yakalama ve karmaşık veri yapılarını ele alma konusundaki etkinliğini vurgulayarak, onu özellikle dengeli sınıflandırmaların gerektiği senaryolarda değerli kılmaktadır. Ayrıca, NOMA en yüksek GD'ye ulaşarak farklı sınıflardaki örnekleri doğru bir şekilde sınıflandırmadaki etkinliğinin altını çizmektedir. Bununla birlikte, NOMA'nın sağlıklı sınıfları tespit etmede diğer yöntemlere kıyasla nispeten düşük performans gösterdiğini belirtmek gerekir.


TBA, ayırt edici güç ve genel sınıflandırma doğruluğunda önemli güçler göstermektedir. En yüksek AUC değerine ulaşarak sınıflar arasında etkili bir şekilde ayırım yapma kabiliyetini gösterir. Ek olarak, TBA duyarlılık değerinde de daha üstündür. Ayrıca, TBA, NOMA'yı yakından takip ederek ikinci en yüksek GD'yi sergiler ve bu da farklı sınıflardaki örnekleri doğru bir şekilde sınıflandırmadaki etkinliğini vurgular.

NOMA ve TBA'nın bazı açılardan üstünlük göstermesine rağmen, diğer boyut indirgeme yöntemleri de önemli katkılarda bulunmaktadır. Örneğin, BBA yüksek AUC ve MKK değerleri elde ederek sınıflar arasında ayırım yapma ve dengeli sınıflandırmaları sürdürme konusundaki etkinliğini göstermektedir. Ayrıca TDA, AUC, MKK ve Kappa dahil olmak üzere çeşitli ölçümlerde rekabetçi performans göstermektedir. Ek olarak, SG güçlü bir duyarlılık sergileyerek sağlıklı örnekleri doğru bir şekilde belirleme kabiliyetini vurgulamaktadır.

Farklılıklarına rağmen, tüm yöntemler hesaplama işlemlerinde verimlilik göstermektedir (Boyut İndirgeme Süresi, BİS). TBA ve TDA nispeten daha verimli hesaplama performansı gösterirken, NOMA ve SG gibi diğer yöntemler daha uzun işlem süreleri sergilemektedir. Ayrıca, bu işlem sürelerindeki farklılıklar, ilgili

yöntemlerin sınıflandırma performansını artırma yeteneklerinin hesaplama yüküyle uyumlu olduğunu göstermektedir.

Özet olarak, her boyut indirgeme yöntemi belirli güçlü yönler sergilerken, NOMA ve TBA özellikle dengeli sınıflandırmaları sürdürme ve yüksek ayırt edici güç ile genel doğruluk sağlama konularında öne çıkar. Yöntem seçimi, kesinlik, duyarlılık, hesaplama verimliliği ve genel sınıflandırma performansı gibi özel gereksinimler ve değerlendirmeler tarafından belirlenmelidir



Şekil 4.20. İkili sınıf senaryolarına genişletilmiş ROC eğrileri, en iyi iki boyut indirgeme tekniği olan TBA ve NOMA'nın karşılaştırmalı etkinliğini görsel olarak göstermektedir. Bu eğriler, mikro-ortalama ROC Eğrisi Altındaki Alan (AUC) ve sınıfların şu şekilde tanımlandığı her bir sınıf için AUC değerleri hakkında fikir vermektedir: Hasta için 0 ve Sağlıklı için 1. Ayrıca, yanlış pozitif oranı ile doğru pozitif oranı arasındaki ilişkiyi temsil eden ROC eğrileri de gösterilmektedir.

Şekil 4.20, yenidoğan sağlık değerlendirmesi için HSG'de uygulanan en iyi iki boyut indirgeme tekniği olan TBA ve NOMA arasındaki bir karşılaştırmayı göstermektedir. x ekseninde, sağlıklı bir yenidoğanın hasta olarak yanlış sınıflandırılma olasılığını gösteren YPO yer almaktadır. y eksen, hasta bir yenidoğanı hasta olarak doğru şekilde tanımlama olasılığını gösteren DPO temsil eder. Bu durumda, sol tarafta TBA'yı temsil eden eğri, sağ tarafta NOMA'yı temsil eden eğriye kıyasla daha yüksek değerlere ulaşarak daha büyük bir AUC ile üstün performansa işaret etmektedir. Sonuç olarak, bu grafikler, yenidoğan sağlığı değerlendirme çalışmaları için HSG sınıflandırılmasında, ROC ve AUC ölçütlerine dayalı olarak, TBA'nın bir boyut indirgeme tekniği olarak NOMA'dan daha etkili olduğunu göstermektedir.

4.3.3. Tartışma

Bu tez çalışması, yenidoğan HSG verilerinin analizini ve sınıflandırmasını geliştirmeyi amaçlayan çeşitli boyut indirgeme tekniklerinin kapsamlı bir

değerlendirmesini sunmaktadır. Temel amaç, bu teknikleri kullanarak HSG veri kümelerinin doğasında bulunan karmaşıklığı azaltmak, sınıflandırma performansını artırmak ve kesin teşhisler sağlamaktır. Bunu başarmak için temel bir İSA modeli geliştirilmiş ve farklı boyut indirgeme yöntemlerinin etkinliğini değerlendirmek için kullanılmıştır.

Sonuçlar, farklı boyut indirgeme yöntemlerinin çeşitli performans ölçütleri üzerindeki etkisini göstermektedir. Özellikle, NOMA ve TBA gibi teknikler sırasıyla dengeli sınıflandırmaları sürdürme ve genel doğruluğu artırma konusunda öne çıkmaktadır. NOMA, dengeli sınıflandırmaları koruma ve güçlü uyumu sağlama konusunda önemli bir etkiye sahipken, TBA sınıflar arasında etkili bir şekilde ayırım yapma yeteneği sergilemektedir.

Öte yandan, BBA ve TDA gibi teknikler de belirli performans ölçütlerinde rekabetçi sonuçlar göstermektedir. Özellikle, BBA yüksek AUC ve MKK skorları gösterirken, TDA çeşitli metrikler arasında rekabetçi performans sergilemektedir. Bu, her bir yöntemin belirli koşullar altında etkili olduğunu ve kullanım senaryolarına bağlı olarak tercih edilebileceğini göstermektedir.

Ek olarak, tüm yöntemlerin hesaplama işlemlerini etkin bir şekilde gerçekleştirerek, gerçek dünya senaryolarında uygulanabilirliklerini ve verimliliklerini gösterdiği belirlenmiştir. En iyi hesaplama süresine sahip olanlar ise TBA ve TDA yöntemleridir.

Özetle, bu çalışma yenidoğan HSG verilerinin sınıflandırılması için çeşitli boyut indirgeme tekniklerinin performansını kapsamlı bir şekilde değerlendirerek araştırmacılara ve uygulayıcılara değerli bir rehberlik sağlamaktadır. Her bir teknik, en iyi sınıflandırma sonuçlarını elde etmek için özel gereksinimlere ve koşullara göre titizlikle seçilmelidir.

4.3.4. Sonuçların İncelenmesi

Tez kapsamında yapılan bu çalışmada, yenidoğan HSG verilerinin İSA ile sınıflandırılması için çeşitli boyut indirgeme tekniklerinin performansını kapsamlı bir şekilde değerlendirmiştir. Sonuçlar, NOMA ve TBA gibi tekniklerin sırasıyla dengeli sınıflandırmaları sürdürme ve genel doğruluğu artırma konusundaki etkinliğini

vurgulamaktadır. Diğer boyut indirgeme yöntemleri de belirli ölçütlerde rekabetçi performans sergilemektedir.

Bu bulgular, HSG verilerinin analizi ve sınıflandırılması için farklı boyut indirgeme yöntemleri kullanılmasının önemini vurgulamaktadır. Her yöntemin, belirli ihtiyaçlara ve hedeflere göre dikkatlice seçilmesi gerekmektedir. Bu çalışmadan elde edilen bilgiler, gelecekteki araştırma ve klinik uygulamalarda HSG veri analizi için daha etkili ve güvenilir yöntemlerin geliştirilmesine katkıda bulunabilir.

4.4. Araştırma Bulgularının Değerlendirilmesi

Tez kapsamında yapılan tüm çalışmalar, HSG analizinde yeni yaklaşımların ve İSA kullanımının önemini ele almaktadır. Uzaktan algılama, yeryüzü gözleme ve biyomedikal görüntüleme alanlarında yapılan çalışmalarla, HSG verilerinin analizindeki zorluklar ve çözümleri geniş bir açıdan değerlendirilmiştir. İSA tabanlı yeni modeller geliştirilmiş ve farklı alanlardaki HSG verilerinin analizleri yapılmıştır.

İSA'lar, HSG veri analizinde geleneksel ESA'lardan farklı bir yaklaşım sunmaktadır. Bu ağlar, involüsyon katmanlarının kullanılmasıyla verimli bir şekilde tasarlanmıştır. Uzaktan algılama ve yeryüzü gözleme alanında yapılan çalışmalarda öne sürülen IRSN modeli, HSG sınıflandırılmasında önemli bir adım olarak öne çıkmaktadır. Geleneksel konvolüsyon yöntemlerin aksine, involüsyon yaklaşımıyla, daha az parametre kullanarak daha etkili bir performans sergilemiştir. Modelin, spektral-uzamsal bilgileri daha iyi yakalayarak yüksek doğruluk oranları elde etmesi, HSG verilerinin analizinde yeni bir perspektif sunmuştur.

Biyomedikal alanında, İSA kullanımı önemli bir ilerleme sağlamaktadır. Geleneksel derin öğrenme modelleri, HSG ile elde edilen verilerin analizinde kullanılmaktadır. Ancak, bu modeller genellikle sınırlı spektral-uzamsal bilgi sağlamakta ve karmaşık yapıları nedeniyle hesaplama maliyetini yükseltmektedir. İSA'lar, bu tür zorlukları aşmak için etkili bir çözüm sunarlar. Özellikle, HSG analizi gibi çok boyutlu ve karmaşık veri türlerinin işlenmesinde İSA'ların kullanılması, daha iyi spektral-uzamsal özelliklerin yakalanmasını sağlar. Bu da biyomedikal görüntülerden daha kesin bilgilerin çıkarılmasına ve doğru teşhislerin yapılmasına olanak tanır. Ayrıca, İSA'ların daha az parametre kullanarak daha etkili bir performans sağlaması ve hesaplama maliyetini azaltması, gerçek zamanlı teşhislerin yapılmasını mümkün kılmaktadır. Bu durum, biyomedikal alanında İSA'ların kullanımının tıp

alanında önemli bir ilerleme sağladığını vurgular. Bu nedenle, İSA'ların biyomedikal araştırmalarda ve klinik uygulamalarda daha yaygın olarak kullanılması, gelecekteki sağlık hizmetlerinde büyük bir potansiyel sunmaktadır.

Bu tez kapsamında, biyomedikal görüntüleme alanında yapılan çalışmalar ve önerilen involüsyon tabanlı modeller (HarmonyNet, MC-I²Net ve HybridCISN), HSG teknolojisinin yenidoğan sağlık değerlendirmesindeki önemi vurgulanmaktadır. Bu modeller kullanılarak yapılan çalışmalar, yenidoğan hastalıkların erken teşhisinde ve tedavisinde önemli bir rol oynamıştır. Tez kapsamında yapılan çalışmalarda ilk olarak HarmonyNet modeli önerilmiş ve hasta ve sağlıklı yenidoğanlara ait HSG verilerinin tespit edilmesi hedeflenmiştir. HarmonyNet, yenidoğan sağlık durumunun otomatik olarak tespiti için involüsyon tabanlı bir yaklaşım kullanarak oldukça etkili bir model olarak öne çıkmıştır. Model, yüksek doğruluk oranları ve düşük hesaplama maliyeti ile dikkat çekmektedir. Özellikle düşük eğitim veri yüzdelerinde bile hasta ve sağlıklı yenidoğanların doğru bir şekilde tespit edilmesini başarmıştır. Benzer şekilde, MC-I²Net modeli de involüsyon tabanlı bir derin öğrenme modeli olarak yenidoğan hastalıkların (5 farklı hastalık ve kontrol grubu) teşhisi için dikkat çekmektedir. Yüksek doğruluk oranlarına sahip olmasının yanı sıra, düşük parametre sayısı ile de dikkat çeken bu model, başlangıç modüllerini ve çok ölçekli bağlamsal yapılarının kullanımıyla performansını artırmaktadır. Ayrıca, 2B/3B konvolüsyon ve involüsyon katmanları ile birlikte geliştirilen HybridCISN modeli hem HSG verileri hem de kan biyobelirteçleri kullanılarak yenidoğan hastalıkların teşhisinde daha etkili bir yaklaşım sunmaktadır. İnvolüsyon katmanlarının önemli bir rol oynadığı bu modelde, spektrum verileri ile kan biyobelirteçlerinin birleştirilmesiyle elde edilen sonuçların diğer sınıflandırma yöntemlerine kıyasla daha yüksek doğruluk oranlarına sahip olduğu görülmektedir.

Ayrıca tez kapsamında, boyut indirgeme tekniklerinin HSG veri analizindeki önemi ve yeri araştırılmıştır. Bu bağlamda farklı boyut indirgeme yöntemleri kullanılarak İSA ile sınıflandırmalar yapılmış ve en etkin boyut indirgeme yönteminin belirlenmesi hedeflenmiştir. Bu kapsamda NOMA ve TBA gibi tekniklerin, HSG verilerin analizinde önemli avantajlar sağladığı tespit edilmiştir. Ayrıca, İSA modellerinin bu analizde nasıl kullanılabileceği üzerinde de durulmuş ve bu yöntemlerin yenidoğan sağlık değerlendirmesindeki potansiyelini vurgulanmıştır.

Yapılan analizler, HSG verilerin karmaşıklığının azaltılmasının ve analizinin daha etkili hale getirilmesinin ne kadar kritik olduğunu göstermiştir.

İSA'ların boyut indirgeme teknikleriyle entegrasyonu önemli bir araştırma alanı olarak ortaya çıkmaktadır. Boyut indirgeme tekniklerinin İSA'larla birleştirilmesi, HSG verilerin daha etkili bir şekilde analiz edilmesini sağlamıştır. Bu, daha hassas sınıflandırmaların elde edilmesi ve hesaplama maliyetinin azaltılması gibi avantajlar sunmuştur.

İnvölüsyon tabanlı modellerde, konvolüsyon tabanlı modellere kıyasla daha uzun çıkarım süreleri, NVIDIA'nın CUDA teknolojisi sayesinde konvolüsyonel işlemleri optimize etmesinden kaynaklanmıştır. CUDA teknolojisi, özellikle GPU'ların konvolüsyonel işlemler gibi hesaplama yoğun görevlerde etkin bir şekilde kullanılmasını sağlar. Ancak, invölüsyon tabanlı modellerin nispeten daha yüksek çıkarım süreleri, bu optimize edilmiş çekirdeklerin kullanılmaması veya belirli GPU mimarileriyle uyumluluk sorunlarından kaynaklanmaktadır. Gelecekte, invölüsyon tabanlı modellerin çıkarım sürelerinde iyileşme bekleniyorsa, bu iyileştirmeler NVIDIA'nın CUDA teknolojisini içeren geliştirmelere bağlı olacaktır. Bu şekilde, invölüsyon tabanlı modellerin performansı optimize edilip GPU için optimize edilmiş metodolojilerle uyumlu hale getirilebilir.

Bu ayrıntılı tartışma, HSG verilerinin analizinde karşılaşılan zorlukları ele alırken, İSA gibi yeni yaklaşımların potansiyelini vurgulamaktadır. Uzaktan algılama, yeryüzü gözleme ve biyomedikal görüntüleme alanlarında İSA'ların önemi oldukça büyüktür. İSA'lar, uzaktan algılama ile elde edilen HSG verilerinin analizinde ve biyomedikal görüntüleme alanında geleneksel yöntemlerden farklı bir yaklaşım sunarak daha etkili sonuçlar elde etmektedirler. Bu, çeşitli uygulama alanlarında daha kesin sonuçların alınmasını sağlar. Gelecekteki çalışmalar, bu bulguları ve önerileri temel alarak uzaktan algılama, yeryüzü gözleme ve biyomedikal alanlarda daha ileri adımlar atmaya yönelebilirler. Ayrıca bu çalışmaların, yenidoğan sağlık hizmetlerinde erken teşhis ve tedavi için önemli bir etki yapabileceği düşünülmektedir.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

5.1.1. Ana Bulgular

Tez çalışması, İSA'ların HSG veri analizindeki etkinliğini incelemek ve değerlendirmek için iki ayrı alanda yapılmış farklı çalışmaları ele almıştır. Çalışmaların incelenmesi sonucunda aşağıdaki ana bulgulara ulaşılmıştır:

- 1) Geleneksel konvolüsyon yapısı, görüntünün herhangi bir konumunda aynı şekilde çalışan uzamsal-agnostik bir yapıya sahiptir. Bu sebeple çekirdeklerin farklı uzamsal konumlara göre çeşitli görsel kalıplara uyum sağlama yeteneğini kısıtlar. Aynı zamanda, kanal-spesifik özelliklerine dayalı bir yapıya sahip olması, çekirdeklerin esnekliğini artırırken hesaplama karmaşıklığını da artırır. Bu sınırlamaları aşmak ve daha etkili bir analiz yöntemi sunmak amacıyla HSG verilerin analizinde involüsyon yapısı kullanılmıştır. Bu yaklaşım, konvolüsyon işleminden farklı olarak simetrik olarak ters içsel özelliklere sahip olduğu için uzamsal-spesifik ve kanaldan-bağımsız bir işlem sunmaktadır, bu da daha geniş bir uzamsal modelleme yeteneği sağlamakta ve hesaplama karmaşıklığını azaltmaktadır. Involüsyon katmanlarını içeren İSA'lar, öz-dikkat mekanizmaları ile hesaplama maliyetlerini azaltarak modelin ayırt edici kapasitesini artırmış ve HSG verilerini analizinde potansiyel bir araç olarak değerlendirilmiştir. Bu bağlamda HSG verileri analiz etmek için özgün İSA modelleri geliştirilmiştir.
- 2) Tez kapsamında farklı uygulama alanları için geliştirilen involüsyon tabanlı modellerin (IRSN, HarmonyNet, MC-I²Net ve HybridCISN), geleneksel konvolüsyon tabanlı modellere kıyasla daha yüksek doğruluk oranları ve daha düşük hesaplama maliyetleri sağladığı gözlemlenmiştir. Bu modeller, özellikle HSG gibi karmaşık veri türlerini işlerken daha etkili bir performans sergilemektedir. Ayrıca, bu modellerin spektral-uzamsal bilgileri daha iyi yakaladığı, az sayıda parametre kullanarak önemli ölçüde geliştirilmiş sınıflandırma sonuçları elde ettiği tespit edilmiştir. Yapılan çalışmalarda, model performanslarını maksimize etmek için involüsyon katmanlarındaki hiper parametreler olan G ve r 'nin dikkatle seçilmesini vurgulamaktadır;

burada en etkili G değeri olarak 16, en uygun r değeri ise 4 veya 8 olarak belirlenmiştir.

- 3) İncelenen boyut indirgeme tekniklerinin, HSG veri analizinde önemli bir rol oynadığı ve İSA ile birleştirildiğinde daha etkili sonuçlar elde edildiği belirlenmiştir. Bu teknikler, karmaşık HSG veri setlerinin boyutunu azaltarak analiz sürecini iyileştirirken, İSA'lar ile birleştirildiğinde daha hassas sınıflandırma ve tanıma sonuçları elde edilmiştir. Bu yaklaşım, özellikle HSG spektral-uzamsal özelliklerini daha iyi yakalayarak, doğru spektrum tespitlerinin yapılmasına ve yenidoğan sağlık durumlarının daha etkili bir şekilde değerlendirilmesine katkıda bulunmuştur. Ayrıca, boyut indirgeme tekniklerinin, HSG veri analizindeki önemi ve avantajları üzerinde durulmuş; NOMA ve TBA gibi tekniklerin etkili olduğu belirlenmiştir.
- 4) Boyut indirgeme aşamasında kullanılan temel bileşen sayısının artmasıyla model performansı genellikle artmaktadır, ancak daha yüksek doğruluk için daha fazla veri ve hesaplama gücü gerekmektedir. Bu sebeple, model karmaşıklığı ve veri seti özellikleri en uygun temel bileşen sayısının belirlenmesinde önemlidir.
- 5) İSA'lar, uzaktan algılama ve yeryüzü gözlemi gibi alanlarda etkin bir şekilde kullanılarak daha hassas sonuçlar elde edilmesini sağlamıştır. İnvolüsyonel ağlar, HSG verilerin analizinde daha iyi spektral-uzamsal özelliklerin yakalanmasına yardımcı olmuştur. Bu, çeşitli uygulama alanlarında, özellikle doğal afet izleme, ormansızlaşma tespiti ve kentsel planlama gibi konularda önemli bir potansiyele sahip olduklarını göstermektedir.
- 6) Yenidoğan sağlık değerlendirmesi için yapılan tüm çalışmalar, İSA'ların bu alanda önemli bir potansiyele sahip olduğunu göstermektedir. Bu ağlar, erken teşhis ve tedavi süreçlerine katkıda bulunabilecek düşük maliyetli, yüksek doğruluklu ve etkili araçlar olarak öne çıkmaktadır. HSG ile birlikte İSA'lar, özellikle yenidoğan hastalıkların erken teşhisi ve takibi konularında, daha hassas ve hızlı sonuçlar elde edilmesini sağlayarak sağlık hizmetlerinde önemli bir rol oynamaktadır.

5.1.2. Tezin Katkıları

Bu tez çalışması, HSG veri analizi alanında İSA'ların kullanımının önemini vurgulamakta ve aşağıdaki katkıları sağlamaktadır:

- 1) İSA tabanlı modellerin, geleneksel yöntemlerle kıyaslandığında daha etkili ve verimli olduğunu göstererek, HSG veri analizinde yeni bir perspektif sunmaktadır. Bu perspektif, karmaşık veri setlerini işleme ve daha doğru sonuçlar elde etme yeteneğini vurgulamaktadır.
- 2) Boyut indirgeme tekniklerinin HSG veri analizindeki önemi ve etkinliği detaylı bir şekilde incelenmiş ve İSA ile birleştirildiğinde daha iyi sonuçlar elde edildiği gösterilmiştir. Ayrıca, NOMA ve TBA gibi boyut indirgeme tekniklerinin HSG veri analizindeki rolü, bu alandaki araştırmalara yeni bir bakış açısı sunmuştur.
- 3) İSA tabanlı modeller, HSG veri analizinde veriyi dikkate alarak oluşturulan çekirdeklerle daha iyi spektral-uzamsal özelliklerin yakalanmasına yardımcı olmuştur. Bu da uzaktan algılama, yeryüzü gözlemi ve biyomedikal görüntüleme gibi alanlarda daha hassas sonuçların elde edilmesini sağlamakta ve bu teknolojilerin uygulanabilirliğini artırmaktadır.
- 4) Yapılan çalışmalar, İSA'ların yenidoğan sağlık değerlendirmesinde kullanılabilirliğini göstererek, bu alandaki araştırmalara önemli katkılar sağlamıştır. Bu, yenidoğanların sağlık durumunu izlemek, erken teşhis ve tedavi süreçlerini iyileştirmek için İSA tabanlı HSG analizinin kullanımının yaygınlaşmasını teşvik etmektedir.
- 5) Bu tez çalışması, biyomedikal HSG verileri ve İSA'ların birlikte kullanıldığı yeni bir çerçeve sunmuştur. Literatürde biyomedikal görüntüleme alanında HSG ve İSA'nın birlikte kullanıldığı herhangi bir çalışmanın olmaması ve bu çalışma kapsamında özel bir veri setinin oluşturulması, HSG ve İSA ile bu veri seti üzerinde gerçekleştirilen çalışmalar, bu yeni yaklaşımın klinik uygulamalarda ve araştırma alanında etkin bir yaklaşım olduğunu göstermiştir.

5.2. Öneriler

5.2.1. Gelecekteki Araştırma Önerileri

Bu tez çalışmasından elde edilen bulgular ışığında, gelecekteki araştırmacılara aşağıdaki konularda odaklanmaları önerilmektedir:

- 1) İSA tabanlı modellerin daha derinlemesine incelenmesi ve optimize edilmesi, HSG veri analizi alanında daha iyi performans elde etmek için önemlidir. Bu bağlamda, yeni İSA modellerinin probleme özgü olarak geliştirilmesi sağlanabilir. Ayrıca, 3B involüsyon kavramının önerilmesi ve HSG veri analizinde kullanılması, HSG verilerini analiz etmede daha etkin sonuçlar ortaya koyabilir. Özellikle, yeni nesil derin öğrenme tekniklerinin ve öğrenme algoritmalarının HSG verilerinin karmaşıklığını ele alması ve model performansını artırması için araştırılması önerilmektedir.
- 2) İSA'ların farklı uygulama alanlarında kullanımı ve etkinliği daha fazla araştırılmalıdır. Bu, HSG teknolojisinin genişletilmesine katkı sağlayabilir ve çeşitli sektörlerde daha etkili çözümlerin geliştirilmesine olanak tanır. Özellikle, tarım, çevre yönetimi, şehir planlaması, sağlık hizmetleri gibi farklı alanlarda İSA tabanlı HSG analizinin potansiyelini keşfetmek için multidisipliner çalışmalara odaklanılmalıdır.
- 3) Daha etkili boyut indirgeme teknikleri geliştirilerek, HSG veri analizindeki hesaplama maliyeti azaltılabilir ve sınıflandırma performansı artırılabilir. Bu, özellikle büyük ölçekli HSG veri setlerinin analizinde karşılaşılan zorlukları hafifletmek için önemlidir. Yeni boyut indirgeme yöntemlerinin yanı sıra, mevcut tekniklerin de optimize edilerek daha iyi sonuçlar elde edilmesi için çalışılmalıdır. Ayrıca, boyut indirgeme tekniklerinin farklı HSG veri tipleri ve uygulama senaryoları için uygunluğunun değerlendirilmesi gerekmektedir.

5.2.2. Pratik Uygulama Alanları

İSA'ların HSG veri analizi alanındaki pratik uygulama alanları şunları içerebilir:

- 1) Tıbbi görüntüleme alanında hastalık teşhisi ve tedavisi için kullanılabilir. Özellikle yenidoğan sağlık değerlendirmesinde, İSA tabanlı HSG analizi, erken teşhis ve tedavi süreçlerini iyileştirebilir. Bu, düşük maliyetli ve etkili araçlarla yenidoğanların sağlık durumunu izlemeyi ve gerektiğinde müdahale etmeyi sağlayarak bebek ölümlerini azaltabilir.
- 2) İSA'lar ile HSG analizi, uzaktan algılama alanında doğal afetlerin izlenmesi, ormansızlaşma tespiti ve kentsel planlama gibi konularda kullanılabilir, bu da kentsel ve doğal ortamların daha iyi yönetilmesine yardımcı olabilir.
- 3) Tarım alanında, İSA'larla desteklenmiş HSG analizi, tarım arazilerinin sağlığını izlemek, hastalık ve zararlıları tespit etmek için kullanılabilir. Bu, tarım verimliliğini artırarak gıda güvenliği ve arazi kullanımı planlamasına katkı sağlayabilir.
- 4) Şehir planlamasında, HSG verilerinin analizi, kentsel gelişimi izlemek, yeşil alanları korumak, altyapı projelerini yönlendirmek için önemlidir. İSA'lar, kentsel alanlardaki değişiklikleri izlemek ve optimize etmek için kullanılabilir.

Sonuç olarak, HSG verilerinin analizi için İSA'ların kullanımı, geniş bir yelpazede pratik uygulama alanlarına sahiptir ve birçok sektörde önemli katkılar sağlayabilir. Bu teknolojilerin birleşimi, çevre izleme, tarım, sağlık hizmetleri, kentsel planlama, doğal afet yönetimi ve daha birçok alanda kullanılabilir. Özellikle, İSA'ların spektral-uzamsal özellikleri daha etkin bir şekilde yakalayabilmesi ve karmaşık veri setlerini işleyebilmesi, HSG verilerinin analizinde yeni bir perspektif sunar. Böylece daha hassas sonuçların elde edilmesi, verimliliğin artırılması ve karar verme süreçlerinin iyileştirilmesi sağlanabilir. Gelecekteki araştırmalar, İSA tabanlı HSG analizinin optimize edilmesi ve farklı sektörlerdeki kullanım potansiyelinin daha detaylı bir şekilde incelenmesi üzerine odaklanabilir, böylece bu teknolojilerin daha geniş bir kitleye yayılması ve toplumsal fayda sağlaması mümkün olabilir.

KAYNAKLAR

- Aburaed, N., Alkhatib, M.Q., Marshall, S., Zabalza, J., ve Al Ahmad, H., 2023, A review of spatial enhancement of hyperspectral remote sensing imaging techniques, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 2275-2300, DOI: 10.1109/JSTARS.2023.3242048
- Ahmad, M., Khan, A.M., Mazzara, M., Distefano, S., Ali, M., ve Sarfraz M.S., 2020, A fast and compact 3-D CNN for hyperspectral image classification, *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5, DOI: 10.1109/LGRS.2020.3043710
- Al-Masni, M.A., ve Kim, D.H., 2021, CMM-Net: Contextual multi-scale multi-level network for efficient biomedical image Segmentation, *Scientific reports*, 11:1, 1-18, <https://doi.org/10.1038/s41598-021-89686-3>
- Amelio, A., Bonifazi, G., Cauteruccio, F., Corradini, E., Marchetti, M., Ursino, D., ve Virgili, L., 2023, Representation and compression of Residual Neural Networks through a multilayer network based approach, *Expert Systems with Applications*, 215, 1-19, <https://doi.org/10.1016/j.eswa.2022.119391>
- Archibald, R., ve Fann, G., 2007, Feature selection and classification of hyperspectral images with support vector machines, *IEEE Geoscience and remote sensing letters*, 4:4, 674-677, DOI: 10.1109/LGRS.2007.905116
- Asiri, A.A., Shaf, A., Ali, T., Zafar, M., Pasha, M.A., Irfan, M., Alqahtani, S., Alghamdi, A.J., Alghamdi, A.H., Alshamrani, A.F.A., Aleylyani, M. ve Alamri, S., 2023, Enhancing Brain Tumor Diagnosis: Transitioning From Convolutional Neural Network to Involutional Neural Network, *IEEE Access*, 11, 123080-123095, DOI: 10.1109/ACCESS.2023.3326421
- Atienza-Navarro I., Alves-Martinez, P., Lubian-Lopez, S., ve Garcia-Alloza, M., 2020, Germinal matrix-intraventricular hemorrhage of the preterm newborn and preclinical models: inflammatory considerations, *International journal of molecular sciences*, 21:21, 1-24, <https://doi.org/10.3390/ijms21218343>
- Audebert, N., Le Saux, B., ve Lefèvre, S., 2019, Deep learning for classification of hyperspectral data: A comparative review, *IEEE geoscience and remote sensing magazine*, 7:2, 159-173, DOI: 10.1109/MGRS.2019.2912563
- Ayala, L., Isensee, F., Wirkert, S.J., Vemuri, A.S., Maier-Hein, K.H., Fei, B., ve Maier-Hein, L., 2022, Band selection for oxygenation estimation with multispectral/hyperspectral imaging, *Biomedical Optics Express*, 13:3, 1224-1242, <https://doi.org/10.1364/BOE.441214>
- Bejani M.M., ve M. Ghatee, 2021, A systematic review on overfitting control in shallow and deep neural networks, *Artificial Intelligence Review*, 54:8, 6391-6438, <https://doi.org/10.1007/s10462-021-09975-1>

- Boardman, J.W., 1989, Inversion of imaging spectrometry data using singular value decomposition, in *12th Canadian Symposium on Remote Sensing Geoscience and Remote Sensing Symposium*, Vancouver, BC, Canada, 4, 2069-2072, DOI: 10.1109/IGARSS.1989.577779
- Campbell, J.M., Mahbub, S.B., Habibalahi, A., Agha, A., Handley, S., Anwer, A.G., ve Goldys, E.M., 2023, Clinical applications of non-invasive multi and hyperspectral imaging of cell and tissue autofluorescence beyond oncology, *Journal of biophotonics*, 16:4, 1-14, <https://doi.org/10.1002/jbio.202200264>
- Cihan, M., 2020, Hiperspektral görüntüleme yöntemi kullanılarak yenidoğan sağlık durumlarının derin öğrenme metotları ile sınıflandırılması [Classification of health status of neonates with deep learning methods using hyperspectral imaging], Master's thesis, Konya Technical University.
- Cihan, M., Ceylan, M., Soylu, H., ve Konak, M., 2022, Fast evaluation of unhealthy and healthy neonates using hyperspectral features on 700-850 Nm wavelengths, ROI extraction, and 3D-CNN, *IRBM*, 43:5, 362-371, <https://doi.org/10.1016/j.irbm.2021.06.009>
- Cihan, M., ve Ceylan, M., 2023, Hyperspectral imaging-based cutaneous wound classification using neighbourhood extraction 3D convolutional neural network, *Biomedical Engineering/Biomedizinische Technik*, 68:4, 427-435, <https://doi.org/10.1515/bmt-2022-0179>
- Cihan, M., Çevik, M., Yılmaz, N., Konak, M., Soylu, H., ve Ceylan, M., 2023, Neonatal Hiperspektral Görüntü Sınıflandırması için 3 Boyutlu Evrişimli Sinir Ağları ile Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi, *International Journal of Multidisciplinary Studies and Innovative Technologies*, 7:2, 74-83, DOI: 10.36287/ijmsit.7.2.6
- Cihan, M., ve Ceylan, M., 2024, IRSN: Involutional Residual Spectral Network for Hyperspectral Image Classification, *IEEE Geoscience and Remote Sensing Letters*, 21, 1-5, DOI: 10.1109/LGRS.2023.3341497
- Collins, T., Bencteux, V., Benedicenti, S., Moretti, V., Mita, M.T., Barbieri, V., Rubichi, F., Altamura, A., Giaracuni, G., Marescaux, J., Hostettler, A., Diana, M., Viola, M.G., ve Barberio, M., 2022, Automatic optical biopsy for colorectal cancer using hyperspectral imaging and artificial neural networks, *Surgical Endoscopy*, 36:11, 8549–8559, <https://doi.org/10.1007/s00464-022-09524-z>
- Datta, D., Mallick, P.K., Bhoi, A.K., Ijaz, M.F., Shafi, J., Choi, J., 2022, Hyperspectral image classification: Potentials, challenges, and future directions, *Computational Intelligence and Neuroscience*, special issue, 1-36, <https://doi.org/10.1155/2022/3854635>
- De Luca D., 2021, Respiratory distress syndrome in preterm neonates in the era of precision medicine: A modern critical care-based approach, *Pediatrics & Neonatology*, 62, 3-9, <https://doi.org/10.1016/j.pedneo.2020.11.005>

- Delibasoglu, I., ve Cetin, M., 2020, Improved U-Nets with inception blocks for building detection, *Journal of Applied Remote Sensing*, 14:4, 044512-044512, <https://doi.org/10.1117/1.JRS.14.044512>.
- Devassy B.M., ve S. George, 2020, Dimensionality reduction and visualisation of hyperspectral ink data using t-SNE, *Forensic science international*, 311, 1-9, <https://doi.org/10.1016/j.forsciint.2020.110194>
- Ding, Y., Zhao, X., Zhang, Z., Cai, W., ve Yang, N., 2021, Multiscale graph sample and aggregate network with context-aware learning for hyperspectral image classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4561-4572, DOI: 10.1109/JSTARS.2021.3074469
- Firat H., Asker, M.E., ve Hanbay, D., 2022, Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN, *Remote Sensing Applications: Society and Environment*, 25, 1-18, <https://doi.org/10.1016/j.rsase.2022.100694>
- Firat, H., Asker, M.E., Bayındır, M.İ., ve Hanbay, D., 2023, Hybrid 3D/2D complete inception module and convolutional neural network for hyperspectral remote sensing image classification, *Neural Processing Letters*, 55:2, 1087-1130, <https://doi.org/10.1007/s11063-022-10929-z>
- Fu, H., Zhang, A., Sun, G., Ren, J., Jia, X., Pan, Z., ve Ma, H., 2022, A novel band selection and spatial noise reduction method for hyperspectral image classification, *IEEE transactions on geoscience and remote sensing*, 60, 1-13, DOI: 10.1109/TGRS.2022.3189015
- Gao, H., Feng, H., Zhang, Y., Xu, S., ve Zhang, B., 2023, AMSSE-Net: Adaptive Multiscale Spatial-Spectral Enhancement Network for Classification of Hyperspectral and LiDAR Data, *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-17, DOI: 10.1109/TGRS.2023.3331486
- Gao, J., Zhao, L., Li, J., Deng, L., Ni, J., ve Han, Z., 2021, Aflatoxin rapid detection based on hyperspectral with 1D-convolution neural network in the pixel level, *Food Chemistry*, 360, 1-8, <https://doi.org/10.1016/j.foodchem.2021.129968>
- GIC, 2024, Kamuya Açık Uzaktan Algılama ve Yeryüzü Gözleme Veri Setleri [https://ehu.eus/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](https://ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes) [Erişim Tarihi: 01.05.2024].
- Grigoriou, A., Yoon, J., ve Bohndiek, S.E., 2020, Deep learning applied to hyperspectral endoscopy for online spectral classification, *Scientific Reports*, 10:1, 1-10, <https://doi.org/10.1038/s41598-020-60574-6>
- Guo, B., Gunn, S.R., Damper, R.I., ve Nelson, J.D., 2008, Customizing kernel functions for SVM-based hyperspectral image classification, *IEEE Transactions on Image Processing*, 17:4, 622-629, DOI: 10.1109/TIP.2008.918955

- Halicek, M., Fabelo, H., Ortega, S., Callico, G. M., ve Fei, B., 2019, In-vivo and ex-vivo tissue analysis through hyperspectral imaging techniques: revealing the invisible features of cancer, *Cancers*, 11:6, 1-30, <https://doi.org/10.3390/cancers11060756>
- Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C., ve Xu, C., 2020, GhostNet: More features from cheap operations, in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 1580–1589.
- Haque M.R., ve S. Z. Mishu, 2019, Spectral-spatial feature extraction using PCA and multi-scale deep convolutional neural network for hyperspectral image classification, in *2019 22nd International Conference on Computer and Information Technology (ICCIT)*, Dhaka, Bangladesh, 1-6, DOI: 10.1109/ICCIT48885.2019.9038385
- He, M., Li, B., ve Chen, H., 2017, Multi-scale 3D deep convolutional neural network for hyperspectral image classification, in *2017 IEEE International Conference on Image Processing*, Beijing, China, 3904-3908, DOI: 10.1109/ICIP.2017.8297014
- Hede, S.V., DeVore, G., Satou, G., ve Sklansky, M., 2020, Neonatal management of prenatally suspected coarctation of the aorta, *Prenatal diagnosis*, 40:8, 942-948, <https://doi.org/10.1002/pd.5696>
- Hoeser, T., Bachofer, F., ve Kuenzer, C., 2020, Object detection and image segmentation with deep learning on Earth observation data: A review—Part II: Applications, *Remote Sensing*, 12:18, 1-43, <https://doi.org/10.3390/rs12101667>
- Hossain, M.M., ve Hossaini M.A., 2019, Feature reduction and classification of hyperspectral image based on multiple kernel PCA and deep learning, in *2019 IEEE International Conference on Robotics, Automation, Artificial-intelligence and Internet-of-Things (RAAICON)*, Dhaka, Bangladesh, 141-144, DOI: 10.1109/RAAICON48939.2019.59
- Hsieh, T.H., ve Kiang, J.F., 2020, Comparison of CNN algorithms on hyperspectral image classification in agricultural lands, *Sensors*, 20:6, 1-17, <https://doi.org/10.3390/s20061734>
- Hu, T., Yuan, J., Wang, X., Yan, C., ve Ju, X., 2022, Spectral-Spatial Features Extraction of Hyperspectral Remote Sensing Oil Spill Imagery Based on Convolutional Neural Networks, *IEEE Access*, 10, 127969-127983, DOI: 10.1109/ACCESS.2022.3194260
- Hu, Y., Ma, B., Wang, H., Zhang, Y., Li, Y., ve Yu, G., 2023, Detecting different pesticide residues on Hami melon surface using hyperspectral imaging combined with 1D-CNN and information Fusion, *Frontiers in Plant Science*, 14, 1-15, <https://doi.org/10.3389/fpls.2023.1105601>
- Huang M., Q. Zhu, B. Wang, ve R. Lu, 2012, Analysis of hyperspectral scattering images using locally linear embedding algorithm for apple mealiness

- classification, *Computers and electronics in agriculture*, 89, 175-181, <https://doi.org/10.1016/j.compag.2012.09.003>
- Huang, W., He, W., Liao, S., Xu, Z., ve Yan, J., 2023, Efficient SpectralFormer for Hyperspectral Image Classification, *Digital Signal Processing*, 143, 1-13, <https://doi.org/10.1016/j.dsp.2023.104237>
- Huang, J., He, H., Lv, R., Zhang, G., Zhou, Z., ve Wang, X., 2022, Non-destructive detection and classification of textile fibres based on hyperspectral imaging and 1D-CNN, *Analytica Chimica Acta*, 1224, 1-10, <https://doi.org/10.1016/j.aca.2022.340238>
- Huang, Q., Li, W., ve Xie, X., 2018, Convolutional neural network for medical hyperspectral image classification with kernel Fusion, in *Proceedings of the BIBE 2018; International Conference on Biological Information and Biomedical Engineering*, Shanghai, China, 1-4.
- Huang, Q., Li, W., Zhang, B., Li, Q., Tao, R., ve Lovell, N.H., 2020, Blood Cell Classification Based on Hyperspectral Imaging With Modulated Gabor and CNN, *IEEE Journal of Biomedical and Health Informatics*, 24, 160–170, DOI: 10.1109/JBHI.2019.2905623
- Huang, T., Shi, J., Li, J., Wang, J., Du, J., ve Shi, J., 2024, Involution Transformer based U-Net for Landmark Detection in Ultrasound Images for Diagnosis of Infantile DDH, *IEEE Journal of Biomedical and Health Informatics*, Early Access, 1-13, DOI: 10.1109/JBHI.2024.3390241
- Hyvärinen A., 2013, Independent component analysis: recent advances, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 371, 1-19, <https://doi.org/10.1098/rsta.2011.0534>
- Jaiswal, G., Sharma, A., ve Yadav, S.K., 2021, Critical insights into modern hyperspectral image applications through deep learning, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 11:6, 1-22, <https://doi.org/10.1002/widm.1426>
- Jolliffe I.T., 2002, *Principal Component Analysis for Special Types of Data*, Springer New York, 338-372, https://doi.org/10.1007/0-387-22440-8_13
- Kennedy, H.L., 2020, Improving the frequency response of Savitzky-Golay filters via colored-noise models, *Digital Signal Processing*, 102, 1-9, <https://doi.org/10.1016/j.dsp.2020.102743>
- Khan, M.J., Khan, H.S., Yousaf, A., Khurshid, K., ve Abbas, A., 2018, Modern trends in hyperspectral image analysis: A review, *IEEE Access*, 6, 14118-14129, DOI: 10.1109/ACCESS.2018.2812999
- Kiani, S., Yazdanpanah, H., ve Feizy, J., 2023, Geographical origin differentiation and quality determination of saffron using a portable Hyperspectral imaging system,

Infrared Physics & Technology, 131, 1-8,
<https://doi.org/10.1016/j.infrared.2023.104634>

- Klinke, M., Wiskemann, H., Bay, B., Schäfer, H.J., Raluy, L.P., Reinshagen, K., ve Boettcher, M., 2021, Cardiac and inflammatory necrotizing enterocolitis in newborns are not the same entity, *Frontiers in Pediatrics*, 8, 1-10, <https://doi.org/10.3389/fped.2020.593926>
- Kraemer, H.C., 1980, Extension of the kappa coefficient, *Biometrics*, 36:2, 207-216, <https://doi.org/10.2307/2529972>
- Lee, H., ve Kwon, H., 2017, Going deeper with contextual CNN for hyperspectral image classification, *IEEE Transactions on Image Processing*, 26:10, 4843-4855, DOI: 10.1109/TIP.2017.2725580
- Li, D., Hu, J., Wang, C., Li, X., She, Q., Zhu, L., Zhang, T., ve Chen, Q., 2021, Involution: Inverting the inherence of convolution for visual recognition, in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Nashville, TN, USA, 12321-12330.
- Li, K., Dai, D., ve Van Gool, L., 2023, Jointly Learning Band Selection and Filter Array Design for Hyperspectral Imaging, In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, Waikoloa, HI, USA, 6384-6394.
- Li, Y., Deng, L., Yang, X., Liu, Z., Zhao, X., Huang, F., Zhu, S., Chen, X., Chen, Z., ve Zhang, W., 2019, Early diagnosis of gastric cancer based on deep learning combined with the spectral-spatial classification method, *Biomedical Optics Express*, 10, 4999-5014, <https://doi.org/10.1364/BOE.10.004999>
- Liang, H., ve Li, Q., 2016, Hyperspectral imagery classification using sparse representations of convolutional neural network features, *Remote Sensing*, 8:2, 1-16, <https://doi.org/10.3390/rs8020099>
- Liu, D., Li, J., Yuan, Q., Zheng, L., He, J., Zhao, S., ve Xiao, Y., 2023, An efficient unfolding network with disentangled spatial-spectral representation for hyperspectral image super-resolution, *Information Fusion*, 94, 92-111, <https://doi.org/10.1016/j.inffus.2023.01.018>
- Liu, H., Yu, T., Hu, B., Hou, X., Zhang, Z., Liu, X., Liu, J., Wang, X., Zhong, J., Tan, X., Xia, S., ve Qian, B., 2021, Uav-borne hyperspectral imaging remote sensing system based on acousto-optic tunable filter for water quality monitoring, *Remote Sensing*, 13:20, 1-32, <https://doi.org/10.3390/rs13204069>
- Liu, J., Kurepa, D., Feletti, F., Alonso-Ojembarrena, A., Lovrenski, J., Copetti, R., Sorantin, E., Rodriguez-Fanjul, J., Katti, K., Aliverti, A., Zhang, H., Hwang, M., Yeh, T.F., Hu, C.-B., Feng, X., Qiu, R.-X., Chi, J.-H., Shang, L.-L., Lyu, G.-R., He, S.-Z., Chai, Y.-F., Qiu, Z.-J., Cao, H.-Y., Gao, Y.-Q., Ren, X.-L., Guo, G., Zhang, L., Liu, Y., Fu, W., Lu, Z.-L., ve Li, H.-L., 2020, International expert consensus and recommendations for neonatal pneumothorax ultrasound diagnosis

- and ultrasound-guided thoracentesis procedure, *Journal of Visualized Experiments*, 157, 1-10, DOI: 10.3791/60836
- Lupu, D., Necoara, I., Garrett, J.L., ve Johansen, T. A., 2022, Stochastic higher-order independent component analysis for hyperspectral dimensionality reduction, *IEEE Transactions on Computational Imaging*, 8, 1184-1194, DOI: 10.1109/TCI.2022.3230584
- Lv, Z., Dong, X.M., Peng, J., ve Sun, W., 2022, ESSINet: Efficient spatial-spectral interaction network for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-15, DOI: 10.1109/TGRS.2022.3162721
- Makantasis, K., Karantzalos, K., Doulamis, A., ve Doulamis, N., 2015, Deep supervised learning for hyperspectral data classification through convolutional neural networks, in *2015 IEEE international geoscience and remote sensing symposium*, Milan, Italy, 4959-4962, DOI: 10.1109/IGARSS.2015.7326945
- Manni, F., Fonollà, R., van der Sommen, F., Zinger, S., Shan, C., Kho, E., de Koning, S.B., Ruers, T., ve de With, P.H., 2020, Hyperspectral imaging for colon cancer classification in surgical specimens: Towards optical biopsy during image-guided surgery, in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Montreal, QC, Canada, 1169–1173, DOI: 10.1109/EMBC44109.2020.9176543
- Masson, J.F., Biggins, J.S., ve Ringe, E., 2023, Machine learning for nanoplasmonics, *Nature Nanotechnology*, 18:2, 111-123, <https://doi.org/10.1038/s41565-022-01284-0>
- Matthews, B.W., 1975, Comparison of the predicted and observed secondary structure of T4 phage lysozyme, *Biochimica et Biophysica Acta (BBA)-Protein Structure*, 405:2, 442-451, [https://doi.org/10.1016/0005-2795\(75\)90109-9](https://doi.org/10.1016/0005-2795(75)90109-9)
- Meng, Z., Zhao, F., Liang, M., ve Xie, W., 2021, Deep residual involution network for hyperspectral image classification, *Remote Sensing*, 13:16, 1-29, <https://doi.org/10.3390/rs13163055>
- Morales, G., Sheppard, J.W., Logan, R.D., ve Shaw, J.A., 2021, Hyperspectral dimensionality reduction based on inter-band redundancy analysis and greedy spectral selection, *Remote Sensing*, 13, 1-31, <https://doi.org/10.3390/rs13183649>
- Nidamanuri, J., Vaigarai, S., Gunavardhan, V.S., ve Teja, K.V., 2023, SCED: A Multi-criteria-based Modeling of Deep Learning Architectures for Skin Cancer Analysis, in *2023 10th IEEE International Conference on Computing for Sustainable Global Development (INDIACom)*, New Delhi, India, 1110-1115.
- Okwuashi, O., ve Ndehedehe, C.E., 2020, Deep support vector machine for hyperspectral image classification, *Pattern Recognition*, 103, 1-10. <https://doi.org/10.1016/j.patcog.2020.107298>

- Pandey, P.C., Balzter, H., Srivastava, P.K., Petropoulos, G.P., ve Bhattacharya, B., 2020, Future perspectives and challenges in hyperspectral remote sensing, *Hyperspectral Remote Sensing*, 429-439, <https://doi.org/10.1016/B978-0-08-102894-0.00021-8>
- Paoletti, M.E., Haut, J.M., Plaza, J., ve Plaza, A., 2019, Deep learning classifiers for hyperspectral imaging: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 279-317, <https://doi.org/10.1016/j.isprsjprs.2019.09.006>
- Priya, K., Rajkumar, K.K., 2022, Hyperspectral and Multispectral Image Fusion Using Deep Convolutional Neural Network-ResNet Fusion, *IntechOpen*, DOI: 10.5772/intechopen.105455
- Qiu, J., Chen, C., Liu, S., Zhang, H.-Y., ve Zeng, B., 2021, SlimConv: Reducing channel redundancy in convolutional neural networks by features recombining, *IEEE Transactions on Image Processing*, 30, 6434–6445, DOI: 10.1109/TIP.2021.3093795.
- Rayhana, R., Ma, Z., Liu, Z., Xiao, G., Ruan, Y., ve Sangha, J.S., 2023, A Review on Plant Disease Detection Using Hyperspectral Imaging, *IEEE Transactions on AgriFood Electronics*, 1:2, 108-134, DOI: 10.1109/TAFE.2023.3329849
- Roweis S.T., ve L.K. Saul, 2000, Nonlinear dimensionality reduction by locally linear embedding, *Science*, 290, 2323-2326, DOI: 10.1126/science.290.5500.2323
- Roy, S.K., Krishna, G., Dubey, S.R., Chaudhuri, B.B., 2019, HybridSN: Exploring 3-D–2-D CNN feature hierarchy for hyperspectral image classification, *IEEE Geoscience and Remote Sensing Letters*, 17:2, 277-281, DOI: 10.1109/LGRS.2019.2918719
- Sethy, P.K., Pandey, C., Sahu, Y.K., ve Behera, S.K., 2022, Hyperspectral imagery applications for precision agriculture-a systemic survey, *Multimedia Tools and Applications*, 81:2, 3005-3038, <https://doi.org/10.1007/s11042-021-11729-8>
- Shao, Y., Liu, J., Yang, J., ve Wu, Z., 2022, Spatial–spectral involution mlp network for hyperspectral image classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 9293-9310, DOI: 10.1109/JSTARS.2022.3216590
- Singh, P.S., ve Karthikeyan, S., 2022, Enhanced classification of remotely sensed hyperspectral images through efficient band selection using autoencoders and genetic algorithm, *Neural Computing and Applications*, 34:24, 21539-21550, <https://doi.org/10.1007/s00521-021-06121-4>
- Sommer, F., Sun, B., Fischer, J., Goldammer, M., Thiele, C., Malberg, H., ve Markgraf, W., 2022, Hyperspectral Imaging during Normothermic Machine Perfusion—A Functional Classification of Ex Vivo Kidneys Based on Convolutional Neural Networks, *Biomedicines*, 10, 1-20, <https://doi.org/10.3390/biomedicines10020397>

- Sra, S., ve Dhillon, I., 2005, Generalized nonnegative matrix approximations with Bregman divergences, *Advances in Neural Information Processing Systems*, Vancouver, BC, Canada 1-8.
- Subudhi, S., Patro, R.N., Biswal, P.K., ve Dell'Acqua, F., 2021, A survey on superpixel segmentation as a preprocessing step in hyperspectral image analysis, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 5015-5035, DOI: 10.1109/JSTARS.2021.3076005
- Terentev, A., Dolzhenko, V., Fedotov, A., ve Eremenko, D., 2022, Current state of hyperspectral remote sensing for early plant disease detection: A review, *Sensors*, 22:3, 1-31, <https://doi.org/10.3390/s22030757>
- Thudumu, S., Branch, P., Jin, J., ve Singh, J., 2020, A comprehensive survey of anomaly detection techniques for high dimensional big data, *Journal of Big Data*, 7, 1-30, <https://doi.org/10.1186/s40537-020-00320-x>
- Ulya, M., Chamidah, N., ve Saifudin, T., 2023, Mango quality prediction based on near-infrared spectroscopy using multi-predictor local polynomial regression modeling, *F1000Research*, 12, 1-19, <https://doi.org/10.12688/f1000research.130015.1>
- Van der Maaten L., ve G. Hinton, 2008, Visualizing data using t-SNE, *Journal of Machine Learning Research*, 9, 2579-2605.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł., ve Polosukhin, I., 2017, Attention is all you need, *Advances in neural information processing systems*, Long Beach, California, USA, 1-11,
- Von Luxburg U., 2007, A tutorial on spectral clustering, *Statistics and computing*, 17, 395-416, <https://doi.org/10.1007/s11222-007-9033-z>
- Wang, G., Ye, J.C., ve De Man, B., 2020, Deep learning for tomographic image reconstruction, *Nature Machine Intelligence*, 2:12, 737-748, <https://doi.org/10.1038/s42256-020-00273-z>
- Wang, M., Hong, D., Han, Z., Li, J., Yao, J., Gao, L., Zhang, B., ve Chanussot, J., 2023, Tensor decompositions for hyperspectral data processing in remote sensing: A comprehensive review, *IEEE Geoscience and Remote Sensing Magazine*, 11:1, 26-72, DOI: 10.1109/MGRS.2022.3227063
- Wang, M., Xu, Y., Wang, Z., ve Xing, C., 2023, Deep margin cosine autoencoder based medical hyperspectral image classification for tumor diagnosis, *IEEE Transactions on Instrumentation and Measurement*, 72, 1-12, DOI: 10.1109/TIM.2023.3293548
- Wang, Q., Wang, J., Zhou, M., Li, Q., Wen, Y., ve Chu, J., 2021, A 3D attention networks for classification of white blood cells from microscopy hyperspectral images, *Optics & Laser Technology*, 139, 1-8, <https://doi.org/10.1016/j.optlastec.2021.106931>

- Wei, X., Li, W., Zhang, M., ve Li, Q., 2019, Medical Hyperspectral Image Classification Based on End-to-End Fusion Deep Neural Network, *IEEE Transactions on Instrumentation and Measurement*, 68, 4481–4492, DOI: 10.1109/TIM.2018.2887069
- Yang, Z., Xi, Z., Zhang, T., Guo, W., Zhang, Z., ve Li, H.C., 2022, CMR-CNN: Cross-mixing residual network for hyperspectral image classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 8974–8989, DOI: 10.1109/JSTARS.2022.3213865
- Yoon, J., 2022, Hyperspectral imaging for clinical applications, *BioChip Journal*, 16:1, 1-12, <https://doi.org/10.1007/s13206-021-00041-0>
- Zaffino, P., Moccia, S., De Momi, E., ve Spadea, M.F., 2020, A review on advances in intra-operative imaging for surgery and therapy: imagining the operating room of the future, *Annals of Biomedical Engineering*, 48:8, 2171-2191, <https://doi.org/10.1007/s10439-020-02553-6>
- Zebari, R., Abdulazeez, A., Zeebaree, D., Zebari, D., ve Saeed, J., 2020, A comprehensive review of dimensionality reduction techniques for feature selection and feature extraction, *Journal of Applied Science and Technology Trends*, 1, 56-70, <https://doi.org/10.38094/jastt1224>
- Zhao, W., ve Du, S., 2016, Spectral–spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach, *IEEE Transactions on Geoscience and Remote Sensing*, 54, 4544-4554, DOI: 10.1109/TGRS.2016.2543748
- Zhao, L., Yi, J., Li, X., Hu, W., Wu, J., ve Zhang, G., 2021, Compact band weighting module based on attention-driven for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 59:11, 9540-9552, DOI: 10.1109/TGRS.2021.3053397
- Zheng, J., Feng, Y., Bai, C., ve Zhang, J., 2021, Hyperspectral image classification using mixed convolutions and covariance pooling, *IEEE Transactions on Geoscience and Remote Sensing*, 59:1, 522-534, DOI: 10.1109/TGRS.2020.2995575
- Zhong, Z., Li, J., Luo, Z., ve Chapman, M., 2017, Spectral–spatial residual network for hyperspectral image classification: A 3-D deep learning framework, *IEEE Transactions on Geoscience and Remote Sensing*, 56:2, 847-858, DOI: 10.1109/TGRS.2017.2755542
- Zhu, Q., Ma, H., ve Yu, H., 2022, A hybrid gray wolf optimizer for hyperspectral image band selection, *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-13, DOI: 10.1109/TGRS.2022.3167888

EKLER**EK-1 Hiperspektral Görüntülerin Alınması için Etik Kurul Kararı**

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

YEREL ETİK KURULU KARARLARI

Toplantı Sayısı: 2022/05

Toplantı Tarihi :01.03.2022

Karar Sayısı 2022/125 Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik Elektronik Mühendisliği Bölümü Öğretim Üyesi Doç. Dr. Murat CEYLAN'ın "Hiperspektral Görüntüleme ve Yapay Zeka Kullanılarak Yenidoğanlar İçin Ön-Teşhis Sisteminin Geliştirilmesi" başlıklı araştırmasının değerlendirilme talebi ile ilgili 22.02.2022 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç. Dr. Murat CEYLAN'ın "Hiperspektral Görüntüleme ve Yapay Zeka Kullanılarak Yenidoğanlar İçin Ön-Teşhis Sisteminin Geliştirilmesi" adlı araştırmasının kabulüne oy birliği ile karar verildi.

Yardımcı Araştırmacılar: Hanifi SOYLU, Murat KONAK.


NOT: 3359 sayılı Sağlık Hizmetleri Temel Kanunu Ek 10.madde hükümleri uyarınca; bazı çalışmalar için etik kurul onayı alındıktan sonra, Sağlık Bakanlığı veya bağlı kuruluşlarından (çalışmanın yapılacağı kurum) izin alınması zorunlu olduğundan araştırmacıların bu hususa dikkat etmeleri gerekmektedir.

ASLI GİBİDİR
01.03.2022

İmzalı

Burcu Tuğba ALDORA
Sekretarya


Involution-based HarmonyNet: An Efficient Hyperspectral Imaging Model for Automatic Detection of Neonatal Health Status



CONCLUSION:

The success of the HarmonyNet model highlights the valuable potential of hyperspectral imaging technology in neonatal health, contributing meaningfully to the development of neonatal health practices.

EK-3 Grafiksel Özet. Hiperspektral Görüntüleme ile Yenidoğan Hastalığı Teşhisi için MC-I²Net: Çok Ölçekli Bağlamsal Yapı ve Başlangıç Modülü ile İnvölüsyon Tabanlı Derin Öğrenme Yaklaşımı



EK-4 Grafiksel Özet. Hiperspektral Görüntüleme ve Kan Biyobelirteçleri Kullanılarak Yenidoğan Hastalığının Tanımlanması için 2B/3B Konvolüsyon ve İnvolüsyon Tabanlı HybridCISN Modeli

