

# Neonatal Hiperspektral Görüntü Sınıflandırması için 3 Boyutlu Evrişimli Sinir Ağları ile Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi

Mücahit Cihan<sup>1</sup>, Mahmut Çevik<sup>2\*</sup>, Nezahat Yılmaz<sup>3</sup>, Murat Konak<sup>4</sup>, Hanifi Soylu<sup>5</sup> ve Murat Ceylan<sup>6</sup>

<sup>1</sup> Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, Türkiye (mcihan@ktun.edu.tr) (ORCID: 0000-0002-1426-319X)

<sup>2\*</sup> AIVISIONTECH Elektronik Yazılım A.Ş., Konya, Türkiye (mahmut@aivisiontech.com) (ORCID: 0009-0001-8630-9564)

<sup>3</sup> Selçuk Üniversitesi, Tıp Fakültesi, Çocuk Sağlığı ve Hastalıkları Ana Bilim Dalı, Konya, Türkiye (nzhtylmz.42@gmail.com) (ORCID: 0000-0002-1214-9692)

<sup>4</sup> Selçuk Üniversitesi, Tıp Fakültesi, Dahili Tıp Bilimleri Bölümü, Konya, Türkiye (drmkonak@hotmail.com) (ORCID: 0000-0001-8728-4541)

<sup>5</sup> Selçuk Üniversitesi, Tıp Fakültesi, Dahili Tıp Bilimleri Bölümü, Konya, Türkiye (hasoylu@hotmail.com) (ORCID: 0000-0003-0367-859X)

<sup>6</sup> Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, Türkiye (mceylan@ktun.edu.tr) (ORCID: 0000-0001-6503-9668)

**Türkçe Özet** – Hiperspektral Görüntüleme (HSG) verilerinin yüksek boyutlu olması, sınıflandırma performansını olumsuz etkilemektedir. Bu nedenle, birçok HSG sınıflandırma uygulamasında, yüksek boyutlu verilerle başa çıkmak için boyut indirgeme yöntemlerine başvurulmaktadır. Boyut indirgeme yöntemleri, kullanışlı özelliklerin elde edilmesini hedeflemektedir. Bu sürecin sonucunda veri boyutu azaltılmakta ve işlem maliyeti düşürülmektedir. Bu çalışmada, neonatal HSG sınıflandırma başarısını artırmak için veriler üzerine çeşitli boyut indirgeme yöntemleri uygulanmıştır. Hem uzamsal hem de spektral özelliklere erişebilen özel bir 3 boyutlu evrişimli sinir ağı (3B-ESA) modeli sınıflandırma için kullanılmıştır. Birçok boyut indirgeme yöntemi farklı performans değerlendirme ölçütleri kullanılarak değerlendirilmiş ve Temel Bileşenler Analizi (TBA) ile en iyi sonuca ulaşılmıştır. TBA, genel doğruluk oranı dışında boyut indirgeme süresi bakımından diğer yöntemlere kıyasla oldukça başarılı olmuştur. Bu sayede TBA, anlamlı spektral özelliklerin daha kısa bir sürede elde edilmesini sağlayarak hesaplama maliyetini düşürmüştür. Ayrıca, Negatif Olmayan Matris Ayrışımı (NOMA) ve Yerel Doğrusal Gömme (YDG) yöntemleri de başarılı sonuçlar vermiştir. t-Dağıtılmış Stokastik Komşu Gömme (t-SKG) yöntemi, iyi sonuçlar vermesine rağmen boyut indirme işleminde en fazla süreyi alan yöntem olmuştur. Sonuç olarak, bu çalışma neonatal hiperspektral görüntü sınıflandırmasında çeşitli boyut indirgeme yöntemlerinin başarılı sonuçlar elde edilmesini sağlayabileceğini göstermektedir. Bu tür tekniklerin kullanılması, yüksek boyutlu HSG verilerini daha işlenebilir hale getirerek sınıflandırma performansını artırmaktadır.

**Anahtar Kelimeler** – Hiperspektral Görüntüleme, Boyut İndirgeme, 3 Boyutlu Evrişimli Sinir Ağları, Neonatal, Temel Bileşenler Analizi, Negatif Olmayan Matris Ayrışımı, Yerel Doğrusal Gömme, t-Dağıtılmış Stokastik Komşu Gömme.

**Atf:** Cihan, M., Çevik, M., Yılmaz, N., Konak, M., Soylu, H., 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.

## Comparative Analysis of Dimension Reduction Methods with 3 Dimensional Convolutional Neural Networks for Neonatal Hyperspectral Image Classification

### Extended Abstract

**Research Problem/Questions** – Hyperspectral imaging (HSI) data are high-dimensional and complex data containing a large number of spectral bands. Therefore, these images generate large datasets and become challenging to process. The high dimensionality of HSI data often hinders classification performance.

**Short Literature Review** – Consequently, in many HSI classification applications, dimensionality reduction methods are employed to deal with the challenges posed by high-dimensional data. These methods aim to extract valuable features, reducing data size and computational costs in the process.

**Methodology** – In this study, various dimensionality reduction techniques were applied to enhance neonatal HSI classification performance. A specialized 3D Convolutional Neural Network (3D-CNN) model, capable of incorporating both spatial and spectral features, was used for classification. Several dimensionality reduction methods were assessed using various performance evaluation criteria.

**Results and Conclusions** – Principal Component Analysis (PCA) emerged as the top-performing method. Additionally, PCA exhibited remarkable efficiency in dimensionality reduction time when compared to other techniques, significantly reducing computational costs while providing meaningful spectral features. Non-Negative Matrix Factorization (NMF) and Local Linear Embedding (LLE) also delivered strong results. On the other hand, t-Distributed Stochastic Neighbor Embedding (t-SNE), although effective, consumed the most time in dimension reduction. In conclusion, this study underscores the potential of various dimensionality reduction methods in improving neonatal hyperspectral image classification. The application of such techniques enhances classification performance by rendering high-dimensional HSI data more manageable.

**Keywords** – Hyperspectral Imaging, Dimension Reduction, 3D Convolutional Neural Networks, Neonatal, Principal Component Analysis, Non-Negative Matrix Factorization, Local Linear Embedding, t-Distributed Stochastic Neighbor Embedding.

**Citation:** Cihan, M., Çevik, M., Yılmaz, N., Konak, M., Soylu, H., Ceylan, M. (2023). Comparative Analysis of Dimension Reduction Methods with 3D Convolutional Neural Networks for Neonatal Hyperspectral Image Classification. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(2): 74-83.

## I. GİRİŞ

Hiperspektral Görüntüleme (HSG), yüzlerce veya binlerce ayrı spektral bant içeren görüntülerin elde edilmesini sağlayan güçlü bir görüntüleme tekniğidir [1]. Bu teknoloji, nesnelerin malzeme bileşenleri, kimyasal içerikleri ve fiziksel özellikleri hakkında ayrıntılı bilgi sağlama kapasitesi ile geniş bir uygulama yelpazesi sunmaktadır. Tarım sektöründe bitki sağlığının izlenmesi [2], madencilikte mineral kaynaklarının tespiti [3], çevre işleme [4], uzaktan algılama [5], gıda güvenliği [6], tıbbi teşhis [7], arkeoloji [8], askeri istihbarat [9], sanayi kalite kontrolü [10], su kaynakları yönetimi [11] gibi bir dizi alanda kullanılmaktadır.

HSG sağlık alanında önemli uygulama potansiyeli taşımaktadır. Özellikle tıbbi teşhis ve tedavi izleme süreçlerinde, HSG cilt lezyonları, kanser teşhisi, doku karakterizasyonu ve oksijen doygunluğu gibi kritik parametrelerin izlenmesine yardımcı olmaktadır [12]. Bu teknoloji, dokuların spektral imzalarını incelemek suretiyle sağlık profesyonellerine daha ayrıntılı ve hassas bilgiler sunar, böylece erken teşhislerin yapılmasına ve tedavi stratejilerinin iyileştirilmesine katkıda bulunur [13]. Ayrıca, hiperspektral görüntüleme, tıbbi uygulamalarda görüntü işleme ve veri analizinde yeni olanaklar sunarak sağlık hizmetlerinin kalitesini artırmaktadır [14]. Neonatal sağlık alanında, hiperspektral görüntüleme, yenidoğan bebeklerin cilt sağlığı (yara tespiti gibi) ve oksijen doygunluğu gibi önemli tıbbi parametrelerin izlenmesi için kullanılmıştır [15], [16].

Hiperspektral görüntüler, yüksek boyutlu ve karmaşık verilerdir. Her pikselde çok sayıda spektral bant içerdiğinden, bu görüntüler büyük veri kümelerini oluşturur ve işlenmesi zorlu hale gelir [17]. Bu büyük boyutlu veriler, analiz ve işlem süreçlerini karmaşıklştırabilir, hesaplama maliyetlerini artırabilir ve sınıflandırma algoritmalarının etkinliğini olumsuz etkileyebilir. Ayrıca, bu yüksek boyutlu verilerin işlenmesi, analizi ve sınıflandırılması, özellikle derin öğrenme yöntemleri gibi gelişmiş algoritmalar gerektirir [18]. Bu zorluğun üstesinden gelmek ve hiperspektral görüntü

verilerinden anlamlı bilgiler elde etmek için boyut indirgeme yöntemleri kritik bir rol oynar.

Boyut indirgeme yöntemleri, yüksek boyutlu hiperspektral verilerin boyutunu indirgeyerek daha düşük boyutlu temsillemelelere dönüştürmeyi amaçlar. Bu süreç, gereksiz ve gürültülü bilgilerin elemine edilmesini içerirken önemli spektral özelliklerin korunmasına odaklanır. Bu, verilerin daha anlamlı ve işlenebilir hale gelmesini sağlar. Ayrıca, boyut indirgeme yöntemleri, sınıflandırma algoritmalarının daha iyi performans göstermesine yardımcı olur [19].

Temel Bileşenler Analizi (TBA) [20], Bağımsız Bileşenler Analizi (BBA) [21], Tekil Değer Ayrışması (TDA) [22], t-Dağıtılmış Stokastik Komşu Gömme (t-SKG) [23], Yerel Doğrusal Gömme (YDG) [24] Negatif olmayan Matris Ayrışımı (NOMA) [25] ve Spektral Gömme (SG) [26] gibi çeşitli boyut indirgeme teknikleri hiperspektral görüntü verilerinin işlenmesinde yaygın olarak kullanılır. Bu yöntemler, yüksek boyutlu verileri daha yönetilebilir boyutlara indirirken önemli bilgiyi korur. Literatürde, HSG verilerine farklı boyut indirgeme yöntemleri uygulanarak çeşitli çalışmalar yapılmıştır. Örneğin; Haque ve Mishu [27]'de, TBA tabanlı boyut indirgeme tekniği ve çok ölçekli ESA'dan oluşan bir hibrit yöntem önermişler ve kullandıkları uzaktan algılama veri kümesinde 0.99 doğruluk oranı elde etmişlerdir. Fırat ve ark. [28]'de, TBA'ya ilave olarak BBA ve TDA gibi boyut indirgeme yöntemlerini kullanarak HSG sınıflandırma performansı artırılmışlardır. Devassy ve George ise [29]'da, t-SKG boyut indirgeme yöntemini kullanarak spektral benzerlikleri daha düşük boyutlara ölçeklemişlerdir. Huang ve ark. [30]'da, hiperspektral saçılım özelliklerini çıkarmak için bir YDG algoritması kullanmıştır. Hossain ve Hossain [31]'de, TBA, NOMA, BBA ve TDA gibi boyut indirgeme algoritmalarını kullanmanın sınıflandırma üzerindeki etkilerini ve performansını göstermek için deneysel çalışmalar yapmışlardır. Huang ve ark. [32]'de, HSG verilerindeki komşu bantlara yerel olarak özgü dizi bilgilerini öğrenmek için SG modülünü kullanmışlardır. HSG verilerinin boyutunun

indirgenmesi, analiz ve işleme kolaylığının sağlanması için birçok farklı yöntem literatürde kullanılmıştır.

Bu çalışma, neonatal hiperspektral görüntü sınıflandırması için 3 Boyutlu Evrişimli Sinir Ağları (3B-ESA) kullanarak boyut indirgeme yöntemlerinin karşılaştırmalı analizini sunmaktadır. Hiperspektral görüntülerin boyutlarının indirgenmesi, veri analizini kolaylaştırır, hesaplama karmaşıklığını azaltır ve sınıflandırma performansını artırır. Bu nedenle, bu çalışma hiperspektral görüntüler için farklı boyut indirgeme yöntemlerinin etkinliğini değerlendirmeyi hedeflemektedir. Çalışmanın temel amaçları aşağıdaki gibi ifade edilebilir:

- Farklı boyut indirgeme tekniklerinin neonatal hiperspektral görüntü verileri üzerindeki etkisini incelemek.
- 3B ESA kullanarak boyut indirgenmiş görüntülerle sınıflandırma performansını karşılaştırmak.
- Optimal boyut indirgeme yöntemini ve sınıflandırma stratejisini belirlemek ve neonatal tıbbi teşhis uygulamaları için potansiyel faydalarını değerlendirmek.

Hiperspektral görüntü analizi ve boyut indirgeme konularında daha ileri bir adım atılarak, neonatal sağlık izleme uygulamalarına önemli katkılar sunmak amaçlanmıştır. Özellikle, hiperspektral görüntülerin boyut indirgeme yöntemleri kullanılarak elde edilen verileri, 3B-ESA ile sınıflandırılması incelenmektedir. Boyut indirgeme, bu karmaşık verileri daha anlamlı ve işlenebilir hale getirmek için kritik bir adımdır.

Bildirinin geri kalan kısmında, verisetinin tanıtımı, boyut indirgeme yöntemlerinin açıklaması, 3B-ESA modeli ve performans ölçütleri yer almaktadır. Daha sonra, deneysel sonuçların sunumu ve sonuçların analiz edilmesiyle devam edecek ve son bölümde genel sonuçlar sunulacaktır.

## II. MATERYAL VE METOT


### A. HSG Sistemi

HSG verileri, MS Spektral firması tarafından tasarlanan HSG sistemi kullanılarak elde edilmiştir. Görüntüleme sistemi 0.5m mesafede 50mm çapından ışık toplayabilen noktasal bir spektrometredir. Bu sistem noktasal tarama tekniği ile HSG verileri toplamaktadır.

Bu sistemde BROADCOM firmasının geliştirmiş olduğu AFBR-S20M2VN Qmini VIS/NIR-Miniature USB spektrometresi bulunmaktadır. Cihazın teknik özellikleri Tablo 1'de verilmiştir. Yansıyan spektrum ölçümleri kalibrasyonu için BaSO<sub>4</sub> bazlı bir beyaz referans panel ve ışık kaynağı olarak 21V 150W gücünde bir halojen ampül kullanılmıştır. Ölçüm kurulumu Şekil 1'de gösterilmiştir.

Tablo 1. AFBR-S20M2VN Qmini VIS/NIR-Miniature USB spektrometresi 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 600s



Şekil 1. Ölçüm kurulumu; (1) kamera sistemi, (2) yenidoğan, (3) kütüz, (4) tripod, (5) bilgisayar ve (6) beyaz referans panel.

### B. Veriseti

Neonatal HSG verileri, TÜBİTAK – 1001- Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı (Proje No: 122E021) kapsamında Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesindeki yenidoğanlardan elde edilmiştir. Proje araştırması, Etik Kurul Onayı (2022/125) ile gerçekleştirilmiştir.

Kamera 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 derece olarak belirlenmektedir. Sonuç olarak kamera her bir nokta için 2018 dalga boyunda veri toplamaktadır.

Kamera noktasal veri topladığı için elde edilen verilerin boyutu 1×1×2018 boyutundadır. Uzamsal anlamda boyutu genişletmek için farklı noktalardan ölçümler alınmış ve bu ölçümler birleştirilmiştir. Toplamda bir yenidoğan için 100 farklı noktadan veriler alınarak 10×10×2018 hiperspektral veri küpleri oluşturulmuştur. Bir bebeğin spektral imzaları sağlık durumuna göre (hasta veya sağlıklı) farklı noktalarda benzer özellikler gösterdiği için verilerin birleştirilmesi sorun teşkil etmemektedir. Bu sayede hacimsel veriler oluşturulmuştur.

Bu çalışma için toplamda 220 HSG verisi kullanılmıştır. Bu verilerin 110'u hasta yenidoğanlara aitken, diğer 110'u ise kontrol grubuna aittir. Hasta verileri içinde 37 tanesi AORT damarının daralması veya sıkışması sonucu meydana gelen AORT koarktasyonu hastalığına, 27 tanesi çeşitli sebeplerden kaynaklanan akciğer çökmesi sonucu oluşan pnömotoraks hastalığına, ve 46 tanesi akciğerlerin yeterince gelişmemesi nedeniyle ortaya çıkan solunum sıkıntısı olan respiratuar distres sendromu hastalığına aittir. Bu hastalıkların tamamının gövde bölgesinde olduğu dikkate alınarak, daha doğru bir

karşılaştırma yapmak amacıyla kontrol grubuna ait HSG verileri de aynı bölgelerden alınan verilerden oluşmaktadır.

Şekil 2, örnek bir sağlıklı yenidoğan ve bir hasta yenidoğan için elde edilen tüm spektrumları ve bu spektrumların ortalamalarını göstermektedir. Bu spektral imzalar, her bir pikselin farklı dalga boyları altındaki spektral değerlerini temsil etmek amacıyla oluşturulmuştur [33]. Bu imzalardaki spektral bilgiler kullanılarak uygulamalar gerçekleştirilmiştir.

Spektral imzalar incelendiğinde, numuneden yansıyan ışığın performansının 500nm'nin altında ve 1000nm'nin üzerinde düşük olduğu gözlemlenmiştir. Bu nedenle, 500-1000nm aralığının dışındaki spektrumlar sadece gürültü içerirken, bu aralıktaki spektrumlar yenidoğanların sağlık durumuyla ilgilidir. Bu nedenle, 500-1000nm aralığındaki 1538 spektrum analize dahil edilmiştir. Ayrıca, veri kesinliğini artırmak için her spektrum Savitzky-Golay [34] filtresi kullanılarak yumuşatılmıştır. Bu filtre, verisetindeki dalgalanmaları azaltmak için kullanılır ve verilerin düzgünleştirilmesine yardımcı olur. Sonuç olarak, spektrum verileri daha kesin ve güvenilir hale getirilmiştir.

### C. Boyut İndirgeme Yöntemleri

Büyük ve karmaşık bir HSG veri kümesini daha yönetilebilir ve işlenebilir hale getirmek amacıyla, HSG veri işleme ve analizi sırasında kanal boyutunu azaltma işlemi uygulanmıştır. Hiperspektral görüntüler, genellikle yüzlerce veya binlerce dar bant spektral kanaldan oluşur ve bu büyük veri kümesini işlemek zorlaştırabilir. Kanal boyutu azaltma, veriyi daha verimli hale getirmek amacıyla bu çalışmada çeşitli boyut indirgeme yöntemleri kullanılmıştır.

*Temel Bileşenler Analizi (Principal component analysis, TBA):*

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

**Veri Hazırlığı:** Hiperspektral 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:

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

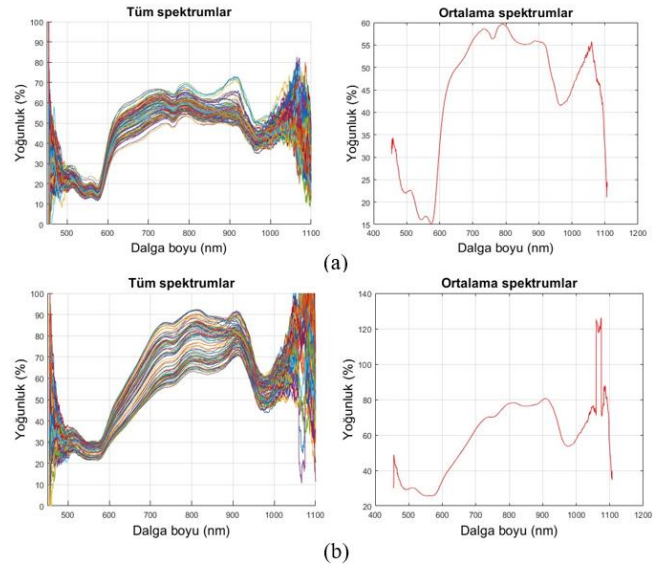
**Ortalama Merkezileştirme:** Her spektral bandın ortalamasını çıkararak verilerin merkezileştirilmesi gerekmektedir. Bu işlem, her bir özellik veya spektral bant için yapılır. Örneğin, bir spektral bandın ortalaması  $j$  için şu şekildedir:

$$\bar{x}_j = \frac{1}{m} \sum_{i=1}^m x_{ij} \quad (2)$$

Ortalama merkezileştirme sonucunda, her spektral bandın ortalaması sıfır olur.

**Kovaryans Matrisinin Hesaplanması:** Kovaryans matrisi, hiperspektral verilerin varyansını ve korelasyonunu hesaplamak için kullanılır. Kovaryans matrisi  $\Sigma$  şu şekildedir:

$$\Sigma = \frac{1}{m} X^T X \quad (3)$$



Şekil 2. Örnek spektral imzalar ve bu imzaların ortalamaları; (a) sağlıklı ve (b) hasta.

Burada,  $\Sigma$  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.

$$Z = XU \quad (4)$$

Burada,  $U$  özvektör matrisini ve  $Z$  temel bileşenler matrisini temsil eder.

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

*Bağımsız Bileşenler Analizi (Independent Component Analysis, BBA):*

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

$$X = AS \quad (5)$$

Burada  $X$  hiperspektral veri matrisini,  $A$  karışım matrisini ve  $S$  bağımsız bileşen matrisini temsil eder.

**Amaç 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 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, hiperspektral verilerin spektral boyutunu korurken veriyi bağımsız bileşenlere ayırmak ve verinin yapılarını incelemek için kullanılır.

*Tekil Değer Ayrışması (Singular Value Decomposition, TDA):*

TDA, bir matrisi üç ayrı matrise ayıran matematiksel bir işlemdir. Veri matrisi TDA ile aşağıdaki şekilde ayrıştırılabilir:

$$X = U\Sigma V^T \quad (6)$$

$X$ : hiperspektral veri matrisini ifade eder.

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

$\Sigma$ :  $m \times n$  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 analiz edilebilir.

**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:

$$X' = U_k \Sigma_k V_k^T \quad (7)$$

Burada,  $k$  azaltılmış boyut sayısını temsil eder.

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.

*t-Dağıtılmış Stokastik Komşu Gömme (t-Distributed Stochastic Neighbor Embedding, t-SKG):*

t-SKG Modeli: t-SKG, yüksek boyutlu verileri düşük boyutlu bir uzaya indirgemek için kullanılan bir doğrusal olmayan boyut indirgeme yöntemidir. t-SKG için şu adımlar takip edilir:

a. İlk olarak, benzerlik matrisi  $P$  oluşturulur.  $P$  matrisi, verinin benzerliklerini yansıtır ve çoğunlukla Gaussian olasılık yoğunluğu kullanılarak hesaplanır:

$$p_{ij} = \frac{e^{-\frac{\|z_i - z_j\|^2}{2\sigma_i^2}}}{\sum_{k \neq i} e^{-\frac{\|x_i - x_k\|^2}{2\sigma_i^2}}} \quad (8)$$

Burada,  $p_{ij}$  iki nokta  $x_i$  ve  $x_j$  arasındaki benzerliği temsil eder ve  $\sigma_i$  benzerlik ölçeği olarak kullanılır.

b. Ardından, düşük boyutlu veriyi temsil eden bir benzerlik matrisi  $Q$  oluşturulur.  $Q$  matrisi, düşük boyutlu uzayda noktalar arasındaki benzerliği temsil eder:

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_i - y_k\|^2)^{-1}} \quad (8)$$

Burada,  $q_{ij}$  iki nokta  $y_i$  ve  $y_j$  arasındaki benzerliği temsil eder.

**Amaç Fonksiyonu:** t-SKG, benzerlik matrislerinin benzerliklerini en iyi şekilde korumaya çalışır. Bu amaç fonksiyonu, Kullback-Leibler (KL) diverjansını minimize etmeyi amaçlar:

$$C = KL(P \parallel Q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (9)$$

Burada,  $C$  amaç fonksiyonunu temsil eder.

**Optimizasyon:** t-SKG, amaç fonksiyonunu optimize ederek düşük boyutlu temsili bulur. Genellikle gradyan iniş veya diğer iteratif yöntemler kullanılır. Optimizasyon işlemi sonucunda, düşük boyutlu temsili ( $y_i$ ) hesaplanır ve verinin spektral boyutu korunurken veri, düşük boyutlu uzamsal temsilde temsil edilir.

t-SKG, verinin benzerliklerini koruyarak yüksek boyutlu veriyi düşük boyutlu uzamsal temsilde ifade etmek için kullanılır. Bu şekilde verinin yapısını daha iyi anlamak ve görselleştirmek için faydalıdır.

*Yerel Doğrusal Gömme (Locally Linear Embedding, YDG):*

**YDG Algoritması:** YDG, veriyi yakındaki noktaların lokal doğrusal ilişkilerini koruyacak şekilde düşük boyutlu bir uzaya çekmek için kullanılır. Bu işlemi gerçekleştirmek için aşağıdaki adımları takip eder ( $X$ : Giriş HSG verisi):

a. **Komşu Noktaların Bulunması:** Her pikselin, yakınındaki komşu pikselleri belirlemek için bir komşuluk grafiği oluşturulur.

b. **Ağırlık Matrisinin Oluşturulması:** Her piksel, komşu piksellere olan uzaklıklara göre bir ağırlık matrisi hesaplar. Bu ağırlıklar, her bir pikselin komşularıyla olan yerel doğrusal ilişkisini yansıtır.

c. **Düşük Boyutlu Temsilin Hesaplanması:** Ağırlık matrisi ve veri matrisi kullanılarak düşük boyutlu temsil hesaplanır. Genellikle en küçük özdeğerlere karşılık gelen özvektörler kullanılır.

d. **Sonuçların Yeniden İnşa Edilmesi:** Düşük boyutlu temsil kullanılarak, her pikselin yeniden inşa edilmiş uzamsal temsili hesaplanır.

**Azaltılmış Boyutta Yeniden İnşa:** YDG'nin sonucu olarak, her pikselin azaltılmış boyutta temsili ve bu temsili kullanarak uzamsal yeniden inşa edilmiş temsili vardır.

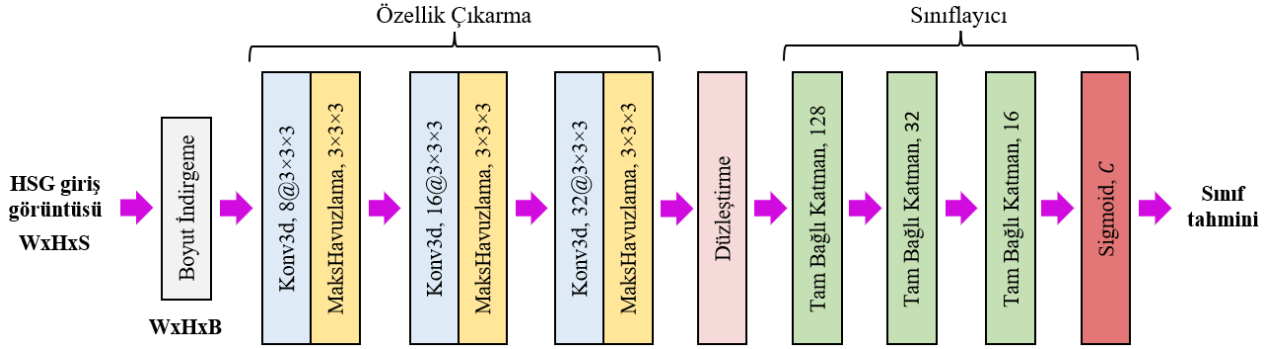
$$X' = [x'_1, x'_2, \dots, x'_m] \quad (10)$$

Burada,  $X'$  azaltılmış boyutta veriyi temsil eder.

YDG, hiperspektral verilerin spektral boyutunu korurken uzamsal boyutta azaltılmasına yardımcı olur. Azaltılmış boyutta temsil, veriyi daha anlamlı ve indirgenmiş boyutta analiz etmek için kullanılabilir.

*Negatif olmayan Matris Ayrışımı (Non-negative Matrix Factorization, NOMA):*

NOMA, spektral boyutun korunduğu ve yalnızca verinin spektral bileşenlerinin yaklaşık bir temsili olan iki matrisin çarpımının hesaplandığı bir dizi adımdan oluşur. NOMA adımları aşağıdaki gibidir:



Şekil 3. Hem uzamsal hem de spektral özellikleri çıkarmak için 3B konvolüsyon katmanlarına sahip 3B-ESA modeli.

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

$$X \approx WH \quad (11)$$

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

Amaç Fonksiyonu: NOMA, bir amaç fonksiyonunu minimize etmek amacıyla çalışır. Tipik olarak, bu amaç fonksiyonu, verinin orijinal matrisine ne kadar iyi yaklaşıldığını ölçer ve aşağıdaki gibi tanımlanır:

$$\|X - WH\|^2 \quad (12)$$

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 temsiline daha düşük boyutlu matrisler  $W$  ve  $H$  ile yapıldığı bir şekilde yaklaşık hale gelir.

NOMA, spektral boyutun korunması gerektiği durumlarda hiperspektral verilerin boyutsal azaltma ve temsiline geliştirmek için yaygın olarak kullanılan bir tekniktir.

#### Spektral Gömme (Spectral Embedding, SG)

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

a. 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.

b. Ardından, derece matrisi  $D$  oluşturulur. Bu matris, her bir noktanın toplam benzerliklerini içerir:

$$D_{ii} = \sum_j W_{ij} \quad (12)$$

c. Laplacian matrisi  $L$  hesaplanır. Bu matris,  $L = D - W$  olarak hesaplanır.

d.  $L$  matrisinin en küçük özdeğerlerine ve bu özdeğerlere karşılık gelen özvektörlere bakılır. Genellikle en küçük  $k$  özdeğer ve bu özdeğerlere karşılık gelen özvektörler seçilir.

e. Seçilen özdeğerlere karşılık gelen özvektörler kullanılarak düşük boyutlu temsili ( $Y$ ) hesaplanır:

$$Y = \begin{bmatrix} y_1^1 & y_2^1 & \dots & y_k^1 \\ y_1^2 & y_2^2 & \dots & y_k^2 \\ \vdots & \vdots & \ddots & \vdots \\ y_1^m & y_2^m & \dots & y_k^m \end{bmatrix} \quad (13)$$

Bu işlem sonucunda,  $Y$  matrisi HSG verinin spektral boyutunu koruyarak düşük boyutlu bir uzamsal temsili sağlar. Yani, uzamsal boyut değişmezken, veri spektral boyutunda azaltılmış boyutta temsil edilir.

SG, hiperspektral verileri düşük boyutlu uzamsal temsillerde temsil etmek için kullanılabilir ve bu sayede verinin yapısını daha iyi anlamak ve analiz etmek için faydalıdır.

Yukarıda belirtilen boyut indirgeme yöntemleri, HSG verilerinin benzerliklerini korumak ve düşük boyutlu bir temsiline elde etmek amacıyla kullanılmaktadır. Bu yöntemlerin bir kısmı lineer yöntemlerken (TBA, NOMA, TDA ve BBA), bir kısmı ise lineer olmayan yöntemlerdir (YDG, SG ve t-SKG). Bu yöntemlerin uygulanması sonucunda HSG verilerinin boyutu indirgenmiş ve bu indirgenmiş veriler ile sınıflandırma uygulaması yapılarak en iyi yöntemin belirlenmesi amaçlanmıştır. Sınıflandırma işlemi için 3B-ESA yöntemi kullanılmıştır.

#### D. 3B-ESA Modeli

Bu çalışmada, hem uzamsal hem de spektral bilgilere erişmek amacıyla 3B-ESA modeli kullanılmıştır. 3B konvolüsyon işlemi, hacimsel HSG verilerine 3B çekirdeklerle uygulanmıştır. Bu yöntem, 3B özellik haritalarının oluşturulmasına imkan tanımış ve spektral bilgilerin yakalanmasını sağlamıştır. 3B konvolüsyon işleminin matematiksel karşılığı aşağıdaki gibidir:

$$v_{ij}^{xyz} = f \left( r_{ij} + \sum_{m=0}^{M_i-1} \sum_{b=0}^{B_i-1} \sum_{h=0}^{H_i-1} \sum_{w=0}^{W_i-1} k_{ijm}^{hwb} v_{(i-1)m}^{(x+h)(y+w)(z+b)} \right) \quad (14)$$

Burada  $v$ , özellik haritasındaki çıktı değişkenini ifade eder.  $B, H, W$  verinin sırasıyla spektral ve uzamsal boyutlar boyunca filtrenin boyutunu temsil eder.  $(b, h, w)$  filtre endeksleridir ve  $z, x, y$  sırasıyla 2 uzamsal 1 spektral boyuta karşılık gelen özellik haritasının dizinleridir.  $k$ , filtre parametreleri anlamına

Tablo 2. 3B-ESA modelinin ayrıntılı katman özeti.

Katman Türü	Boyut/Filtre Sayısı	Aktivasyon Fonksiyonu	Çıkış Şekli	Diğer Parametreler
Giriş Katmanı	$W \times H \times B$	-	(10x10x16)	-
Konvolüsyon Katmanı 1	3x3x3 (8 adet)	ReLU	(5x5x8)	Same Padding, Maksimum Havuzlama (2x2x2)
Konvolüsyon Katmanı 2	3x3x3 (16 adet)	ReLU	(3x3x4)	Same Padding, Maksimum Havuzlama (2x2x2)
Konvolüsyon Katmanı 3	3x3x3 (32 adet)	ReLU	(2x2x2)	Same Padding, Maksimum Havuzlama (2x2x2)
Tam Bağlı Katman 1	128	ReLU	(128)	Unutturma (0.4)
Tam Bağlı Katman 2	32	ReLU	(32)	Unutturma (0.4)
Tam Bağlı Katman 3	16	ReLU	(16)	Unutturma (0.4)
Çıkış Katmanı	$C$ (2)	Sigmoid	(2)	-

gelir.  $(i, j, m)$  sırasıyla giriş katmanı, çıkış katmanı ve özellik haritasının dizinleridir.  $M$ , özellik haritalarının sayısıdır,

dolayısıyla  $M_i$ ,  $i$ . katmanındaki özellik haritalarının sayısı anlamına gelir.  $r$ , bias terimidir.

Bu çalışmada, daha önceki araştırmamızda geliştirdiğimiz etkili bir 3B-ESA modeli kullanılmıştır [35]. Bu model, hacimsel neonatal hiperspektral veriler için başarılı sonuçlar elde etmiştir. 3B-ESA yapısı, Şekil 3'te gösterilmiştir. İlk başta, HSG giriş verilerinin boyutu  $W \times H \times S$  olarak temsil edilmiştir. Burada  $W$  ve  $H$ , uzamsal boyutları ifade ederken  $S$ , spektral boyutu belirtmektedir. Verilerin uzamsal boyutları  $W = H = 10$ 'dur. Başlangıçta 500-1000nm arasında seçilen 1538 spektrumdan oluşan bir spektral boyut mevcuttur. Ancak tüm spektrumlar kullanılmamış, boyut indirgeme yöntemleri kullanılarak spektral boyut  $B$ 'ye indirgenmiştir. Daha önceki çalışmamızda bir dizi temel bileşen değeri ile deneyler gerçekleştirilmiş ve en iyi sonuca temel bileşen sayısı 16 olduğunda ulaşılmıştır [35]. Bu nedenle bu çalışmada  $B$  değeri 16 olarak kabul edilmiştir.

Modelin geri kalan kısmında toplam üç konvolüsyon katmanı kullanılmıştır ve tüm konvolüsyon işlemlerine özgü olarak "same padding" (aynı boyutta sonuç üretme) uygulanmıştır. İlk konvolüsyon katmanında  $3 \times 3 \times 3$  boyutunda 8 filtre, ikinci konvolüsyon katmanında  $3 \times 3 \times 3$  boyutunda 16 filtre ve son konvolüsyon katmanında  $3 \times 3 \times 3$  boyutunda 32 filtre kullanılarak özellik haritaları oluşturulmuştur. Ayrıca, her bir konvolüsyon katmanının ardından boyutu azaltmak amacıyla  $2 \times 2 \times 2$  boyutunda maksimum havuzlama katmanı kullanılmıştır. Daha sonra, veriler, tam bağlı katmanlara girdi olarak sunulmak üzere tek boyutlu tensörlere dönüştürülmüş ve düzleştirme işlemi uygulanmıştır. Düzleştirme işleminden sonra, eklenen ilk tam bağlı katman 128 nöron, ikinci katman 32 nöron ve üçüncü katman 16 nöron içermektedir. Ayrıca, çıkış katmanında  $C = 2$  nöron kullanılarak sınıf tahmini sigmoid fonksiyonu ile gerçekleştirilmiştir. Tüm tam bağlı katmanlarından sonra unutturma katmanları kullanılmış ve unutturma değerleri 0.4 olarak ayarlanmıştır. Ayrıca modele ait katman özeti Tablo 2'de ayrıntılı olarak verilmiştir.

#### E. Performans Değerlendirme Ölçütleri

Bu çalışmada elde edilen sonuçları değerlendirmek için çeşitli performans değerlendirme ölçütleri kullanılmıştır. Bu ölçütler aşağıda detaylandırılmıştır.

- *Genel Doğruluk (GD)*: GD, doğru tahminlerin toplam veri sayısına oranıdır.

$$GD = \frac{(DP + DN)}{(DP + DN + YP + YN)} \quad (15)$$

DP (Doğru Pozitif): Doğru pozitif tahmin sayısı.

DN (Doğru Negatif): Doğru negatif tahmin sayısı.

YP (Yanlış Pozitif): Yanlış pozitif tahmin sayısı.

YN (Yanlış Negatif): Yanlış negatif tahmin sayısı.

- *Duyarlılık (Recall veya Doğru Pozitif Oran)*: Duyarlılık, gerçek pozitiflerin toplam pozitif sayısına oranıdır.

$$Duyarlılık = \frac{DP}{(DP + YN)} \quad (16)$$

- *Kesinlik (Precision veya Pozitif Tahmin Değeri)*: Kesinlik, gerçek pozitiflerin toplam pozitif tahmin sayısına oranıdır.

$$Kesinlik = \frac{DP}{(DP + YP)} \quad (17)$$

- *F-1 Skor*: F-1 Skoru, Duyarlılık ve Kesinlik değerlerinin harmonik ortalamasıdır ve bir denge ölçüsü olarak kullanılır.

$$F - 1 Skor = 2 * \frac{(Kesinlik * Duyarlılık)}{(Kesinlik + Duyarlılık)} \quad (18)$$

- *Kappa (Cohen's Kappa)*: Kappa, iki farklı teşhis arasındaki tutarlılığı değerlendirmek için medikal uygulamalarda sıklıkla kullanılan bir tekniktir [36]. Bu teknik kullanılarak iki farklı olasılık hesaplanmıştır;  $P_0$  gözlenen doğruluk,  $P_c$  ise bu durumun gerçekleşme olasılığıdır. Bu çalışmada, eşit sayıda test verisi kullanıldığından  $P_c$  %50 olarak alınmıştır.

$$Kappa = \frac{P_0 - P_c}{1 - P_c} \quad (19)$$

Tablo 3. Deneysel Sonuçlar. En iyi sonuçlar koyu renkle gösterilmiştir.

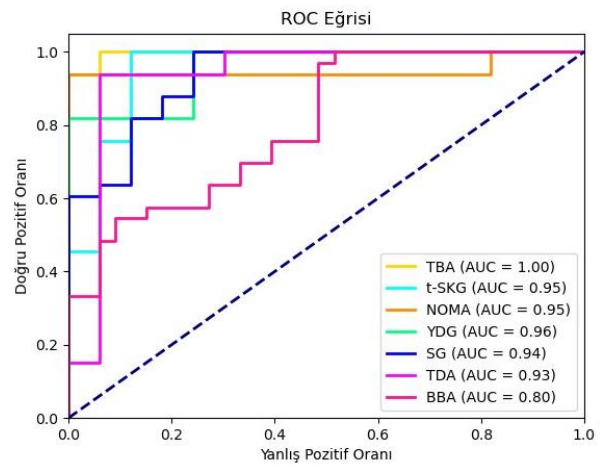
Yöntem	Performans değerlendirme metrikleri						
	GD	Duyarlılık	Kesinlik	F-1 Skor	Kappa	AUC	DRT (sn)
BBA	0.84	0.88	0.82	0.85	0.67	0.80	34.09
YDG	0.89	<b>0.96</b>	0.84	0.90	0.78	0.96	5.93
NOMA	<b>0.90</b>	0.93	0.90	<b>0.91</b>	<b>0.81</b>	0.95	4.73
TBA	<b>0.90</b>	0.90	<b>0.91</b>	0.90	<b>0.81</b>	<b>1.00</b>	<b>1.78</b>
SG	0.85	0.88	0.83	0.85	0.70	0.94	3.16
TDA	0.84	0.88	0.83	0.85	0.68	0.93	<b>1.71</b>
t-SKG	0.89	0.88	0.90	0.89	0.78	0.95	44.43

- **ROC Eğrisi (Receiver Operating Characteristic Curve):** ROC eğrisi, sınıflandırma modelinin farklı kesme noktalarında duyarlılık (recall) ve özgüllük (specificity) arasındaki ilişkiyi gösteren bir eğridir. Bu, modelin performansının bir görselleştirmesidir.
- **AUC:** AUC değeri, ROC eğrisinin altındaki alanı ifade eder ve bir sınıflandırma modelinin performansını tek bir sayısal değerle ölçer. AUC değeri 0 ile 1 arasında olur, 1 mükemmel bir sınıflandırma modelini temsil eder.
- **Boyut İndirgeme Süresi (Dimensional Reduction Time, DRT):** Boyut indirgeme yöntemlerinin uygulanması için gereken süreyi ifade eder. Yani, HSG verilerinin boyutunun azaltılması için geçen süreye karşılık gelir.

### III. DENEYSEL SONUÇLAR VE ANALİZ

Deneyler için toplamda 220 neonatal HSG verisi kullanılmıştır. Bu veriler, 110 hasta ve 110 sağlıklı bireye aittir. İlk aşamada, gürültü içermeyen 500-1000nm dalga boyu aralığındaki 1538 spektrum ele alınmıştır. Daha sonra boyut indirgeme yöntemleri kullanılarak spektral boyut 16'ya indirgenmiş ve bu veriler 3B-ESA modeline girdi olarak verilmiştir. 3B-ESA modeli, *Adam optimizer* kullanılarak eğitilmiş ve veriler ağa parçalar halinde gönderilmiştir. *Grup boyutu (batch size)* burada 64 olarak belirlenmiştir. Başlangıçta *öğrenme oranı (learning rate)* 0.001 olarak alınmış ve öğrenme hızını azaltmak için  $10^{-6}$  büyüklüğünde bir *bozunma (decay)* değeri belirlenmiştir. *Kategorik çapraz entropi*, kayıp fonksiyonu olarak seçilmiş ve tüm modeller 100 epoch boyunca eğitilmiştir. Modellerin genelleme yeteneğini artırmak amacıyla *K katlamalı çapraz doğrulama* yöntemi kullanılmıştır. Bu bağlamda, *K* değeri 5 olarak belirlenmiş ve değerlendirmeler bu doğrultuda gerçekleştirilmiştir. Sonuçları değerlendirmek için önceki bölümde açıklanan performans metrikleri kullanılmıştır.

Bu çalışmada, veri ön işleme ve model eğitim işlemleri, 64 GB RAM'e sahip bir iş istasyonunda bulunan NVIDIA GeForce GTX 1080 Ti üzerinde gerçekleştirilmiştir. Veri oluşturma, bilgi içeren spektrumların tanımlanması ve Savitzky-Golay filtresi gibi ön işleme adımları MATLAB 2022b kullanılarak gerçekleştirilmiştir. Boyut indirgeme işlemleri Scikit-learn 1.0.2 kullanılarak yapılmış, model eğitimi ve testi ise Python 3.9.13 ve Keras 2.10.0 kütüphanesi kullanılarak TensorFlow 2.10.0 arka ucu ile gerçekleştirilmiştir.



Şekil 4. ROC eğrisi ve AUC değerleri.

Tablo 3'te sunulan deneysel sonuçlara göre, *GD (Genel Doğruluk)* oranlarına göre en iyi sonuçların TBA ve NOMA yöntemleri kullanılarak elde edildiği gözlenmektedir. Diğer performans metriklerine bakıldığında, *Duyarlılık* değerinin YDG yöntemi ile en yüksek olduğu, *Kesinlik* ve *F-1 skor* için ise sırasıyla TBA ve NOMA yöntemlerinin en iyi sonuçları verdiği görülmektedir. *Duyarlılık* değeri, hasta olanların doğru bir şekilde sınıflandırılmasını gösterdiği için YDG'nin diğer yöntemlere göre daha etkileyici sonuçlar vermesi önemlidir. İki sınıflı uygulamalar özelinde önemli bir metrik olan Kappa değeri için ise yine TBA ve NOMA yöntemlerinin en iyi sonuçları verdiği görülmektedir.

DP ve YP arasındaki ilişkiyi ölçmek için AUC değerlerine bakıldığında, TBA'nın 1.0 oranıyla en iyi performansı gösterdiği belirlenmiştir (ROC eğrisi Şekil 4'te verilmiştir). Bunun sonucu olarak, sınıfların en doğru bir şekilde tahmin edildiği yöntemin TBA olduğu tespit edilmiştir. Veri boyutlarının aynı olması nedeniyle tüm yöntemler için eğitim ve test süreleri oldukça benzerdir, sırasıyla 0.13 sn ve 0.087 sn. Ancak boyut indirgeme için geçen süreler (DRT) arasında farklar bulunmaktadır. TDA kullanılarak en hızlı boyut indirme işlemine ulaşılsa da düşük başarı oranlarına sahiptir. TBA süresi de TDA'ya oldukça yakındır. Her iki yöntem de veri analizi, model eğitimi ve tahmin süreçlerini hızlandırmak için çok kısa bir sürede boyut indirme işlemini tamamlar. TBA'nın ve TDA'nın hızlı boyut indirme sürelerine sahip olmalarının sebebi, her ikisinin de lineer metotlar olmalarıdır. Ayrıca TBA'nın, temel bileşenleri ve doğrusal dönüşümü hızlı



bir şekilde hesaplayabilmesi, veri varyansını koruyabilmesi ve matematiksel olarak basit ve tekrarlanabilir bir yöntem olması, boyut indirme görevini hızlı bir şekilde tamamlamasına olanak tanır. Boyut indirme için en uzun süreye sahip yöntem ise t-SKG yöntemidir. Tüm metrikler değerlendirildiğinde, en iyi sonuçların TBA ile elde edildiği görülmektedir.

Genel bir değerlendirme yapıldığında, en iyi sonuçların lineer iki yöntem (TBA ve NOMA) kullanılarak elde edildiği görülse de, en düşük sonuçların yine lineer iki yöntem (BBA ve TDA) kullanılarak elde edildiği gözlemlenmektedir. Bu nedenle, tüm lineer boyut indirgeme yöntemlerinin HSG verileri için başarılı sonuçlar vereceği sonucuna varılmaz. Yöntem seçimi probleme özgüdür ve verisetinin özel gereksinimlerine bağlı olarak değişebilir.

#### IV. SONUÇ

Bu çalışmanın temel amacı, neonatal hiperspektral görüntü sınıflandırmasında boyut indirgeme yöntemlerinin etkinliğini 3B-ESA yöntemi ile karşılaştırmaktır. Toplam 220 neonatal

HSG verisi kullanılarak gerçekleştirilen deneyler, bu kritik medikal uygulama için en uygun boyut indirgeme yöntemlerinin tespit edilmesine yardımcı olmuştur.

Sonuçlar, doğrusal boyut indirgeme yöntemlerinden biri olan TBA'nın diğer yöntemlerle karşılaştırıldığında en iyi performansı verdiğini göstermektedir. Boyut indirgeme işlemleri, seçilen yöntemle ilgili olarak farklı sürelerde tamamlanmaktadır. TBA, boyut indirgeme süresi açısından oldukça hızlıdır, bu da anlamlı spektral özelliklerin daha kısa bir sürede elde edilebileceği anlamına gelir. Ayrıca, TBA'nın AUC değerlerine dayalı olarak en iyi performansı gösterdiği ve sınıfların en doğru şekilde tahmin edildiği sonucuna varılmıştır.

Sonuç olarak, bu çalışma, neonatal hiperspektral görüntü sınıflandırmasında başarılı sonuçlar elde etmek için farklı boyut indirgeme yöntemlerinin kullanılabilirliğini göstermektedir. Ancak, hangi yöntemin seçileceği, veriseti ve özel gereksinimlere bağlı olarak değişebilir. Bu sonuçlar, neonatal tıp alanında spektral görüntü analizi konusundaki ilerlemeleri desteklemekte ve klinik uygulamalarda potansiyel faydalar sunmaktadır.

#### TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK, proje numarası: 122E021) tarafından desteklenmiştir.

#### Yazarların Katkıları

**M. Cihan:** Veri küratörlüğü, Araştırma, Metodoloji, Yazılım, Yazım - orijinal taslak. **M. Çevik ve N. Yılmaz:** Veri toplama. **M. Konak ve H. Soylu:** Kaynaklar. **M. Ceylan:** Kavramsallaştırma, Metodoloji, Doğrulama, Yazım - inceleme ve düzenleme.

#### Çıkar Çatışmaları Beyanı

Yazarlar, bu makalede rapor edilen çalışmayı etkilediği düşünülebilecek bilinen herhangi bir rakip finansal veya kişisel ilişkileri olmadığını beyan etmektedir.

#### Araştırma ve Yayın Etiği Beyanı

Yazarlar, bu çalışmanın Araştırma ve Yayın Etiği İlkelerine uygun olduğunu beyan ederler.

#### REFERANSLAR

- [1] G. ElMasry and D. W. Sun, "Principles of hyperspectral imaging technology". In *Hyperspectral imaging for food quality analysis and control*, Academic Press, pp. 3-43, 2010.
- [2] W. Wu, Z. Zhang, L. Zheng, C. Han, X. Wang, J. Xu, and X. Wang, "Research progress on the early monitoring of pine wilt disease using hyperspectral techniques," *Sensors*, vol. 20, p. 3729, 2020.
- [3] Y. Q. Wan, Y. H. Fan, and M. S. Jin, "Application of hyperspectral remote sensing for supplementary investigation of polymetallic deposits in Huanishan ore region, northwestern China," *Scientific Reports*, vol. 11, p. 440, 2021.
- [4] J. Jia, Y. Wang, J. Chen, R. Guo, R. Shu, and J. Wang, "Status and application of advanced airborne hyperspectral imaging technology: A review," *Infrared Physics & Technology*, vol. 104, p. 103115, 2020.
- [5] M. Cihan, and M. Ceylan, "KÇ3B-ESA: Hiperspektral Görüntü Sınıflandırması için Yeni 3B Evrişimli Sinir Ağı ve Uzaktan Algılama Uygulaması," *Avrupa Bilim ve Teknoloji Dergisi, Ejosat Special Issue 2020 (ICCEES)*, pp. 65-71, 2020.
- [6] H. Pu, Q. Wei, and D. W. Sun, "Recent advances in muscle food safety evaluation: Hyperspectral imaging analyses and applications," *Critical Reviews in Food Science and Nutrition*, vol. 63, pp. 1297-1313, 2023.
- [7] M. Cihan, M. Ceylan, and A. H. Ornek, "Spectral-spatial classification for non-invasive health status detection of neonates using hyperspectral imaging and deep convolutional neural networks," *Spectroscopy Letters*, vol. 55, pp. 336-349, 2022.
- [8] C. Cucci, M. Piccolo, L. Chiarantini, G. Uda, L. Fiori, B. De Nigris, and M. Osanna, "Remote-sensing hyperspectral imaging for applications in archaeological areas: Non-invasive investigations on wall paintings and on mural inscriptions in the Pompeii site," *Microchemical Journal*, vol. 158, p. 105082, 2020.
- [9] M. Shimoni, R. Haelterman, and C. Perneel, "Hyperspectral imaging for military and security applications: Combining myriad processing and sensing techniques," *IEEE Geoscience and Remote Sensing Magazine*, vol. 7, pp. 101-117, 2019.
- [10] G. Bonifazi, G. Capobianco, R. Palmieri, and S. Serranti, "Hyperspectral imaging applied to the waste recycling sector," *Spectrosc. Eur.*, vol. 31, pp. 8-11, 2019.
- [11] M. Nourmand-Jadidi, F. Bovolo, and L. Bruzzone, "Water quality retrieval from PRISMA hyperspectral images: First experience in a turbid lake and comparison with sentinel-2," *Remote Sensing*, vol. 12, p. 3984, 2020.
- [12] G. Lu and B. Fei, "Medical hyperspectral imaging: a review," *J Biomed Opt.*, vol. 19, p. 10901, 2014.
- [13] M. Cihan, "Hiperspektral görüntüleme yöntemi kullanılarak yenidoğan sağlık durumlarının derin öğrenme metotları ile sınıflandırılması," Master's Thesis, Konya Teknik Üniversitesi, Konya, Türkiye, 2020.
- [14] M. Tortora, L. Gemini, I. D'Iglio, L. Uggia, G. Spadarella, and R. Cuocolo, "Spectral photon-counting computed tomography: a review on technical principles and clinical applications," *Journal of Imaging*, vol. 8, p. 112, 2022.
- [15] M., Cihan, and M. Ceylan, "Hyperspectral imaging-based cutaneous wound classification using neighbourhood extraction 3D convolutional neural network," *Biomedical Engineering/Biomedizinische Technik*, vol. 68, pp. 427-435, 2023.
- [16] L. Svoboda, J. Sperrhake, M. Nisser, C. Zhang, G. Notni, and H. "Proquitté. Contactless heart rate measurement in newborn infants using a multimodal 3D camera system," *Front Pediatr.*, vol. 10, p. 897961, 2022.
- [17] G. Morales, J. W. Sheppard, R. D. Logan, and J. A. Shaw, "Hyperspectral dimensionality reduction based on inter-band redundancy analysis and greedy spectral selection," *Remote Sensing*, vol. 13, p. 3649, 2021.
- [18] W. Zhao, and S. Du, "Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, pp. 4544-4554, 2016.
- [19] R. Zebari, A. Abdulazeez, D. Zeebaree, D. Zebari, and J. Saeed, "A comprehensive review of dimensionality reduction techniques for feature selection and feature extraction," *Journal of Applied Science and Technology Trends*, vol. 1, pp. 56-70, 2020.
- [20] I. T. Jolliffe, Ed., *Principal Component Analysis for Special Types of Data*. Springer New York, pp. 338-372, 2002.

- [21] A. Hyvärinen, "Independent component analysis: recent advances," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 371, p. 20110534, 2013.
- [22] J. W. Boardman, "Inversion of imaging spectrometry data using singular value decomposition," In *12th Canadian Symposium on Remote Sensing Geoscience and Remote Sensing Symposium*, vol. 4, pp. 2069-2072, 1989.
- [23] L. Van der Maaten, and G. Hinton, "Visualizing data using t-SNE," *Journal of machine learning research*, vol. 9, 2008.
- [24] S. T. Roweis, and L. K. Saul, "Nonlinear dimensionality reduction by locally linear embedding," *science*, vol. 290, pp. 2323-2326, 2000.
- [25] S. Sra, and I. Dhillon, "Generalized nonnegative matrix approximations with Bregman divergences," *Advances in neural information processing systems*, vol. 18, 2005.
- [26] U. Von Luxburg, "A tutorial on spectral clustering," *Statistics and computing*, vol. 17, pp. 395-416, 2007.
- [27] M. R. Haque, and S. Z. Mishu, "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)*, pp. 1-6, 2019.
- [28] H. Firat, M. E. Asker, and D. Hanbay, "Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN," *Remote Sensing Applications: Society and Environment*, vol. 25, p. 100694, 2022.
- [29] B. M. Devassy, and S. George, "Dimensionality reduction and visualisation of hyperspectral ink data using t-SNE," *Forensic science international*, vol. 311, p. 110194, 2020.
- [30] M. Huang, Q. Zhu, B. Wang, and R. Lu, "Analysis of hyperspectral scattering images using locally linear embedding algorithm for apple mealiness classification," *Computers and electronics in agriculture*, vol. 89, pp. 175-181, 2012.
- [31] M. M. Hossain, and M. A. Hossain, "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)*, pp. 141-144, 2019.
- [32] W. Huang, W. He, S. Liao, Z. Xu, & J. Yan, "Efficient SpectralFormer for Hyperspectral Image Classification," *Digital Signal Processing*, p. 104237, 2023.
- [33] M. Cihan and M. Ceylan, "Comparison of Linear Discriminant Analysis, Support Vector Machines and Naive Bayes Methods in the Classification of Neonatal Hyperspectral Signatures," *2021 29th Signal Processing and Communications Applications Conference (SIU)*, Istanbul, Turkey, pp. 1-4, 2021.
- [34] A. Savitzky, and M. J. Golay, "Smoothing and differentiation of data by simplified least squares procedures," *Analytical chemistry*, vol. 36, pp. 1627-1639, 1964.
- [35] M. Cihan, M. Ceylan, H. Soylu, and M. Konak, "Fast evaluation of unhealthy and healthy neonates using hyperspectral features on 700-850 Nm wavelengths, ROI extraction, and 3D-CNN," *IRBM*, vol. 43, pp. 362-371, 2022.
- [36] H. C. Kraemer, "Extension of the Kappa Coefficient," *Biometrics*, vol. 36, pp. 207-216, 1980.