



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



HİPERSPEKTRAL GÖRÜNTÜLEME YÖNTEMİ
KULLANILARAK YENİDOĞAN SAĞLIK
DURUMLARININ DERİN ÖĞRENME METOTLARI İLE
SINIFLANDIRILMASI

Mücahit CİHAN

YÜKSEK LİSANS TEZİ

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Temmuz-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mücahit CİHAN tarafından hazırlanan “Hiperspektral Görüntüleme Yöntemi Kullanılarak Yenidoğan Sağlık Durumlarının Derin Öğrenme Metotları ile Sınıflandırılması” adlı tez çalışması 16/07/2020 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Seral ÖZŞEN

Danışman

Doç. Dr. Murat CEYLAN

Üye

Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

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: 16.07.2020

ÖZET

YÜKSEK LİSANS TEZİ

HİPERSPEKTRAL GÖRÜNTÜLEME YÖNTEMİ KULLANILARAK YENİDOĞAN SAĞLIK DURUMLARININ DERİN ÖĞRENME METOTLARI İLE SINIFLANDIRILMASI

Mücahit CİHAN

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

Danışman: Doç. Dr. Murat CEYLAN

2020, 71 Sayfa

Jüri

Prof. Dr. Seral ÖZŞEN
Doç. Dr. Murat CEYLAN
Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

Yenidoğan bebeklerin sağlık durumlarının hızlı ve zararsız bir şekilde erken tespiti, bebeklerin hem hayatta kalmasını hem de yaşam kalitesini artırabilir. Bu doğrultuda, yenidoğan bebeklerin sağlık durumu tespitinde en iyi yöntem, bebeğe en az invaziv girişim yapılan yöntemdir (az dokun-çok gözlemle prensibi). Yenidoğan Yoğun Bakım Ünitesinde (YYBÜ) bulunan yenidoğanların yaşatılması ve sekellerinin azaltılmasında önemli unsurlardan birisi de gelişen teknolojilerden faydalanılarak oluşturulacak ön tanı ve takip sistemleridir. Hiperspektral görüntüleme (HSG), doku biyopsisinden kaçınarak doku hakkında tanısal bilgiler verdiği için, temassız olarak yenidoğan sağlık durumunun tespitinde güçlü bir araç olarak görülmektedir. Tez çalışmasında kullanılan hiperspektral görüntüler, Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesindeki 19 farklı yenidoğandan elde edilmiştir. Toplamda 32 hiperküp ve bu hiperküplerden elde edilen 6528 hiperspektral görüntü mevcuttur. HSG kullanarak yenidoğanların sağlık durumunu tespit etmek için 2 boyutlu Evrişimli Sinir Ağları (2B-ESA) ve 3 boyutlu Evrişimli Sinir Ağları (3B-ESA) modelleri kullanılmıştır. Komşuluk çıkarma yöntemi kullanılarak mini küpler oluşturulup 3B-ESA ile sınıflandırma işlemi yapılmıştır. Sınıflandırma performansını değerlendirmek için genel doğruluk, Cohen'in kappa katsayısı, hassasiyet ve özgüllük değerleri hesaplanmıştır. Komşuluk çıkarma yöntemi kullanılarak %100 genel doğruluk, %100 Cohen'in kappa katsayısı, %100 hassasiyet ve %100 özgüllük değerine ulaşılmış ve tüm veriler doğru sınıflandırılmıştır. Ayrıca komşuluk çıkarma yöntemiyle az eğitim verisi kullanılarak yüksek doğruluk oranları elde edilmiştir. Bu sonuçlar yenidoğanlara ait hiperspektral görüntülerin sınıflandırılmasında derin öğrenme yöntemlerinin oldukça başarılı olduğunu göstermektedir.

Anahtar Kelimeler: Hiperspektral Görüntüleme, Evrişimli Sinir Ağları, Derin Öğrenme, Yenidoğan Hastalık Tespiti, Spektral-Uzamsal Sınıflandırma, Komşuluk Çıkarma

ABSTRACT

MS THESIS

CLASSIFICATION OF HEALTH STATUS OF NEONATES WITH DEEP LEARNING METHODS USING HYPERSPECTRAL IMAGING

Mücahit CİHAN

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

Advisor: Assoc. Prof. Dr. Murat CEYLAN

2020, 71 Pages

**Jury
Prof. Dr. Seral ÖZŞEN
Assoc. Prof. Dr. Murat CEYLAN
Asst. Prof. Dr. Hüseyin Oktay ALTUN**

Rapid and harmless methods for early detection of the health status of premature babies can both ensure survival and improve these babies' quality of life. In this regard, the best method for health status detection of premature babies is the least invasive process (the principle of less touch/much more observation). In the neonatal intensive care unit (NICU), one of the important factors in keeping neonates alive and reducing their sequelae is the preliminary diagnosis and follow-up systems that will be created by using technologies that are still in the developmental stages. Hyperspectral imaging (HSI) is seen as a powerful tool for determination of neonatal health status because it provides diagnostic information about the disease. The hyperspectral images used in the thesis study were obtained from 19 different neonates in Selcuk University Medical Faculty Neonatal Intensive Care Unit. There are 32 hypercubes in total and 6528 hyperpectral images obtained from these hypercubes. 2 dimensional Convolutional Neural Networks (2D-CNN) and 3 dimensional Convolutional Neural Networks (3D-CNN) models were used to detect the health status of neonates using HSI. Mini cubes were created using the neighbourhood extraction method, and classification was done with 3D-CNN. In order to evaluate the classification performance, general accuracy, Cohen's kappa coefficient, sensitivity and specificity values were calculated. Using the neighbourhood extraction method, 100% overall accuracy, 100% Cohen's kappa coefficient, 100% sensitivity and 100% specificity were reached, and all data were classified correctly. In addition, high accuracy rates were obtained by using less training data with the neighboring method. These results show that deep learning methods are very successful in classifying hyperspectral images of neonates.

Keywords: Hyperspectral Imaging, Convolutional Neural Networks, Deep Learning, Neonates Health Detection, Spectral-Spatial Classification, Neighbourhood Extraction

ÖNSÖZ

Çalışma konumun belirlenmesinde ve çalışmamın hazırlanma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanlarını esirgemeyerek bana her fırsatta yardımcı olan danışmanım Sayın Doç. Dr. Murat CEYLAN'a, bölümümüzün değerli tüm öğretim elemanlarına, manevi anlamda daima yanımda olan aileme ve hiperspektral verileri kaydettiğim Specim IQ kamerasını sağlayan SPECIM® firmasına teşekkürlerimi sunarım. Ayrıca yenidoğan bebeklere ait görüntülerin alınması aşamasında yardımcı olan Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesi personeline ve öğretim üyeleri Prof. Dr. Hanifi SOYLU ve Doç. Dr. Murat KONAK'a teşekkür ederim.

Mücahit CİHAN
KONYA-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	7
3.1. Hiperspektral Görüntüleme.....	7
3.1.1. Spektrum.....	7
3.1.2. Görüntüleme düzeneği.....	8
3.1.3. Hiperküp ve spektral imza	9
3.1.4. Hiperspektral görüntülemenin diğer yöntemlerle karşılaştırılması	10
3.2. Doku Optiği	11
3.3. Temel Bileşen Analizi (TBA).....	13
3.4. Derin Öğrenme	14
3.4.1. Çok katmanlı algılayıcılar (ÇKA).....	15
3.4.2. Evrişimli sinir ağları (ESA)	15
3.4.2.1. Konvolüsyon katmanı	16
3.4.2.2. Aktivasyon fonksiyonları.....	28
3.4.2.3. Düzleştirme katmanı	31
3.4.2.4. Tam bağlı katman	31
3.4.2.5. Unutturma katmanı	33
3.5. Sınıflandırma Sonuçlarının Değerlendirilmesinde Kullanılan Performans Kriterleri.....	34
3.6. K-Katlamalı Çapraz Doğrulama	36
3.7. Komşuluk Çıkarma Yöntemi	36
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	38
4.1. Ölçüm Kurulumu ve Hiperspektral Verilerin Elde Edilmesi.....	38
4.2. Hiperspektral Verilerden Spektral İmzaların Çıkarılması ve İncelenmesi	41
4.2.1. Spektral imzalar arasındaki farklılıkların incelenmesi ile yenidoğanların sağlık durumlarının tespit edilmesi.....	43
4.3. İki Boyutlu Evrişimli Sinir Ağları Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi	46
4.3.1. 2B-ESA model tasarımı	47
4.3.1. Ağ yapısı	47
4.3.2. Parametre öğrenme süreci ve hiperspektral görüntü analizi için uygulama ..	48
4.3.3. 5-katlamalı çapraz doğrulama.....	49

4.3.4. 2B-ESA sonucunda elde edilen sınıflandırma sonuçları	49
4.4. Üç Boyutlu Evrişimli Sinir Ağları Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi	51
4.5. Komşuluk Çıkarma Yöntemi Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi	55
4.5.1. Tüm verilerin %50'sinin eğitim %50'sinin test olarak kullanılmasıyla elde edilen sınıflandırma sonuçları.....	59
4.5.2. Tüm verilerin %10'unun eğitim %90'ının test olarak kullanılmasıyla elde edilen sınıflandırma sonuçları.....	60
6. SONUÇLAR VE ÖNERİLER	61
6.1 Sonuçlar	61
6.2 Öneriler	63
KAYNAKLAR	64
EKLER	69
ÖZGEÇMİŞ	71

SİMGELER VE KISALTMALAR

Simgeler

(x, y)	: Uzamsal koordinatlar
H_a	: Hata
M_i	: i. katmandaki özellik haritası sayısı
\bar{X}, \bar{Y}	: Ortalama değer
X_i, Y_i	: Verinin orijinal değerleri
X_j	: Merkezlenmiş veri
a_k	: Uzamsal kayma
b_k	: Derinlemesine kayma
y_a	: Gerçek değer
y_a^p	: Tahmini değer
$\omega^{(k)}$: İlk ağırlık değeri
$\omega^{(k+1)}$: Güncellenmiş ağırlık değeri
*	: Konvolüsyon işlemi
$Elu(x)$: ELU aktivasyon fonksiyonu
K, L, P	: Hacimsel filtre boyutu
$L_Relu(x)$: Leaky ReLU aktivasyon fonksiyonu
M	: Özellik haritası sayısı
$Pr(a)$: İki farklı sınıf için genel doğruluk
$Pr(e)$: İki farklı sınıf meydana gelme olasılığı
$Relu(x)$: ReLU aktivasyon fonksiyonu
S	: Mini küp boyutu
$Selu(x)$: SELU aktivasyon fonksiyonu
W, H, D	: Hiperküp boyut değerleri
b, h, w	: Filtre endeksleri
k	: Filtre parametreleri
$kov(X, Y)$: Kovaryans matrisi
l	: Sıfır ekleme için boyut büyütme değeri
n	: Toplam eleman sayısı
r	: Bias değeri
$sig(x)$: Sigmoid aktivasyon fonksiyonu

$\tanh(x)$: Tanh aktivasyon fonksiyonu
v	: Özellik haritası çıktı değişkeni
z	: Spektral boyut
α	: Leaky ReLU fonksiyonunun eğimi
η	: Ağırlık öğrenme oranı
κ	: Cohen'in kappa katsayısı
λ	: Dalga boyu
ω	: Ağırlık değeri



Kısaltmalar

1B	: Bir Boyutlu
2B	: İki Boyutlu
3B	: Üç Boyutlu
AVIRIS	: Airborne Visible/Infrared Imaging Spectrometers
BT	: Bilgisayarlı Tomografi
ÇKA	: Çok Katmanlı Algılayıcılar
ÇÜA	: Çekişmeli Üretici Ağlar
DAB	: Diyabetik Anne Bebeği Hastalığı
DKD	: Doğuştan Kalp Defektleri Hastalığı
DN	: Doğru Negatif
DP	: Doğru Pozitif
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makineleri
EEG	: Elektroansefalografi
EKG	: Elektrokardiyografi
ESA	: Evrişimli Sinir Ağları
FAD	: Flavın Adenin Dinükleotidi
GD	: Genel Doğruluk
HS	: Hiperspektral
HSG	: Hiperspektral Görüntüleme
IR	: Kızılötesi
İA	: İlgi Alanı
MIR	: Orta Kızılötesi
MRG	: Manyetik Rezonans Görüntüleme
N	: Negatif
NADH	: Nikotinamid Adenin Dinükleotidi
NEC	: Nekrotizan Enterokolit Hastalığı
NIR	: Yakın Kızılötesi
OKH	: Ortalama Karesel Hata Fonksiyonu
OMH	: Ortalama Mutlak Hata Fonksiyonu
P	: Pozitif
PAH	: Pulmoner Hipertansiyon Hastalığı

PDA	: Patent Ductus Arteriosus Hastalığı
RDS	: Solunum Güçlüğü Sendromu Hastalığı
RODIS	: Reflective Optics System Imaging Spectrometers
TBA	: Temel Bileşenler Analizi
TOF	: Fallot Tetralojisi Hastalığı
UV	: Morötesi
VIS	: Görünür Spektrum
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
YYBÜ	: Yenidoğan Yoğun Bakım Ünitesi



1. GİRİŞ

Günümüzde uzaktan algılama teknolojilerinde devrim niteliğindeki gelişmelerden bir tanesi Hiperspektral Görüntüleme (HSG) ve analiz teknikleridir. Görüntüleme spektrometresi olarak adlandırılan HSG, yüzey materyallerinden yansıyan enerjinin dar ve bitişik çok sayıda dalga boyunda ölçülmesi anlamına gelmektedir (Lu ve Fei, 2014). Çok çeşitli elektromanyetik spektrumda 2 boyutlu görüntüler elde etmenin avantajına sahip olan HSG; medikal (Halicek ve ark., 2019; Kho ve ark., 2019; Baltussen ve ark., 2019), olay yeri tespiti (Edelman ve ark., 2012a; Li ve ark., 2014), adli tıp (Edelman ve ark., 2012b; Schuler ve ark., 2012) arkeoloji ve sanat koruma (Fischer ve Kakoulli, 2006; Liang, 2012), bitki örtüsü ve su kaynakları kontrolü (Hestir ve ark., 2008; Adam ve ark., 2010), gıda kalitesi ve güvenlik kontrolü (Gowen ve ark., 2007; Wu ve Sun, 2013) gibi birçok alana uygulanmıştır. Bu alanlarda kullanılan yaklaşımlar, her bir yüzey materyalinin farklı dalga boylarındaki ışığı soğurma ve yansıtma şiddetlerinde meydana gelen farklılıkları algılamak üzerinedir. Materyallerin gösterdiği karakteristik özellikler spektral imzalarında farklı olmasına sebep olmaktadır. Bu spektral imzalar kullanılarak çeşitli uygulamalar için sınıflandırma işlemleri gerçekleştirilmektedir.

HSG, ilk olarak medikal uygulamalar için ortaya çıkmış bir görüntüleme yöntemidir ve hastalık teşhisinde önemli potansiyele sahiptir. Biyolojik yapıların homojen olmamasından dolayı dokuya verilen ışık, hemoglobinde, melaninde ve suda emildiği için çoklu yayılıma uğrar. Hastalığın ilerlemesi sırasında doku tarafından emilen, yansıtılan ve iletilen ışık miktarının değiştiği varsayılmaktadır. HSG tarafından yakalanan, dokudan yansıyan ve iletilen ışık miktarı algılanarak, doku patolojisi, morfolojisi ve bileşimi hakkında nicel tanısal bilgiye ulaşmak mümkündür.

Dünya Sağlık Örgütü (DSÖ) verilerine göre dünya genelinde her yıl 15 milyon bebek, 37. gebelik haftasından önce dünyaya gelmektedir (WHO, 2018). 37. gebelik haftasından önceki doğum olarak tanımlanan erken doğum, yenidoğan ölümlerinin önemli bir nedenidir (Lawn ve ark., 2014). Yüksek ölüm oranlarının önüne geçmek için yenidoğanların sağlık durumunun anlık olarak takip edilmesi büyük bir öneme sahiptir. Yenidoğan Yoğun Bakım Ünitelerinde (YYBÜ) yer alan kuvözler içerisinde bakım ve tedavileri yapılan erken doğan ve çok düşük doğum ağırlığına sahip olan yenidoğanların dakikalar içerisinde vücut fonksiyonlarında gösterdikleri değişimlerin hızlı bir şekilde tespit edilmesi yenidoğanların sağlık durumlarının takibi için çok önemlidir.

Yenidoğan sağ kalımı ve kaliteli yaşamı için bebek takibinde en iyi yöntem, bebeğe en az invaziv girişim yapılan yöntemdir (az dokun-çok gözlemler prensibi). Yenidoğan yoğun bakım ünitesinde bulunan bebeklerin yaşatılması ve kalıcı sağlık sorunlarının azaltılmasında önemli unsurlardan birisi de gelişen teknolojilerden faydalanılarak oluşturulacak yeni sistemlerdir.

Son yıllarda, hiperspektral kamera teknolojisindeki gelişmeler, görüntü analiz yöntemleri ve hesaplama gücü, tıp alanındaki birçok uygulamanın yapılabilmesini mümkün kılmaktadır (Lu ve Fei, 2014). Martin ve ark., 2006 yılında bir fareye enjekte edilen tümörü tespit etmek için HSG kullanmış ve farklı dalga boylarındaki spektral imzaları inceleyerek tümör tespitini gerçekleştirmişlerdir. Bir başka çalışmada Lu ve ark., 2014'te HSG kullanarak non-invaziv bir şekilde kanser tespiti için Destek Vektör Makinesi (DVM) algoritması ile sınıflandırma çalışması yapmışlardır. Akbari ve ark., 2011 yılında mide kanseri tespiti için HSG kullanmışlar ve tümürlü bölgeyi yüksek doğruluk ile tespit etmişlerdir. Kurtuldu ve ark., 2018'de eritrosit hücrelerini analiz etmek için HSG kullanmıştır. Bilirubin ve hemoglobin değerlerindeki değişimlerin HSG ile incelendiği çalışmalar mevcuttur (Sorg ve ark., 2005; Edelman, 2014; Sakota ve ark., 2015). Tüm bu çalışmalar incelendiğinde HSG, invaziv girişim olmamasından, doku hakkında tanısal bilgiler sağlamasından ve farklı dalga boylarında iki boyutlu görüntüler elde edebilmesinden dolayı yenidoğan sağlık durumu tespiti için büyük bir potansiyele sahiptir.

Derin öğrenme yöntemlerinden birisi olan evrişimli sinir ağları günümüzde genellikle görüntü sınıflandırma uygulamaları için kullanılmaktadır. Hiperspektral görüntülerin sınıflandırıldığı birçok çalışmada evrişimli sinir ağları kullanılmıştır. ROSIS (Reflective Optics System Imaging Spectrometers) ve AVIRIS (Airborne Visible/Infrared Imaging Spectrometers), HS veri setlerini kullanarak yapılmış birçok çalışma mevcuttur. Hu ve ark., 2015; Yue ve Ma, 2016; Luo ve ark., 2018; Roy ve ark., 2019 ve Yu ve ark., 2019'da, farklı evrişimli sinir ağı modelleri ve farklı algoritmalar kullanılarak hiperspektral görüntüleri sınıflandırmışlar ve bu çalışmaların sonucunda yüksek başarımlar elde etmişlerdir. Bu çalışmalar incelendiğinde evrişimli sinir ağlarının hiperspektral görüntü sınıflandırılmasında etkili sonuçlar verdiği kanısı ortaya çıkmaktadır.

Literatürde Hiperspektral Görüntüleme ve evrişimli sinir ağları ile ilgili birçok çalışma olmasına rağmen medikal çalışma sayısı sınırlıdır. Örneğin, Kumar ve ark., 2016'da *ImageCLEF medical Subfigure Classification* HS verisetini kullanarak 2 boyutlu evrişimli sinir ağı ile verileri sınıflandırmışlardır.

HSG ve derin öğrenme yöntemleri ile yenidoğanların hastalık durumlarının tespiti ile ilgili bir çalışma yoktur. Bu tez kapsamında yenidoğan bebeklerden alınan hiperspektral görüntülerin derin öğrenme yöntemleri ile sınıflandırılması gerçekleştirilmiştir. Yenidoğan bebeklerden ilgi alanları (İA) belirlendikten sonra 2B ve 3B konvolüsyon katmanları verilere uygulanarak özellik haritaları çıkarılmış ve sınıflandırma işlemi gerçekleştirilmiştir. Yenidoğan bebeklere ait hiperspektral görüntüler Specim IQ hiperspektral kamera kullanılarak Selçuk Üniversitesi Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesinde bulunan hasta ve sağlıklı yenidoğan bebeklerden elde edilmiştir.

2. KAYNAK ARAŞTIRMASI

Akbari ve arkadaşları, 2011 yılında, prostat kanseri tespiti için hiperspektral görüntü verilerini analiz ederek gelişmiş bir görüntü işleme ve sınıflandırma yönteminin kullanılmasını önermişlerdir. Bu çalışmada, bir fareye tümör enjekte ettikten sonra spektral imzalar hem kanserli hem de normal dokulardan elde edilmiş ve incelenmiştir. Bu spektral imzaları kullanılarak sayısal analizlerle prostat kanserinin kolaylıkla tespitinin yapılabileceğini göstermişlerdir.

2014 yılında Lu ve arkadaşları, baş ve boyun kanseri tespiti uygulamasında HSG için tensör modellemesine dayanan spektral-uzamsal sınıflandırma modelini tanımlamışlardır. Kullandıkları yöntemle hiperküpün hem uzamsal hem de spektral özelliklerini karakterize etmişler ve temel bileşenler analizini kullanarak boyut azaltma işlemi yapmışlardır. Bir hayvana ait baş ve boyun kanseri modelinde, önerilen sınıflandırma yöntemi ile, sırasıyla %93,7 hassasiyet ve %91,3 özgüllük ile tümör ve normal dokular arasında ayırım yapmışlardır. Bu çalışmadan elde edilen sonuçlar, HSG'nin spektral-uzamsal sınıflandırma yöntemleri ile, kanserli dokuların invaziv olmayan bir şekilde doğru ve kantitatif olarak tespit edilebileceğini göstermiştir.

Li ve arkadaşları, 2017, hiperspektral görüntüleme yöntemi ile kırmızı ve beyaz kan hücrelerini ayırt etmek için derin evrişimli sinir ağı tabanlı bir yöntem önermişlerdir. İki gerçek hiperspektral görüntü veri seti kullanılarak elde edilen deneysel çalışmalar neticesinde, evrişimli sinir ağlarının hiperspektral verilerin sınıflandırılmasında iyi sonuçlar verdiğini belirtmişlerdir. Ayrıca, destek vektör makinesi algoritması sonucu ile kendi buldukları sonucu karşılaştırmışlar ve evrişimli sinir ağları ile hem uzamsal ve hem de spektral özellikler elde edildiğinden, kendi yöntemlerinin hiperpektral veri sınıflandırması için daha iyi performans sağladığını tespit etmişlerdir.

Yine 2017 yılında Ma ve arkadaşları, hiperspektral verilerle baş ve boyun kanserinin tespiti için bir derin öğrenme yöntemi önermişlerdir. Derin öğrenme algoritması, özellikleri hiyerarşik olarak öğrenebildiğinden, öğrenilen özelliklerin el yapımı özelliklerden daha ayırt edici olduğunu belirtmişlerdir. Her bir piksel için tümörlü ve normal dokuyu sınıflandırmada evrişimli sinir ağını kullanmışlardır. Önerilen sınıflandırma yöntemi ile, tümör taşıyan 12 fareden elde edilmiş hiperspektral görüntüler içeren hiperküp üzerinde değerlendirmeler yapmışlar ve %91.36 başarı elde etmişlerdir. Yapmış oldukları bu çalışma derin öğrenme yöntemlerinin hayvan modellerinde baş ve

boyun tümörlerini tespit etmek için hiperspektral görüntüleme uygulanabileceğini göstermiştir.

Halicek ve arkadaşları 2017 yılında, skuamöz hücreli karsinom, tiroid kanseri ve normal baş, boyun dokusu örneklerini sınıflandırmak için evrişimli sinir ağını kullanmışlardır. ESA sınıflandırması, baş ve boyun kanseri konusunda uzmanlaşmış bir patolog tarafından doğrulanmıştır. Elde edilen sonuçlar, HSG ile baş ve boyun kanseri hastalarına ait cerrahi örneklerin otomatik doku sınıflandırması için derin öğrenme potansiyelini göstermiştir.

Farklı spektral dalga boylarında biyolojik örneklerin görüntülerini yakalayabilen bir hiperspektral mikroskop sistemi Kurtuldu ve ark. tarafından 2018 yılında geliştirilmiştir. Bu sistemle, kan örneğindeki kırmızı kan hücrelerini çeşitli dalga boylarında analiz etmişler ve kırmızı kan hücrelerinin (eritrositler) yerlerini belirlemek için görüntü sınıflandırması yapmışlardır. Her eritrositin hücre merkezinde sitoplazma, hücre kenarı, hücre dışı sıvı ve soluk alanın saptanmasını başarıyla gerçekleştirmişlerdir. Ayrıca 520 ve 540 nm arasındaki dalga boylarında elde edilen görüntülerin soluk alandaki piksel sayısını ve eritrosit hücresine ait pikselleri ayırt etmek için en iyi aralık olduğunu göstermişlerdir.

Roy ve arkadaşları 2019 yılında, hiperspektral görüntüleri sınıflandırmak için komşuluk çıkarma yöntemini kullanarak hibrit bir 3B ve 2B evrişimli sinir ağı modelini tanıtmışlardır. Çalışmada önerdikleri HybridSN modeli ile, 3B evrişim kullanarak hem uzamsal hem de spektral özellikleri, 2B evrişim kullanarak daha anlamlı uzamsal özellikleri çıkarmışlardır. Diğer yaklaşımlarla karşılaştırdıklarında, ROSIS ve AVIRIS veri setleri üzerinde yapılan çalışmalar ile, önerilen yöntemin üstünlüğünü doğrulamışlardır. Önerilen model, 3B evrişimli sinir ağı modelinden hesaplama maliyeti olarak daha iyi sonuçlar vermiştir. Ayrıca model, küçük eğitim verileri ile bile üstün performans göstermiştir.

Yine 2019 yılında Lu ve Fei, hiperspektral görüntülemenin geniş bir doku alanını ve spektrumu yakalayabiliyor olması nedeniyle, çeşitli derin öğrenme yöntemleri kullanılarak sınıflandırmalar yapılabileceğini ve bunun sonucunda rahim ağzı kanseri, doku tümörü, cilt kanseri, kolon kanseri, meme kanseri, mide-bağırsak parankimaları, yumurtalık kistleri, prostat kanseri, oral doku lezyonları, beyin tümörü gibi kanser ve kist benzeri oluşumların belirlenmesinde etkili bir araç olduğunu ve birçok çalışma ile ortaya koyulduğunu araştırma makalelerinde belirtmişlerdir.

Audebert ve arkadaşları ise, hiperspektral sınıflandırma için önerilen güncel derin öğrenme yaklaşımlarını gözden geçirmişler ve derin sinir ağlarının uygulanmasında ortaya çıkan sorunları ve zorlukları tanımlamışlardır.

Kaynak araştırmasından da anlaşılacağı üzere, hiperspektral görüntüleme ve derin öğrenme yöntemleri kullanılarak yenidoğan bebeklerin sağlık durumlarının tespiti ile ilgili bir çalışma mevcut değildir. Bu yönüyle gerçekleştirilen tez çalışması ilgili alan için bir ilk niteliği taşımaktadır.



3. MATERYAL VE YÖNTEM

3.1. Hiperspektral Görüntüleme

Hiperspektral Görüntüleme, uzaktan algılama teknolojisi ve spektroskopinin bir araya gelmesiyle ortaya çıkmış görüntüleme yöntemidir. Aynı uzamsal bölge için farklı dalga boylarında yüzlerce görüntü toplar (Chang, 2003). İnsan gözü retinasında renkli ışık için üç reseptör bulunur. Birinci reseptör kırmızı ışığa, ikinci yeşil ışığa ve son olarak üçüncü reseptör ise mavi ışığa duyarlıdır. Bu üç renk reseptörü ile insanlar elektromanyetik spektrum bandında görünür spektrumda (VIS) bulunan bir milyondan fazla farklı renk tonunu algılayabilmektedir. İnsan gözü sadece 3 farklı reseptöre sahipken, hiperspektral görüntüleme, görünür bölgenin haricinde yakın kızılötesini (NIR) ve orta kızılötesinin (MIR) bir kısmını da içine alarak, dar ve bitişik çok sayıda dalga boyu aralığında ışığın sürekli spektrumunu ölçer. Toplanan veriler, 2 boyut uzamsal (x, y) bilgiyi, 1 boyut spektral (λ) bilgiyi içeren 3 boyutlu veri kümeleri oluşturur.

3.1.1. Spektrum

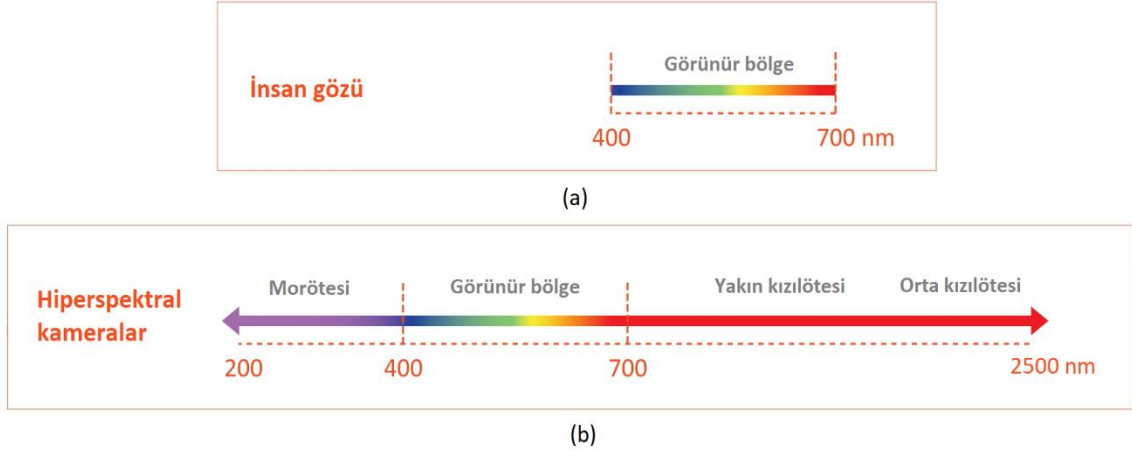
Farklı dalga boylarındaki ışık miktarına spektrum denir. Hedeften ne kadar ışık yayıldığını, yansıtıldığını veya iletildiğini gösterir. Optikten de bilindiği üzere bir cisme gelen ışık ya bu cisim tarafından emilir ya cismin içinden geçerek iletilir ya da geri yansıtılır (Şekil 3.1). Bir cisim için ise emilen, yansıyan ve iletilen ışınım miktarları dalga boyuna bağlı olarak değişmektedir (SPECIM, 2020a)



Şekil 3.1. Cismin gelen ışığa gösterdiği tepki (SPECIM, 2020a)

Normalde insan gözü 3 banttaki (R, G, B) görüntüleri algılayabildiği için elektromanyetik spektrum bandında görünür bölge (Şekil 3.2 (a), 400 ve 700 nm dalga boyu aralığı) dışındaki görüntüleri algılayamaz. Bu bölge, bandın çok dar bir aralığını kapsar. Hiperspektral görüntüleme ise bandı birçok spektruma böler ve bu spektrum 400

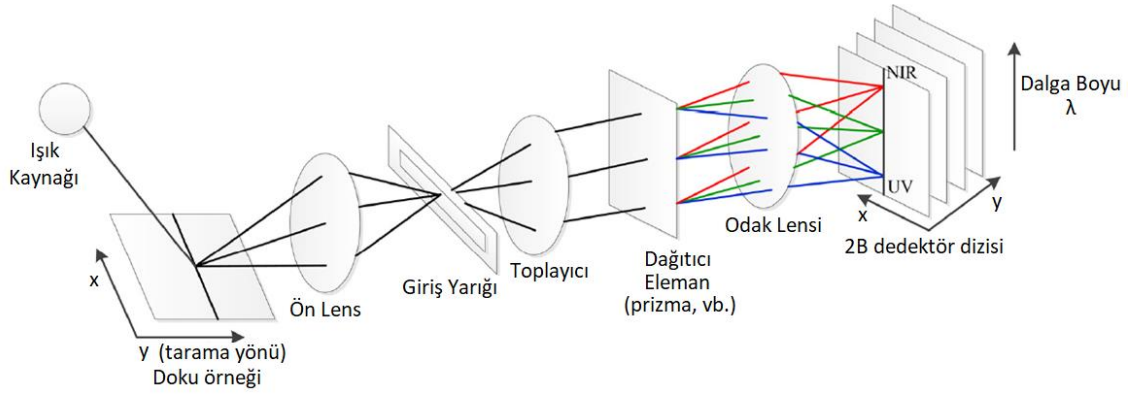
nm ve 2500 nm aralığındadır (Şekil 3.2 (b)). Bu aralık görünür bölgeyi içine aldığı gibi hem yakın kızılötesini hem de orta kızılötesinin bir bölümünü de içine almaktadır. Görüntüyü birçok banda ayıran bu yöntem sayesinde çıplak gözle görünenden daha fazla spektrumları kavrayabilme fırsatımız olur.



Şekil 3.2. Spektrum aralıkları (a) görünür bölge (b) hiperspektral kameralarla elde edilebilecek bölge

3.1.2. Görüntüleme düzeneği


Bir HSG sistemi temel olarak ışık kaynağı, dalga boyu dağılım cihazları ve alan dedektörlerinden oluşur. HSG sisteminin mekanizmalarını göstermek için, tipik bir diyagram örnek olarak Şekil 3.3'te gösterilmiştir. Işık kaynağı tarafından aydınlatılan bir doku örneği, ön lens içinden, sadece dar bir çizgiden ışığı geçiren giriş yarığına yansıtılır. Birleştirmeden (toplayıcı) sonra, spektrometre içinde bulunan prizmaya benzer optik bileşen, spektrometreye ulaşan ışığı dar ve birbirini takip eden çok sayıda dalga boyu bandına ayırır. Yarık genişliği, aynı zamanda spektrografa giren ışığın miktarını kontrol eder. Bu şekilde, yarık tarafından tanımlanan çizgi boyunca her piksel aralığı için, karşılık gelen bir spektrum, dedektör dizisinin bir sütununa yansıtılır. Bu nedenle, bir doku örneğinde hedeflenen alanın her bir çizgisi, bir uzamsal boyut ve bir spektral boyut ile dedektöre 2 boyutlu bir görüntü olarak yansıtılır. Doku örneğini tarayarak veya kameraları bir doğrusal dizin veya çizgi tarama tarzında doku örneği boyunca hareket ettirerek, bir HS kamera, bitişik çizgiler için 2 boyutlu görüntüler toplayarak iki uzamsal boyutta ve bir spektral boyutta hiperküp oluşturur. Ayrıca, yüzeyden gelen enerji her bir bant için ayrı bir dedektör ile ölçülür (Lu ve Fei, 2014).



Şekil 3.3. Hiperspektral görüntüleme sisteminin diyagramı

3.1.3. Hiperküp ve spektral imza


Hiperspektral kamera ile elde edilen görüntüler, ilk iki boyut uzamsal, üçüncü boyut spektral bilgi olmak üzere, üç boyutlu hiperspektral veri küpü (Hiperküp) olarak ifade edilir (Manolakis ve ark., 2016). İki boyut normalde bir veriyi (x,y) uzamsal koordinatlarında ifade eder. Hiperspektral görüntülerde ise her bir bant aralığı için bir katman olmak üzere z ekseninde yüzlerce görüntü vardır. Şekil 3.4 (b)'de bir hiperküp gösterilmiştir. Burada yer verildiği gibi hiperküp elde edildikten sonra bir pikselin farklı dalga boyları altındaki spektral değerleri kullanılarak veya bir dalga boyunda tüm piksellerin spektral değerleri kullanılarak spektral imzalar (Şekil 3.4 (a)) çıkarılmakta ve analizler gerçekleştirilmektedir. Ayrıca Şekil 3.4 (c)'de tek dalga boyu için elde edilmiş 2 boyutlu görüntü gösterilmiştir.



Şekil 3.4 Hiperspektral görüntüleme ile elde edilen (a) bir piksele ait spektral imza (b) bir hiperküp görüntüsü (c) tek bir dalga boyuna ait görüntü

3.1.4. Hiperspektral görüntülemenin diğer yöntemlerle karşılaştırılması

Diğer görüntüleme yöntemlerinden (multispektral, termal, RGB görüntüleme vs.) farklı olarak hiperspektral görüntülemenin en belirgin özelliği, çok daha fazla banda sahip olmasıdır. Fakat alıcıları hiperspektral yapan en önemli özellik bant sayısından çok, bantların birbirine ne kadar bitişik olduğudur.



Şekil 3.5 Hiperspektral görüntü ile RGB görüntü arasındaki karşılaştırma. Hiperküp, her dalga boyunda iki boyutlu bir görüntünün üç boyutlu veri kümesidir. Sol kısım, görüntüdeki bir pikselin yansıma eğrisidir (spektral imza). RGB renkli görüntünün sırasıyla kırmızı, yeşil ve mavi dalga boylarında üç görüntü bandı vardır. Sağ kısım, RGB görüntüsündeki bir pikselin yoğunluk eğrisidir.

Şekil 3.5'te hiperspektral görüntü ile RGB görüntü arasındaki karşılaştırma verilmiştir. Vücudun detayı gibi görünür özellikler 400 ila 700 nm dalga boyları arasında elde edilir. Termal görüntüleme kızılötesi dalga bölgesinde, yani 750 ila 1400 nm arasında çalıştığından, bu özellikler elde edilemez. Hiperspektral görüntüleme ise 400 ila 2500 nm arasında çalıştığından hem görünür hem de kızılötesi özellikler elde edilebilmektedir. Ayrıca, termal görüntüleme bize bir bant sağlarken, hiperspektral görüntüleme ise 100'den fazla ayrı bant sağlamaktadır. Bu bantlar kullanılarak, dokuya ait spektral imzanın çıkarılması ve renkli görüntülerin elde edilmesi gibi uygulamalar gerçekleştirilebilmektedir. Tablo 3.1'de hiperspektral görüntülemenin diğer yöntemlerle karşılaştırılması gösterilmiştir.

Tablo 3.1 Hiperspektral görüntülemenin bant sayısı ve bant genişliği bakımından diğer yöntemlerle karşılaştırılması

	RGB Görüntüleme	Termal Görüntüleme	Multispektral Görüntüleme	Hiperspektral Görüntüleme
Bant sayısı (Adet)	3	1	5-10	100+
Bant genişliği (nm)	400-700	750-1400	400-900	400-2500

3.2. Doku Optiđi

Biyolojik dokuya verilen ışık, doku boyunca yayılırken çoklu saçılma ve sođurma olaylarından geđer (Patterson ve ark., 1991). Biyolojik dokular, optik özelliklerde uzamsal deđişikliklere sahip bileşimde farklı cinstedir. Saçılma, kırılma endeksinde uzamsal bir deđişiklik olduğunda meydana gelir (Joel ve Tuan, 2003). Hücresel ortamdaki önemli dağılımlar, büyüklükleri 100 nm ila 6000 nm arasında çalışan alt hücre organelleridir. Örneđin, mitokondri organelleri arasında baskın saçılım vardır. İçinde akan lipit zarlarının ve lipit kıvrımlarının yapısı, mitokondriye, çevreleyen sitoplazmaya karşı yüksek bir optik kontrast verir ve gözlenen güçlü saçılma etkilerini üretir. Hücrelerin şekli ve büyüklüğü, birkaç mikron ve daha büyük boyutlarda olan farklı doku tipleri arasında deđişmektedir (Joel ve Tuan, 2003). Hücreler ve hücre dışı proteinlerden oluşan destek dokularının saçılma özellikleri, küçük ölçekli homojen olmayan maddeler ve oluşturdukları yapılarıdaki büyük ölçekli deđişikliklerden kaynaklanır (Lu ve Fei, 2014).

Işıđın biyolojik dokulara nüfuz etme derinliđi, dokunun ışığı ne kadar güçlü emdiğine bađlıdır. Çođu doku, 600 ila 1300 nm arasında deđişen, terapötik pencere içinde önemli miktarda ışık girmesine izin verecek kadar zayıf emicilerdir. Terapötik pencerede saçılma aşırı emilimde olduğundan yayılan ışık dađınık hale gelir. Doku emilimi, moleküler bileşimin bir fonksiyonudur. Moleküller, fotonların enerjisi iç enerji durumları arasındaki bir aralıkla eşleştiginde fotonları emer ve kuantum durumları arasındaki geđiş, türlerin seçim kurallarına bađlıdır. Sođurma işleminde sırasında, belirli dalga boylarında iyi tanımlanmış bir molekülün iki enerji seviyesi arasındaki geđişler, tanısal amaçlar için molekülün spektral imzası olarak işlev görebilir (Zhang ve ark., 2013). Örneđin, sođurma spektrumları, kanserin iki ayırt edici özelliđini ortaya çıkaran: anjiyogenez ve hipermetabolizma, hemoglobinin oksijen satürasyonunu ve konsantrasyonunu karakterize eder (Wang ve Wu, 2009). Işıđı emen doku bileşenlerine kromofor denir. Görünür dalga boyları için en önemli kromoforlardan bazıları kan ve melanin olup, dalga boyu arttıkça sođurma katsayısı azalır. IR dalga boyları için önemli emici kromofor su iken, morötesi (UV) dalga boyları için birincil emiciler, protein ve amino asitlerdir (Welch ve ark., 2010).

Doku bileşenleri tarafından emilen ışık, floresan ve fosforesan da dahil olmak üzere, ısıya dönüştürülür veya ışıldama formunda yayılır (Roggan ve ark., 1995). Endojen floresan kromoforlarından kaynaklanan floresan ayrıca otofloresan olarakta adlandırılır.

Tipik olarak UV veya VIS bölgesinde meydana gelen ışık, doku moleküllerini uyarır ve floresan emisyonunu indükler. Endojen floroforların çoğu, dokunun yapısal matrisi veya çeşitli hücrel metabolik yollar ile ilişkilidir (Freeberg ve ark., 2007). Yapısal matristeki en yaygın floroforlar kollajen ve elastin iken, hücrel metabolizmada yer alan baskın floroforlar nikotinamid adenin dinükleotidi (NADH), flavin adenin dinükleotidi (FAD) ve lipopigmentlerdir (Tuan ve Brian, 2003). Bu intrinsik floroforlar, farklı güçlü yönler sergiler ve UV ve VIS bölgelerinde spektral aralıkları kapsar. Örneğin, 300 ve 400 nm arasında eksitasyon kullanan kollajen veya elastinden oluşmuş floresanlar, çeşitli doku tiplerini, örneğin epitel ve bağ dokusunu ayırt etmek için kullanılabilen 400 ila 600 nm arasındaki geniş emisyon bantlarını gösterir. Farklı hastalık durumlarındaki hücreler genellikle farklı yapılara sahiptir veya farklı floresan emisyon spektrumları ile sonuçlanan farklı metabolizma oranlarına maruz kalırlar. Bu nedenle, floresan görüntüleme, harici floresan ajanları uygulamadan dokuların gerçek zamanlı olarak teşhis edilmesine yönelik dokuların araştırılmasını mümkün kılar.

Gelen ışık doğrudan doku yüzeyine yansıtılabilir veya doku yoğunluğundaki (membranlar, çekirdekler vb.) rastgele uzamsal değişikliklerden dolayı dağılıbilir ve doku yüzeyine tekrar gönderilebilir (Roggan ve ark., 1995). Işık, çoklu saçılma nedeniyle rasgele hale gelir ve bu, doku içindeki derin saçılma ve emilim bileşenleri hakkında bilgi sağlayan, dağınık yansıma olarak bilinir (Sasha ve ark., 2011). Ölçülen yansıtma sinyali, doku içinde çeşitli örnekleme derinliklerini örnekleyen ışığı temsil eder ve bu nedenle, belirli bir doku hacmi üzerindeki özelliklerin ortalama bir ölçümüdür. Saçılma ve soğurma sinyallerinin kökenini bilmek, yansıtma verilerinin doğru bir şekilde modellenmesini ve yorumlanmasını kolaylaştıracaktır. Epitel dokusundan ölçülen yansıtma sinyali, dokunun yapısal ve biyokimyasal özellikleri ile belirlenir; bu nedenle, optik özelliklerde meydana gelen değişiklikler, invaziv olmayan bir şekilde doku mikro ortamını araştırmak için kullanılabilir (Sasha ve ark., 2011). Hiperplazi, nükleer kalabalık, hücre dışı matristeki kollajenin matris metaloproteinazlar tarafından parçalanması ve hastalık ilerlemesi ile ilişkili artan nükleer / sitoplazmik oran dahil olmak üzere doku morfolojisindeki değişiklikler saçılma sinyallerini etkileyebilir. Hastalıklar ilerledikçe, hemoglobin emilimi anjiyogenez ve doku hipoksisi vs.'den etkilenebilir. Bu nedenle hastalık durumlarındaki değişiklikler, dokudan yansıyan ışık modellerinde karşılık gelen ilgili değişikliklere sebep olmaktadır.

Yansıyan ışığın ölçülmesi, dokunun saçılma ve soğurma özelliklerinde lokal değişiklikleri saptayabilir ve floresan görüntüleme, endojen florofor seviyelerini açığa çıkararak dokunun biyokimyasal kompozisyonunda değişikliklere neden olabilir (Roblyer ve ark., 2008).

3.3. Temel Bileşen Analizi (TBA)

Kullanılan verinin büyüklüğü yalnızca bilgisayar donanımı açısından değil görüntü işleme ve yapay zekâ algoritmalarının performansı açısından da sorun teşkil eder. Burada verinin büyüklüğü ile ifade edilen durum aynı anlama gelen birçok özelliğin bir arada kullanılmasıdır. Bu durum yerine bir veriyi temsil eden farklı özelliklerin bulunması ve hem görüntü işleme hem de yapay zekâ algoritmalarında kullanılması gerekmektedir. Temel Bileşen Analizi (TBA), büyük bir veri kümesini, büyük kümedeki bilgilerin çoğunu içeren küçük bir kümeye indirmek için kullanılabilen bir boyut azaltma yöntemidir. TBA'nın en büyük avantajı, fazla bilgi kaybı olmadan, boyut düşürülerek verinin sıkıştırılabilmesidir. Bu sayede TBA, görüntü işlemede kullanılmaktadır (Smith, 2002). Bir veriye temel bileşenler analizinin uygulanması dört aşamadan oluşmaktadır.

Verinin Merkezlenmesi: İlk aşama olarak verilerin merkezlenmesi gerekmektedir. Bunun için verinin ortalama değeri (Eşitlik 3.1) hesaplanarak bu değer tüm piksellerden çıkartılır (Eşitlik 3.2).

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (3.1)$$

$$X_j = X_i - \bar{X} \quad (3.2)$$

Burada X_i verinin orijinal değerlerini, \bar{X} verinin ortalama değerini, n toplam eleman sayısını ve X_j merkezlenmiş veriyi ifade etmektedir.

Kovaryans matrisinin oluşturulması: İki değişkenin birbirleri arasındaki ilişkiyi belirlemek için kovaryans matrisi (Eşitlik 3.3) oluşturulur.


$$kov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n - 1)} \quad (3.3)$$

Kovaryans matrisinin öz değer ve öz vektörlerinin hesaplanması: Bir vektör ile bir matris çarpıldığında sonuç, vektörün bir katsayı ile çarpılmış haline eşit ise o vektör matrisin özvektörüdür (yön aynı). Katsayı ise özdeğer olarak adlandırılır. Bunun yapılmasındaki amaç büyük boyutlu matrisler ile işlem yapmak yerine aynı özellikleri taşıyan daha küçük boyutlu vektörler ile işlem yapılmasının daha etkili olmasıdır.

Temel bileşenlerin seçilmesi: Elde edilen öz vektörler, öz değeri en büyük olandan en küçük olana doğru sıralanır. Bu işlem veriyi içeren özelliklerin önem sırasına göre sıralanması anlamına gelmektedir. Bu özelliklerden istenilen sayıda seçilerek yapay zekâ ve görüntü işleme algoritmalarında kullanımı gerçekleştirilir.

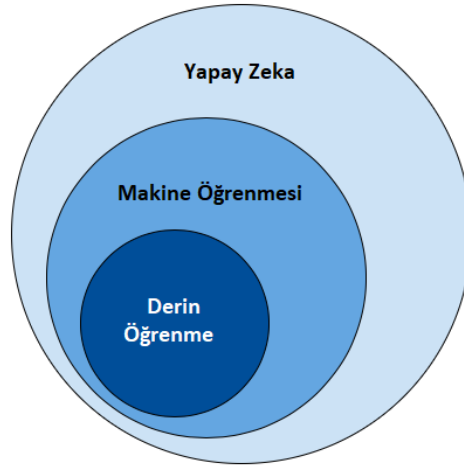
3.4. Derin Öğrenme

Derin öğrenme, birbirini takip eden katmanlarda veriler işlenirken giderek artan şekilde daha kullanışlı gösterimler elde edebilen makine öğrenmesinin bir alt koludur. “Derin” kavramı birbirini takip eden gösterim katmanlarını ifade etmektedir. Modeldeki katman sayısı modelin derinliğini oluşturmaktadır. Buna hiyerarşik gösterim öğrenme de denilebilir. Modern derin öğrenme modelleri, onlarca hatta yüzlerce birbirini takip eden katman içermektedir (Şekil 3.6). Oysa diğer makine öğrenme algoritmaları, genelde bir veya iki katmandan oluşur ki buda sığ öğrenme olarak adlandırılır. Ayrıca, Şekil 3.7’de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki gösterilmiştir.



Şekil 3.6 Birçok katmandan oluşan derin öğrenme ağı


Birçok derin öğrenme modeli bulunmaktadır. Bunlar; çok katmanlı algılayıcılar, evrişimli sinir ağları, çekişmeli üretici ağlar ve otomatik kodlayıcılar vb. gibi. Bu yöntemler görüntü sınıflandırma, nesne algılama, konuşma tanıma, görsel veri tanıma, ilaç keşfi ve genomik gibi birçok alanda kullanılmaktadır (LeCun ve ark., 2015).



Şekil 3.7. Yapay zekâ, makine öğrenmesi ve derin öğrenme kümesi

3.4.1. Çok katmanlı algılayıcılar (ÇKA)

Çok katmanlı algılayıcılar giriş, gizli katmanlar ve çıkış olmak üzere 3 temel yapıdan meydana gelirler. Şekil 3.8’de çok katmanlı algılayıcı modeli gösterilmiştir. Giriş katmanı verilerin direkt olarak kendisini veya verilerden çıkarılmış özellikleri barındırırken çıkış katmanı verilerin hangi sınıfa ait olduğunu gösterir. Gizli katman ise aktivasyon fonksiyonları ile beraber doğrusal yöntemlerle çözülemeyen problemlerin doğrusal olmayan yöntemlerle çözülmesini sağlar. Çok katmanlı algılayıcıların en iyi şekilde sonuç üretmesi için, kullanılan gizli düğüm sayılarına ve aktivasyon fonksiyonlarına dikkat edilmesi gerekmektedir.




Şekil 3.8 Çok katmanlı algılayıcı modeli

3.4.2. Evrişimli sinir ağları (ESA)

Evrişimli Sinir Ağları (ESA) sinir ağlarının bir alt koludur ve çok katmanlı algılayıcıların düzenli versiyonlarıdır. Günümüzde genellikle görüntü sınıflandırma, tıbbi görüntü analizi, görüntüleri benzerliğe göre kümeleme ve nesne tanıma gibi uygulamalar

için kullanılmaktadır (Sun ve ark., 2019; Zhang ve ark., 2019). Bir ESA temel olarak konvolüsyon katmanı, aktivasyon fonksiyonu, havuzlama katmanı ve tam bağlı katman dan oluşmaktadır. Şekil 3.9’da örnek bir ESA yapısı verilmiştir.



Şekil 3.9. ESA yapısı


Görüntü sınıflandırmalarında en sık kullanılan evrişimli sinir ağı 2B-ESA’dır. 2B-ESA’nın haricinde 1B-ESA ve 3B-ESA olmak üzere iki tip ESA daha mevcuttur. Uygulamalarda kullanılan konvolüsyon katmanının boyutu aynı zamanda ESA boyutunu da vermektedir.

3.4.2.1. Konvolüsyon katmanı

Konvolüsyon katmanı, bir giriş görüntüsündeki özellik haritalarını çıkarmak için kullanılan ilk ESA katmanıdır. Giriş görüntüsündeki küçük kareleri kullanarak görüntü özelliklerini öğrenip pikseller arasındaki ilişkiyi korur. Görüntü matrisi ve filtre olmak üzere iki girdisi olan bir matematiksel işlemdir. Boyutuna göre 3 çeşit konvolüsyon vardır.

3.4.2.1.1. Bir boyutlu konvolüsyon

Bir boyutlu ESA’da filtre 1 boyut boyunca kayar. 1B-ESA uygulanırken önemli nokta konvolüsyonun hangi veriler üzerinde 1 boyutta kayacağıdır. Bu sorunun cevabı zaman serisi verileridir. Bu verilere örnek olarak Elektrokardiyografi sinyalleri (EKG), Elektroensefalografi sinyalleri (EEG) verilebilir. Şekil 3.10’da örnek olarak verilmiş bazı bir boyutlu filtreler mevcuttur.



Şekil 3.10. Farklı boyutlarda bir boyutlu filtreler (a) 5x1 (b) 1x3 (c) 3x1

1 boyutlu konvolüsyon işleminin matematiksel karşılığı aşağıdaki gibidir:

$$v_{ij}^z = f(r_{ij} + \sum_{m=0}^{M_i-1} \sum_{b=0}^{B_i-1} k_{ijm}^b v_{(i-1)m}^{(z+b)}) \quad (3.4)$$


Burada v , özellik haritasındaki çıktı değişkenini ifade eder. B , verinin boyut boyunca filtrenin boyutunu temsil eder. b filtre endeksidir ve z özellik haritasının dizinidir. k filtre parametreleri anlamına 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.

Eşitlik 3.4'ün verilere uygulanması ise verinin ilk değerine bir filtre yerleştirilerek başlar ve filtrenin eleman değerleri ile veri üzerine denk gelen eleman değerleri çarpılarak sonuçlar toplanır. Bu şekilde elde edilen değer, özellik haritasının ilk elemanı olarak yerine yazılır. Şekil 3.11'de 3x1'lik bir filtre için bu durum gösterilmiştir. İkinci aşamada Şekil 3.12'de gösterildiği gibi filtre bir alt satıra kaydırılır ve üst üste gelen elemanlar çarpılarak toplama işlemi yeniden gerçekleştirilir. Bu işlem, tüm veri taranıcaya kadar devam eder. Tüm veriye filtrenin uygulanması ile elde edilen sonuç Şekil 3.13'de gösterilmiştir. Burada en son elde edilen sonuç matrisi özellik haritası olarak adlandırılır.


1B-ESA sonucunda elde edilen özellik haritasının boyutu Eşitlik 3.5'deki gibi hesaplanır:

$$(W \times H) * (K \times L) = (W - K + 1) * (H - L + 1) \quad (3.5)$$


Burada $W \times H$ giriş verisinin boyutunu, $K \times L$ filtrenin boyutunu ifade etmektedir. Şekil 3.11’de verilen örnek için $W = 10, H = 1, K = 3$ ve $L = 1$ ’dir. Buna göre özellik haritasının boyutu 8×1 olarak bulunur.



Şekil 3.11 Bir boyutlu konvolüsyon işleminde birinci elemanın bulunması



Şekil 3.12 Bir boyutlu konvolüsyon işleminde ikinci elemanın bulunması




Şekil 3.13. Bir boyutlu konvolüsyon işlemi sonucunda bulunan özellik haritası


3.4.2.1.1 Bir boyutlu ESA için kaydırma ve sıfır ekleme

Kaydırma, filtrenin giriş verisi üzerinde nasıl kaydırılacağını kontrol eder. Şekil 3.11’de verilen örnekte, filtre bir kerede bir birim hareket ettirilecek şekilde giriş verisi üzerinde kaydırılmıştır. Filtrenin kaydığı miktar *stride* olarak isimlendirilir. Stride, çıkış boyutunun kesirli değil tamsayı olacak şekilde ayarlanır. Şekil 3.14’de stride 1 ve 2 olacak şekilde elde edilen özellik haritaları verilmiştir.

Şekil 3.13’de görüldüğü gibi konvolüsyon işleminin sonucunda elde edilen özellik haritasının boyutu orijinal görüntünün boyutundan daha küçük olmaktadır. Boyut azalmasının istenmediği durumlarda orijinal görüntünün etrafına Şekil 3.15’te görüldüğü gibi *sıfır ekleme* işlemi gerçekleştirilmektedir.




Şekil 3.14. Stride 1 ve 2 iken elde edilen özellik haritaları (a) stride 1 iken elde edilen ilk eleman (b) stride 1 iken elde edilen ikinci eleman (c) stride 1 iken elde edilen üçüncü eleman (d) stride 2 iken elde edilen ilk eleman (e) stride 2 iken elde edilen ikinci eleman (f) stride 2 iken elde edilen üçüncü eleman.



Şekil 3.15. Sıfır ekleme (a) orijinal veri (b) sıfır ekleme işlemi (c) filtre çıkışı

3.4.2.1.1.2 Bir boyutlu ESA için havuzlama katmanı


Havuzlama katmanı, bir girdi verisine konvolüsyon uygulandıktan sonra elde edilen özellik haritalarının boyutunun azaltılmasını sağlayan ESA katmanıdır. Çeşitli boyutlarda (2x1, 3x1 gibi) bir filtre özellik haritaları üzerinde hareket ettirilerek, her seferinde filtre ile denk gelen elemanların maksimum veya ortalama değeri alınmaktadır. Havuzlama boyutunun büyümesi verinin boyutunu çok aşırı bir şekilde küçültebilir. Bu yüzden havuzlama boyutu uygun seçilmesi gerekmektedir. Şekil 3.16’da 2x1 maksimum ve 2x1 ortalama havuzlama gösterilmiştir.



Şekil 3.16. Maksimum ve ortalama havuzlama (a) orijinal veri (b) 2x1 maksimum havuzlama (c) 2x1 ortalama havuzlama

3.4.2.1.2. İki boyutlu konvolüsyon

2B-ESA ilk olarak Lenet-5 (LeCun ve ark., 1998) mimarisinde tanıtılmıştır ve genellikle görüntü verileri üzerinde kullanılmaktadır. 2B-ESA olarak adlandırılmasının sebebi, filtrenin görüntü üzerinde 2 boyut boyunca kaymasından dolayıdır. Filtreler görüntü üzerinde yatay ve dikey olarak kayarak özellik haritalarını çıkarırlar. Genellikle bu filtreler 1x1, 3x3, 5x5 ve 7x7 boyutunda olmaktadır. Şekil 3.17’de farklı boyutlardaki 2B filtreler verilmiştir.



Şekil 3.17. Farklı boyutlarda 2B filtreler (a) 1x1 (b) 3x3 (c) 5x5 (d) 7x7

2 boyutlu konvolüsyon işleminin matematiksel karşılığı aşağıdaki gibidir:

$$v_{ij}^{xy} = f(r_{ij} + \sum_{m=0}^{M_i-1} \sum_{h=0}^{H_i-1} \sum_{w=0}^{W_i-1} k_{ijm}^{hw} v_{(i-1)m}^{(x+h)(y+w)}) \quad (3.6)$$

Burada v , özellik haritasındaki çıktı değişkenini ifade eder. H, W verinin boyut boyunca filtrenin boyutunu temsil eder. h, w filtre endeksidir ve x, y özellik haritasının dizinidir. k filtre parametreleri anlamına 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.

Eşitlik 3.6’daki matematiksel ifadenin görüntülere uygulanması ise görüntünün sol üst köşesine bir filtre yerleştirilerek başlar ve filtrenin eleman değerleri ile görüntü üzerine denk gelen eleman değerleri çarpılarak sonuçlar toplanır. Bu şekilde elde edilen değer, özellik haritasının ilk elemanı olarak yerine yazılır. Şekil 3.18’de 5x5’lik bir filtre için bu durum gösterilmiştir. İkinci aşamada Şekil 3.19’da gösterildiği gibi filtre bir alt satıra kaydırılır ve üst üste gelen elemanlar çarpılarak toplama işlemi yeniden gerçekleştirilir. Bu işlem, tüm görüntü taranıncaya kadar devam eder. Görüntü matrisinin tamamına filtrenin uygulanması ile elde edilen sonuç şekil 3.20’de gösterilmiştir. Bulunan sonuç matrisi özellik haritasını oluşturmaktadır.

95 ¹	125 ¹	66 ¹	98 ¹	105 ¹	210	200			
80 ¹	124 ⁻¹	36 ⁻¹	200 ⁻¹	115 ¹	85	90			
65 ¹	15 ⁻¹	152 ⁻⁴	85 ⁻¹	96 ¹	120	150	495		
92 ¹	78 ⁻¹	25 ⁻¹	56 ⁻¹	120 ¹	200	85			
200 ¹	80 ¹	145 ¹	140 ¹	100 ¹	125	10			
201	150	123	125	90	110	89			
255	200	190	255	101	150	68			

Şekil 3.18. İki boyutlu konvolüsyon işleminin uygulanması sonucunda elde edilen birinci eleman

95	125 ¹	66 ¹	98 ¹	105 ¹	210 ¹	200			
80	124 ¹	36 ⁻¹	200 ⁻¹	115 ⁻¹	85 ¹	90			
65	15 ¹	152 ⁻¹	85 ⁻⁴	96 ⁻¹	120 ¹	150	495	676	
92	78 ¹	25 ⁻¹	56 ⁻¹	120 ⁻¹	200 ¹	85			
200	80 ¹	145 ¹	140 ¹	100 ¹	125 ¹	10			
201	150	123	125	90	110	89			
255	200	190	255	101	150	68			

Şekil 3.19. İki boyutlu konvolüsyon işleminin uygulanması sonucunda elde edilen ikinci eleman


95	125	66	98	105	210	200			
80	124	36	200	115	85	90			
65	15	152 ¹	85 ¹	96 ¹	120 ¹	150 ¹	495	676	372
92	78	25 ¹	56 ⁻¹	120 ⁻¹	200 ⁻¹	85 ¹	1066	689	228
200	80	145 ¹	140 ⁻¹	100 ⁻⁴	125 ⁻¹	10 ¹	860	763	478
201	150	123 ¹	125 ⁻¹	90 ⁻¹	110 ⁻¹	89 ¹			
255	200	190 ¹	255 ¹	101 ¹	150 ¹	68 ¹			

Şekil 3.20. İki boyutlu konvolüsyon işlemi sonucunda elde edilen özellik haritası

2B-ESA sonucunda elde edilen özellik haritasının boyutu 1B-ESA'da olduğu gibi eşitlik 3.5'e göre hesaplanır. Bu eşitlikte $W \times H$ giriş görüntüsünün boyutunu, $K \times L$ filtrenin boyutunu ifade etmektedir. Şekil 3.18'deki verilen örnekte $W = 7, H = 7, K = 5$ ve $L = 5$ 'dir. Buna göre elde edilen özellik haritasının boyutu 3×3 'tür.


3.4.2.1.2.1. İki boyutlu ESA için kaydırma ve sıfır ekleme

Kaydırma işlemi 1B-ESA'dan farklı olarak iki boyutta gerçekleştirilir. Şekil 3.18'de verilen örnekte, filtre bir kerede bir birim hareket ettirilecek şekilde giriş verisi üzerinde kaydırılmıştır. Filtrenin kaydığı miktar, 1B-ESA'da olduğu gibi *stride* olarak isimlendirilir. Şekil 3.21'de stride 1 ve 2 olacak şekilde oluşan özellik haritaları verilmiştir.



Şekil 3.21. Stride 1 ve 2 iken oluşan özellik haritaları (a) stride 1 iken elde edilen ilk eleman
 (b) stride 1 iken elde edilen ikinci eleman (c) stride 2 iken elde edilen ilk eleman
 (d) stride 2 iken elde edilen ikinci eleman


Şekil 3.20'de görüldüğü gibi konvolüsyon işleminin sonucunda elde edilen özellik haritasının boyutu orijinal görüntünün boyutundan daha küçük olmaktadır. Boyut azalmasının istenmediği durumlarda orijinal görüntünün etrafına Şekil 3.22'de görüldüğü gibi sıfır ekleme işlemi gerçekleştirilmektedir.



Şekil 3.22. Sıfır ekleme uygulandıktan sonra elde edilen özellik haritası

3.4.2.1.2.2 İki boyutlu ESA için havuzlama katmanı


2B-ESA için çeşitli boyutlarda (2x2, 3x3 vb. gibi) bir filtre özellik haritaları üzerinde hareket ettirilerek, her seferinde filtre ile denk gelen elemanların maksimum veya ortalama değeri alınmaktadır. 1B-ESA’da olduğu gibi, havuzlama boyutunun büyümesi verinin boyutunu çok aşırı bir şekilde küçültebilir (Scherer ve ark., 2010). Bu yüzden havuzlama boyutu uygun seçilmelidir. Şekil 3.23’te 3x3 maksimum ve 3x3 ortalama havuzlama işlemi gösterilmiştir.



Şekil 3.23. Maksimum ve ortalama havuzlama (a) orijinal görüntü (b) 3x3 maksimum havuzlama (c) 3x3 ortalama havuzlama

3.4.2.1.3. Üç boyutlu konvolüsyon

Üç boyutlu ESA'da filtre 3 boyutlu olarak kaymaktadır ve 3 boyutlu hacimsel veriler için kullanılmaktadır. Örneğin HS veriler, Manyetik Rezonans Görüntüleme (MRG) verileri, Bilgisayarlı Tomografi (BT) taramaları ve vücudun farklı açılarından alınan X-ray görüntülerinin birleşmesiyle oluşan veriler 3B verilere örnek olabilir. Sonuç olarak 3B-ESA hacimsel verileri sınıflandırmak veya onlardan özellik çıkarmak için kullanılmaktadır. Şekil 3.24'de farklı boyutlardaki 3B filtreler gösterilmiştir.



Şekil 3.24. Farklı boyutlarda 3B filtreler (a) 1x1x5 (b) 3x3x3 (c) 5x5x3


3 boyutlu konvolüsyon işleminin matematiksel karşılığı aşağıdaki gibidir:

$$v_{ij}^{xyz} = f(r_{ij} + \sum_{m=0}^{M_i-1} \sum_{b=0}^{B_i-1} \sum_{h=0}^{H_i-1} \sum_{w=0}^{W_i-1} k_{ijm}^{hwb} v_{(i-1)m}^{(x+h)(y+w)(z+b)}) \quad (3.7)$$

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 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.

3B konvolüsyonun verilere uygulanması 2B konvolüsyona çok benzemektedir. Örnek olarak Şekil 3.25 (a)'da gösterilen 4x4x4 boyutundaki veriye, Şekil 3.25 (b)'deki 3x3x3 boyutunda bir filtre uygulanmıştır. Burada veriler parçalanmış bir şekilde ifade edilmiştir. Parçalanmış verilere filtreler sırasıyla uygulanarak matrisler bulunur. Bu işlem

sonucunda bulunan 3 farklı matris skaler olarak toplanarak özellik haritasının birinci katmanı elde edilir. Daha sonra filtreler bir basamak aşağıya kaydırılıp aynı işlem uygulanır, Şekil 3.26'nın sonucunda özellik haritasının ikinci katmanı bulunur. Sonuç olarak Şekil 3.27'de tüm veriye filtrenin uygulanmasıyla elde edilen 2x2x2 boyutunda özellik haritası gösterilmiştir.




Şekil 3.25. Üç boyutlu konvolüsyon işleminde birinci özellik haritasının bulunması (a) 4x4x4 boyutundaki hacimsel veri (b) 3x3x3 boyutunda filtre (c) filtrelerin verilere tek tek uygulanması sonucu oluşan matrisler (d) elde edilen matrislerin toplanması sonucu bulunan özellik haritasının birinci katmanı


3B-ESA sonucunda elde edilen özellik haritasının boyutu Eşitlik 3.8'deki gibi hesaplanır:

$$(W \times H \times D) * (K \times L \times P) = (W - K + 1) * (H - L + 1) * (D - P + 1) \quad (3.8)$$

Burada $W \times H \times D$ giriş verisinin boyutunu, $K \times L \times P$ filtrenin boyutunu ifade etmektedir. Şekil 3.25'te verilen örnek için $W = 4, H = 4, D = 4, K = 3, L = 3$ ve $P = 3$ 'tür. Buna göre elde edilen özellik haritasının boyutu 2x2x2'dir.



Şekil 3.26. Üç boyutlu konvolüsyon işleminde ikinci özellik haritasının bulunması (a) 4x4x4 boyutundaki hacimsel veri (b) 3x3x3 boyutunda filtre (c) filtrelerin verilere tek tek uygulanması sonucu oluşan matrisler (d) elde edilen matrislerin toplanması sonucu bulunan özellik haritasının ikinci katmanı



Şekil 3.27. Üç boyutlu konvolüsyon işlemi sonucunda elde edilen 2x2x2 boyutundaki özellik haritası

3.4.2.1.3.1. Üç boyutlu ESA için kaydırma ve sıfır ekleme

Kaydırma işlemi 2B-ESA'dan farklı olarak üç boyutta gerçekleştirilir. Şekil 3.25'te verilen örnekte, filtre hem uzamsal hem de derinlik olarak bir birim hareket ettirilerek veri üzerinde kaydırılır. Stride işlemi 2B-ESA'ya çok benzemekte olup tek fark değerinin 2 boyutlu olarak ifade edilmesidir. Örneğin; stride (a_k, b_k) olarak alınırsa burada a_k uzamsal kaymayı b_k ise derinlemesine kaymayı ifade etmektedir.


2B-ESA'da olduğu gibi Şekil 3.27'de konvolüsyon işleminin sonucunda elde edilen özellik haritasının boyutu orijinal görüntünün boyutundan daha küçük olmaktadır. Boyut azalmasının istenmediği durumlarda orijinal görüntünün etrafına 2B-ESA'daki gibi sıfır ekleme işlemi yapılabilir.

3.4.2.1.3.2. Üç boyutlu ESA için havuzlama katmanı

3B havuzlama işlemi 2B havuzlama işlemine çok benzemektedir. Çeşitli boyutlarda (2x2x2, 3x3x3 gibi) bir filtre özellik haritaları üzerinde hareket ettirilerek, her seferinde filtre ile denk gelen elemanların maksimum veya ortalama değeri alınmaktadır. Bir boyutlu ESA ve iki boyutlu ESA'da olduğu gibi, havuzlama boyutunun büyümesi verinin boyutunu çok aşırı bir şekilde küçültebilir. Bu yüzden havuzlama boyutu uygun seçilmelidir. Şekil 3.28'de 2x2x2'lik maksimum ve ortalama havuzlama işlemi gösterilmiştir.

3.4.2.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları derin öğrenmenin önemli bileşenleri arasındadır. Bu fonksiyonlar, bir derin öğrenme modelinin çıktısını, doğruluğunu ve ayrıca bir modelin eğitiminin hesaplama verimliliğini belirler. Aktivasyon fonksiyonlarının ayrıca sinir ağının yakınsama yeteneği ve yakınsama hızı üzerinde önemli bir etkisi vardır. Bazı durumlarda aktivasyon fonksiyonları sinir ağlarının ilk etapta yakınsamasını engelleyebilir. Aktivasyon fonksiyonlarına örnek olarak ReLU (Eşitlik 3.9), sigmoid (Eşitlik 3.10), tanh (Eşitlik 3.11), Leaky ReLU (Eşitlik 3.12), ELU (Eşitlik 3.13) ve SELU (Eşitlik 3.14) aktivasyon fonksiyonları verilebilir. Şekil 3.29'da aktivasyon fonksiyonlarının çıkış eğrileri gösterilmiştir.



Şekil 3.28. Maksimum ve ortalama havuzlama (a) orijinal veri (b) 2x2x2 maksimum havuzlama (c) 2x2x2 ortalama havuzlama

$$Relu(x) = \max(0, x) \quad (3.9)$$

$$sig(x) = \frac{1}{1 + e^{-x}} \quad (3.10)$$

$$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3.11)$$

$$L_Relu(x) = \begin{cases} x & x > 0 \\ 0.01x & \text{diğer} \end{cases} \quad (3.12)$$

$$Elu(x) = \begin{cases} x & x > 0 \\ a(e^x - 1) & \text{diğer} \end{cases} \quad (3.13)$$

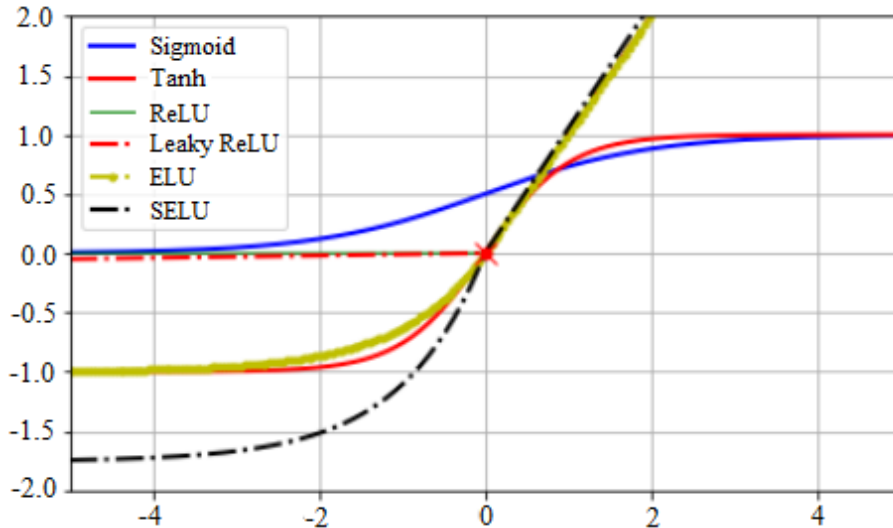
$$Selu(x) = \lambda \begin{cases} x & x > 0 \\ \alpha e^x - \alpha & x \leq 0 \end{cases} \quad (3.14)$$

ReLU evrişimli sinir ağlarında en çok kullanılan aktivasyon fonksiyonlarından biridir. Şekil 3.29'dan anlaşılacağı gibi giriş pozitifse *ReLU*'nun çıkışı doğrusaldır, aksi halde sıfırdır. *ReLU* aralığı $[0, \infty)$ 'dir. *ReLU* fonksiyonu için aktivasyon işlevi süreklidir, ancak $x = 0$ 'da ayırt edilemez. *ReLU*'nun diğer aktivasyon fonksiyonlarına göre çeşitli avantajları vardır. Sadece *max* fonksiyonunu kullandığından, diğer aktivasyon fonksiyonlarına kıyasla hesaplama hızı daha yüksektir.

Sigmoid fonksiyonunun karakteristik bir 'S' şekli eğrisi vardır ve süreklidir. Her yerde sıfırdan farklı bir türe sahiptir. Girdi olarak gerçek değeri alır ve 0 ile 1 arasında çıktı verir. Bununla birlikte, sigmoid fonksiyonu, girdi büyük (negatif veya pozitif) hale geldiğinde, fonksiyonun 0 veya 1'de doygunlaştığını ve türevin sıfıra çok yakın olduğunu gösterir. Ayrıca sigmoid aktivasyon fonksiyonunun hiçbir zaman 0.25'ten fazla eğimi yoktur (Wanto ve ark., 2017).

Tanh aktivasyon fonksiyonu da sigmoid gibi S şeklinde olup, süreklidir. Sigmoid fonksiyonundan farklı olarak çıktı değeri -1 ile +1 arasında değişir, bu da her bir katman çıktısını 0 civarında daha fazla veya daha az merkezleme eğiliminde olduğunu gösterir.


Leaky ReLU ayrıca $\max(\alpha x, x)$ olarak da tanımlanabilir. Hiper parametre alfa (α), işlevin ne kadar sızdığını tanımlar. Alfa, $x < 0$ için fonksiyonun eğimidir ve tipik olarak 0.01'e ayarlanır.



Şekil 3.29. Aktivasyon fonksiyonlarının çıkış eğrileri

3.4.2.3. Düzleştirme katmanı

Düzleştirme işlemi, evrişimli sinir ağları içinde yaygın bir işlemdir. Bu işlemin yapılmasının nedeni, konvolüsyon ve havuzlama işleminden sonra elde edilen iki boyutlu özellik haritalarının, tam bağlı katmana girdi olarak verilmeden önce düzleştirilmesi gerektiğidir. Tam bağlı katmanlar girdi olarak iki boyutlu tensörleri kabul etmezler. Bir tensörü düzleştirmek için en az iki eksene sahip olunması gereklidir. Şekil 3.30’da iki boyutlu bir verinin düzleştirme işlemi verilmiştir.



Şekil 3.30. Düzleştirme işlemi

3.4.2.4. Tam bağlı katman

Bir sinir ağındaki tam bağlı katmanlar, bir katmandaki tüm girdilerin bir sonraki katmanın her aktivasyon birimine bağlandığı katmanlardır. Makine öğrenme modellerinde, son birkaç katman, son çıktıyı oluşturmak için önceki katmanlar tarafından çıkarılan verileri derleyen tam bağlı katmanlardan oluşur. Konvolüsyon katmanından sonra en çok zaman alan ikinci katmandır. Tam bağlı katmanların çalışma yapısı Yapay Sinir Ağları (YSA) ile aynıdır ve elde edilen özellik haritalarının sınıflandırılmasını gerçekleştiren katmandır.

3.4.2.4.1. Geri yayılım algoritması


Geri yayılım algoritması, sinir ağlarının eğitimi için çok önemlidir. Bir sinirsel ağdaki ağırlık değerlerinin, önceki elde edilen hata oranına dayanarak tekrar güncellenmesi işlemidir. Geri yayılım, ağırlıkları uygun şekilde ayarlayarak daha düşük hata oranlarının elde edilmesini sağlar ve modeli, genellemesini artırarak güvenilir kılar. Bu işlem, dört aşamadan meydana gelmektedir. Bunlar *ileri gidiş*, *hata hesaplama*, *geri gidiş* ve *ağırlık güncelleme* işlemleridir.

Bir yapay sinir ağında, girdi katmanından çıktı katmanına kadar gerçekleştirilen bütün ileri yönlü hesaplama akışına *ileri gidiş* adı verilmektedir. İleri gidiş işleminden sonra elde edilen sonuç değeri ile hedeflenen sonuç değeri arasındaki hata oranı hesaplanır. Doğru tahminler için hesaplanan hatayı en aza indirmek gerekmektedir. Hata değerini hesaplayan fonksiyonlara *hata fonksiyonu* denir. En sık kullanılan hata fonksiyonları ortalama mutlak hata fonksiyonu (OMH) (Eşitlik 3.15) ve ortalama karesel hata fonksiyonudur (OKH) (Eşitlik 3.16).

$$OMH = \frac{\sum_{a=1}^n |y_a - y_a^p|}{n} \quad (3.15)$$

$$OKH = \frac{\sum_{a=1}^n (y_a - y_a^p)^2}{n} \quad (3.16)$$

Eşitlik 3.15 ve 3.16'da OMH ve OKH hata değerlerini, n eleman sayısını, y_a gerçek değeri ve y_a^p ise tahmin edilen değeri ifade etmektedir. Hata değeri hesaplandıktan sonra hataya neden olan ağırlık değerlerinin güncellenmesi gerekmektedir. Şekil 3.31'de OMH ve OKH için grafikler verilmiştir.



Şekil 3.31. Kayıp fonksiyonu grafikleri (a) OHM için (b) OKH için


Şekil 3.31’de her iki kayıp fonksiyonu grafiğinde görüldüğü gibi hata değeri yüksek bir noktadan sıfır noktasına doğru azaltılmaya çalışılmaktadır. Bu işlemin yapılabilmesi için hatanın ağırlığa göre türevinin alınması gerekmektedir. Geri gidiş boyunca hataya sebep olan ağırlıklar ile hata değeri arasında türev hesabı yapılarak *ağırlık güncelleme* (Eşitlik 3.17) işlemi gerçekleştirilmektedir.

$$W^{(k+1)} = W^{(k)} - \eta \frac{dH_a}{dW} \quad (3.17)$$

Burada η ağırlık öğrenme oranı, H_a hata, $W^{(k)}$ eski ağırlık değeri ve $W^{(k+1)}$ yeni ağırlık değerini ifade etmektedir. Öğrenme oranı bir sinir ağı modelinin ne kadar hızlı veya yavaş bir problemi öğrendiğini kontrol eder. Öğrenme oranının uygun seçilmesi gerekmektedir. Aksi takdirde bulunulan noktadan istenilen noktaya giderken ulaşılmama problemi ile karşılaşılabilir.

3.4.2.5. Unutturma katmanı

Sinir ağındaki ağırlıkların her biri güncellenerek eğitildiğinde, kullanılan veri kümesine çok bağımlı hale gelebilir. Bu nedenle, model bir tahmin veya sınıflandırma yapmak zorunda kaldığında tatmin edici sonuçlar vermez. Buna *aşırı öğrenme* denir. Unutturma katmanı, bir modelin aşırı öğrenmesini önlemek için kullanılan bir tekniktir (Mei ve ark., 2016; Yu ve ark., 2017; Zhong ve ark., 2018). Unutturma, eğitim aşamasının her güncellemesinde belirli bir katmandaki nöronların bazılarının rastgele olarak devre dışı yapılması işlemidir. Bu işlem Şekil 3.32’de gösterilmiştir.



Şekil 3.32. Unutturma işlemi (a) standart bir sinir ağı (b) unutturma işlemi uygulanmış sinir ağı

Şekil 3.32 (a)'da standart bir sinir ağında tüm nöronlar birbirine bağlanmıştır. Şekil 3.32 (b)'de unutturma işlemi uygulanmış ve bazı nöronlara ağırlık girişi ve ağırlık çıkışı yapılmamıştır.

3.5. Sınıflandırma Sonuçlarının Değerlendirilmesinde Kullanılan Performans Kriterleri

Tez kapsamında yapılan çalışmalardan elde edilen sonuçların değerlendirilmesi için karmaşıklık matrisi, genel doğruluk, Cohen'in kappa katsayısı (κ), hassasiyet ve özgülük değerleri hesaplanmıştır. Karmaşıklık matrisi, elde edilen tahmin ile gerçek değerlerin karşılaştırıldığı bir performans değerlendirme yöntemidir ve medikal verilerin sınıflandırma performansını değerlendirirken sıklıkla kullanılır. Karmaşıklık matrisi, doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN) sayısını bildiren iki sıralı ve iki sütunlu bir tabloyu temsil eder (Şekil 3.33).

- DP: Hasta sınıfına ait verilerin sistem tarafından hasta olarak sınıflandırılması.
- DN: Sağlıklı sınıfına ait verilerin sistem tarafından sağlıklı olarak sınıflandırılması.
- YP: Sağlıklı sınıfına ait verilerin sistem tarafından hasta olarak sınıflandırılması.
- YN: Sağlıksız sınıfına ait verilerin sistem tarafından sağlıklı olarak sınıflandırılması.

		Tahmin edilen sınıf	
		P	N
Gerçek sınıf	P	DP	YN
	N	YP	DN

Şekil 3.33 Karmaşıklık matrisi gösterimi

Karmaşıklık matrisi elde edildikten sonra sınıflandırma performansı değerlendirilebilir. DP ve DN doğru olarak sınıflandırılan verileri gösterirken, YP ve YN ise yanlış olarak sınıflandırılan verileri gösterir. Elde edilen bu değerler kullanılarak genel doğruluk, özgülük ve hassasiyet değerleri hesaplanabilir.

Doğru olarak sınıflandırılan verilerin tüm verilere oranı genel doğruluk (Eşitlik 3.18) değerini ifade eder:

$$GD = \frac{DP + DN}{TD + DP + YN + YP} \quad (3.18)$$

Hasta olarak etiketlenmiş verilerin kaç tanesinin hasta olarak sınıflandırıldığı bulmak için, hasta olarak sınıflandırılan verilerin tüm hasta verilere oranı bulunur. Bulunan bu oran *hassasiyet* ifadesine karşılık gelir (Eşitlik 3.19).

$$Hassasiyet = \frac{DP}{DP + YN} \quad (3.19)$$

Sağlıklı olarak etiketlenmiş verilerin kaç tanesinin sağlıklı olarak sınıflandırıldığı bulmak için, sağlıklı olarak sınıflandırılan verilerin tüm sağlıklı verilere oranı bulunur. Bulunan bu oran *özgüllük* ifadesine karşılık gelir (Eşitlik 3.20).

$$Özgüllük = \frac{DN}{DN + YP} \quad (3.20)$$

Cohen'in kappa katsayısı, iki farklı tanı arasındaki tutarlılığı değerlendirmek için medikal uygulamalarda sıklıkla kullanılan diğer bir tekniktir (Kraemer, 1980). Kappa katsayısı hesaplanırken iki farklı olasılık hesaplanır. Bunlar $Pr(a)$ ve $Pr(e)$ 'dir. $Pr(a)$, iki farklı sınıf için elde edilen sonuçların genel doğruluğu iken, $Pr(e)$ bu sonuçların tahmini olarak ortaya çıkma olasılığıdır. Bu iki olasılık üzerinden "Cohen'in kappa katsayısı" için kullanılacak matematiksel ifade aşağıda Eşitlik 3.21'de gösterilmiştir:

$$\kappa = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (3.21)$$

Kappa değeri -1 ve +1 aralığında bir değer alabilir ve bu değer şu şekilde yorumlanır:

- $\kappa = +1$ ise, iki sınıf için elde edilen sonuçlar tamamen birbiri ile uyumludur.
- $\kappa = 0$ ise, iki sınıf arasındaki uyum sadece tahmine bağlıdır.
- $\kappa = -1$ ise, iki sınıf için elde edilen sonuçlar tamamen birbirinden bağımsızdır.

3.6. K-Katlamalı Çapraz Doğrulama

Çapraz doğrulama, sınırlı bir veri örneğinde makine öğrenme modellerini değerlendirmek için kullanılan *yeniden örnekleme* yöntemidir. Bu yöntem, belirli bir veri örneğinin bölüneceği grup sayısını ifade eden k adlı tek bir parametreye sahiptir. Bu nedenle, genellikle k -katlamalı çapraz doğrulama denir. K için belirli bir değer seçildiğinde, modele referans olarak k değeri kullanılabilir. Örneğin; $K = 10$ için 10-katlamalı çapraz doğrulama gibi. K değerini 10 olarak aldığımızda veri 10 parçaya bölünür. Model eğitilirken 10 parçanın 9'u eğitim 1'i test için kullanılır. Daha sonra bu işlem diğer tüm veriler ayrı ayrı hem eğitim hem de test verisi olacak şekilde 10 kez tekrarlanır. Bu işlem sonucunda her bir test işleminden sonra karmaşıklık matrisi hesaplanır ve en son 10 adet karmaşıklık matrisi toplanarak nihai karmaşıklık matrisi elde edilir. Böylece her bir veri hem eğitim hem de test işleminde kullanılmış olur.


Çapraz doğrulama, esas olarak, bir makine öğrenimi modelinin bilinmeyen veriler üzerindeki becerisini tahmin etmek için makine öğreniminde kullanılır. Yani, modelin eğitimi sırasında kullanılmayan verilerle ilgili tahminlerde bulunmak için kullanıldığında modelin genel olarak nasıl performans göstereceğini tahmin etmek için sınırlı bir sayıda örnek kullanmaktır.

3.7. Komşuluk Çıkarma Yöntemi

Komşuluk çıkarma yöntemi, 3B hiperspektral verilerin sınıflandırıldığı çalışmalarda kullanılmış yeni bir yöntemdir (Roy ve ark., 2019; Ahmad, 2020). Hiperspektral veriler birbirine benzer şekilde spektral boyutta birçok 2B görüntü içermektedir. Komşuluk çıkarma yöntemi için spektral boyutta arka arkaya gelen tüm piksellere tek bir etiket değeri atanır. Daha sonra bu işlem tüm pikseller için gerçekleştirilerek (x, y) boyutunda etiketler oluşturulur. Sonrasında her bir piksel orta noktaya gelecek şekilde $S \times S$ boyutunda mini küpler seçilir. Burada S seçilecek mini küplerin boyutunu ifade etmektedir. Bu işlem x, y boyunca yapılarak toplamda $x \cdot y$ tane mini küp oluşturulmuş olunur. Komşuluk çıkarma yönteminde amaç tüm pikselleri taramak olduğundan mini küpler oluşturulmadan önce veriye sıfır ekleme işlemi yapılır. Bu sayede tüm pikseller orta nokta olacak şekilde mini küpler elde edilir. Oluşturulan bu mini küpler eğitim ve test verisi olarak parçalanıp tasarlanan ESA modelinin eğitilmesinde ve test edilmesinde kullanılır. Bu yöntem *piksel odaklı sınıflandırma* yöntemi demekte uygun olabilir.

Şekil 3.34'te komşuluk çıkarma yöntemi için mini küplerin nasıl oluşturulacağı gösterilmiştir. Toplamda 5 farklı sınıfa ait veri mevcuttur. Farklı renklerdeki küpler farklı etiket değerindeki mini küpleri temsil etmektedir. Tüm piksellerin taranması için veri l boyutunda genişletilerek sıfır ekleme işlemi yapılmıştır. l değeri ise Eşitlik 3.22'deki gibi hesaplanmaktadır.

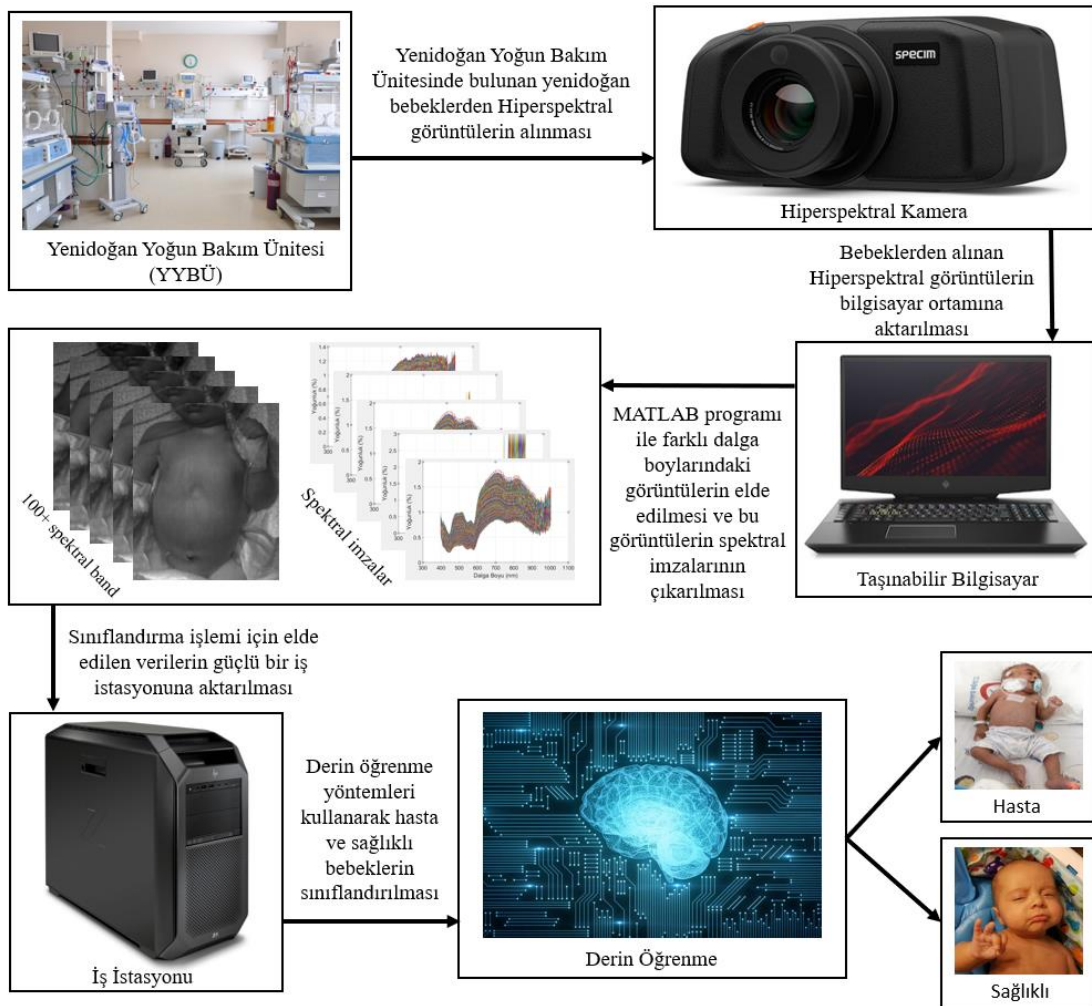
$$l = \frac{(S - 1)}{2} \quad (3.22)$$



Şekil 3.34. Komşuluk çıkarma yöntemi (a) $S \times S$ boyutunda mini küp (b) görüntü üzerinde mini küplerin elde edilip orta noktasındaki etiket değerlerinin atanması

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde ölçüm kurulumu ve hiperspektral verilerin elde edilmesi, hiperspektral verilerden spektral imzaların çıkarılması ve incelenmesi, 2B-ESA, 3B-ESA ve komşuluk çıkarma yöntemi kullanılarak hasta ve sağlıklı yenidoğanlara ait hiperspektral görüntülerin sınıflandırılması uygulamalarının detayları verilmiştir. Bu bölümdeki işlemlerin tümü Python ve MATLAB kullanılarak NVIDIA GeForce GTX 1080 Ti üzerinde, 64 GB RAM'e sahip olan bir iş istasyonunda yürütülmüştür. Tez çalışmasına ait genel blok diyagramı Şekil 4.1'de gösterilmiştir.




Şekil 4.1. Tez çalışmasına ait genel blok diyagramı

4.1. Ölçüm Kurulumu ve Hiperspektral Verilerin Elde Edilmesi


Yenidoğanlara ait hiperspektral görüntüler, Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesindeki hasta ve sağlıklı yenidoğanlardan elde edilmiştir. Tez çalışmasında hiperspektral görüntülerin alınması için 04.09.2019 tarihli, 2019/215 karar sayılı etik kurulu raporu EK-1'de verilmiştir.

Hiperspektral görüntülerin alınabilmesi için gerekli olan ölçüm kurulumu Şekil 4.2’de gösterilmiştir. Bu tez çalışmasında hiperspektral veriler, Specim® şirketi tarafından üretilen Specim IQ hiperspektral kamera kullanılarak elde edilmiştir. Specim IQ kamerası elektromanyetik spektrumda görünür ve yakın kızılötesi bölgesini içine alan; 400 nm ve 1000 nm dalga boyları arasında, 204 farklı spektral bantta ve uzamsal olarak 512 x 512 çözünürlükte görüntüler elde edebilen dokunmatik ekrana sahip taşınabilir bir kameradır (SPECIM, 2020b).



Şekil 4.2. Ölçüm kurulumu (a) hiperspektral kamera (b) ışık kaynağı (c) yenidoğan bebek (d) kuvöz (e) beyaz referans paneli

Hiperspektral veriler alınırken yenidoğan bebeğe herhangi bir zarar vermemek ve onun konforunu bozmamak için her ölçümden önce YYBÜ’de bulunan hemşirelerden yardım alınmıştır. Görüntüler hiperspektral kamera kullanılarak 60-90 sn içerisinde elde edilmiştir. Ayrıca, hiperspektral kamera yüzeyden yansıyan ışığı ölçtüğü için bebeğe zarar vermeyecek şekilde kuvöz üzerinde ve ortamda bulunan ışık kaynakları kullanılarak ışık seviyesi yeterli düzeye getirilmiştir. Bir yenidoğandan elde edilen (a) orijinal görüntü, (b) 510.48 nm, (c) 613.38 nm, (d) 777.64 nm ve (e) 929.68 nm’deki hiperspektral görüntüler Şekil 4.3’te gösterilmiştir.



Şekil 4.3. Hiperspektral Görüntüleme ile elde edilen farklı spektral bantlardaki görüntüler (a) orijinal görüntü, (b) 510.48 nm'de (c) 613.38 nm'de (d) 777.64 nm'de (e) 929.68 nm'de

Tez kapsamında, toplamda 19 farklı yenidoğandan hiperspektral görüntüler alınmıştır. 19 yenidoğanın 3 tanesi sağlıklıken, 16 tanesi ise çeşitli hastalıklara sahiptir. Hasta ve sağlıklı bebeklerin etiketlenmesi, uzman görüşü doğrultusunda tetkiklere uygun olarak yapılmıştır. Tablo 4.1'de sağlıklı yenidoğanların fiziksel özellikleri verilmiştir. Buraya bakıldığı zaman sağlıklı yenidoğanların doğum ağırlıkları 770-1435 gr arasında ve doğum haftaları 25-29 hafta arasındadır.

Tablo 4.1. Sağlıklı yenidoğanların fiziksel özellikleri

Denek	Doğum ağırlığı (gr)	Doğum haftası + günü
Sağlıklı-1	770	25 + 4
Sağlıklı-2	1435	29
Sağlıklı-3	1150	27


Tablo 4.2'de ise hasta yenidoğanların fiziksel özellikleri ve hastalık bilgileri detaylı olarak verilmiştir. Hastalık teşhisi konulmuş 16 yenidoğan bebeğin toplamda 18 farklı hastalığı vardır. Hasta yenidoğanların doğum ağırlıkları 610-4060 gr arasında, doğum haftaları ise 24-40 hafta arasında değişmektedir.

Tablo 4.2. Hasta yenidoğanların fiziksel özellikleri ve hastalık bilgileri

Denek	Hastalık 1	Hastalık 2	Doğum ağırlığı (gr)	Doğum haftası + günü
Hasta-1	Kolay morarma	-	4060	40 + 3
Hasta-2	RDS	Neonatal pneumonia	610	24 + 5
Hasta-3	RDS	NEC	1385	28 + 5
Hasta-4	PAH	Neonatal pneumonia	3940	37
Hasta-5	RDS	PDA	1065	28 + 5
Hasta-6	Menenjit	RDS	955	26 + 5
Hasta-7	DAB	DKD	3725	38 + 3
Hasta-8	DAB	RDS	3900	39 + 6
Hasta-9	PDA	-	810	26
Hasta-10	TOF	Özofagus atrezisi	3200	38 + 6
Hasta-11	Asfeksi	-	2154	37
Hasta-12	PDA	DKD	2715	38
Hasta-13	Asfeksi	İntrakranial kanama	1400	29
Hasta-14	Diyare	Beslenme bozukluğu	1750	33
Hasta-15	PDA	Koanal atrezi	1860	40
Hasta-16	AORT kasılması	-	3900	38 + 6

4.2. Hiperspektral Verilerden Spektral İmzaların Çıkarılması ve İncelenmesi

Hiperspektral kamera kullanılarak yenidoğan bebeklerden 512x512x204 boyutunda hiperküpler elde edilmiştir. Hiperküpler elde edildikten sonra kamerada kayıtlı bulunan tüm veriler SD kart (kablolu ve kablosuz veri aktarımı özelliği de mevcut) aracılığı ile bilgisayar ortamına aktarılmıştır. MATLAB programı kullanılarak, 204 farklı spektrum, görüntülere dönüştürülmüştür. Ayrıca, hiperspektral görüntülerde ilgilenilen kısmın yenidoğanların gövdesi olmasından dolayı (hastalıklar bu bölgede oluşuyor) bütün görüntüler üzerinde çalışmak yerine görüntülerden ilgi alanları seçilmiştir. Bu sayede görüntüler, anlamlı verilere dönüştürülmüştür. Şekil 4.4 (a)'daki bir hiperspektral veri için elde edilmiş ilgi alanı Şekil 4.4 (b)'de gösterilmiştir. Burada gösterilen görüntünün boyutu 150x150'dir. Şekil 4.4 (c)'de ilgi alanlarından tüm pikseller için çıkarılan spektral imzalar gösterilmiştir (Toplamda 22500 piksele ait spektral imza). Ayrıca tüm pikseller için oluşturulan spektral imzaların ortalaması alınarak tek bir imza elde edilmiştir (Şekil 4.4 (d)). Şekil 4.4'teki tüm görüntü ve grafiklerin elde edilmesi için kullanılan MATLAB kodları Şekil 4.5'te verilmiştir.



Şekil 4.4. Bir yenidoğana ait (a) orijinal görüntü (b) ilgi alanı (c) tüm spektral imzalar (d) spektral imzaların ortalaması

```

satir = 512;
sutun = 512;
band_sayisi = 204;
hassasiyet = 0;
format = 'bil';
karakter_vektoru = 'ieee-le';
yansitilan_veri = 'hiperkup \ veri seti';
veri_tipi = 'float32';

```

% Hiperküpün okunması

```

hiperkup = multibandread(yansitilan_veri,
[satir sutun band_sayisi], veri_tipi, hassasiyet,
format, karakter_vektoru);

```

% Farklı dalga boylarındaki görüntüler

```

imread(hiperkup(:,1),[]) % 1. band
imread(hiperkup(:,2),[]) % 2. band
.
imread(hiperkup(:,204),[]) % 204. band

```

% İlgi alanlarının belirlenmesi

```

imread(hiperkup(25:400,200:450,1),[]) % 1.
band İA
imread(hiperkup(25:400,200:450,2),[]) % 2.
band İA
.
imread(hiperkup(25:400,200:450,204),[])
%204. band İA

```

% Spektral imzaların çıkarılması

```

for i=25:400
    for j=200:450
        for k= 1:204
            imza(k) = hiperkup(i,j,k);
        end
        hold on
        plot(imza)
    end
end

```

% Ortalama spektral imzaların bulunması

```

x = zeros(1,204);
for i = 25:400
    for j = 200:450
        for k= 1:204
            imza(k) = hiperkup(i,j,k);
            x(k)= x(k)+imza(k);
        end
    end
end
for p =1:204
    x (p) = x(p)/(22500);
end
hold on
grid on
plot(x, '-b', 'LineWidth', 2)

```


Şekil 4.5. MATLAB kodları

Görüntülere ait spektral imzalar iki farklı yöntemle elde edilebilmektedir. İlk yöntem, bir pikselin farklı dalga boyları altındaki spektral değerleri kullanılarak spektral imzaların çıkarılması, diğeri ise bir dalga boyunda tüm piksellerin spektral değerleri kullanılarak elde edilen spektral imzalardır. Uygulamalarda, genellikle ilk yöntem kullanılarak spektral imzalar elde edilir. Tez çalışmasının bu bölümünde de ilk yöntem tercih edilmiştir.

4.2.1. Spektral imzalar arasındaki farklılıkların incelenmesi ile yenidoğanların sağlık durumlarının tespit edilmesi

Bu çalışma için, 7 hasta ve 3 sağlıklı olmak üzere toplam 10 yenidoğan bebeğe ait spektral imzalar çıkarılarak benzerlikleri ve farklılıkları incelenmiştir. Örnek olarak, Şekil 4.6 (a)'da 3 hasta yenidoğana ve Şekil 4.6 (b)'de 3 sağlıklı yenidoğana ait hiperspektral görüntülerden elde edilen spektral imzalar gösterilmiştir. Öncelikle rastgele olarak verilerden ilgi alanları seçilmiş ve bu ilgi alanları görüntü olarak kaydedilmiştir. Elde edilen görüntülerin boyutları, yenidoğanların gövdesini içine alacak şekilde 150 x 150 olarak belirlenmiştir. Spektral imzalar tüm pikseller için çıkarılmıştır. Şekilde görülen her bir renk farklı bir piksel için spektral imzaya karşılık gelmektedir.

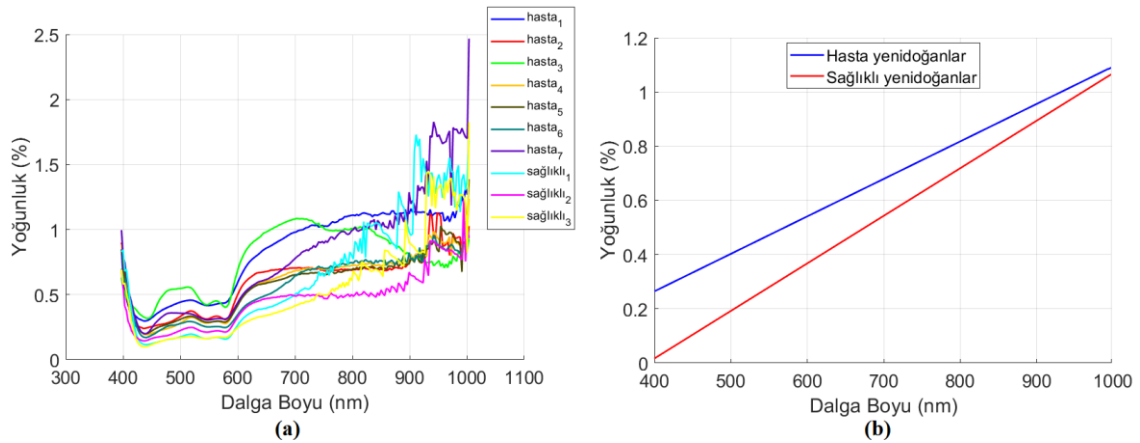
Şekil 4.6'daki hasta ve sağlıklı yenidoğanlara ait spektral imzalar incelendiğinde, aralarındaki fark görsel olarak tespit edilebilmektedir. Hasta yenidoğanların spektral imzaları 600 nm'den sonra yoğunluk bakımından çok yüksek bir şekilde değişim göstermiştir. Sağlıklı yenidoğanların ki ise 600 nm'den sonraki dalga boylarında da kararlı bir değişim göstermektedir. Ayrıca sağlıklı yenidoğanlara ait spektral imzalarda, yaklaşık 750 nm'den sonra ki bantlarda yoğunluk değişimi kararlı değildir. Bu yüzden 750 nm'den sonraki dalga boyları bu veriler için net bir sonuç vermemektedir. Ayrıca Hasta-1 ve Hasta-2'nin spektral imzalarına bakıldığında 600 nm'den sonra yoğunlukları yükselirken 700 nm den sonra ise Hasta-1 in artmaya devam ettiği fakat Hasta-2'nin ise yoğunluğunun düştüğü görülmektedir. Bu durum iki bebeğin farklı hastalıklara sahip olduğunun bir göstergesidir.



Şekil 4.6. Hasta ve sağlıklı yenidoğanlara ait spektral imzalar (a) Hasta-1, Hasta-2 ve Hasta-3 için (b) Sağlıklı-1, Sağlıklı-2 ve Sağlıklı-3 için

Hasta ve sağlıklı yenidoğanlara ait tüm piksellerin ortalamasının alınarak tek bir spektral imza olarak ifade edildiği grafik Şekil 4.7 (a)'da yer almaktadır. Daha önce belirtildiği gibi hasta ve sağlıklı yenidoğanların spektral imzaları arasında gözle görülür bir şekilde farklılıklar vardır. Ayrıca, sağlıklı yenidoğanların spektral imzalarının birbirine ne kadar yakın olduğu şekilde net olarak gösterilmiştir. Şekil 4.7 (b)'de ise iki değişken arasındaki ilişkiyi modellemek için, hasta ve sağlıklı yenidoğanlara ait spektral imzaların ayrı ayrı ortalaması alınarak oluşturulmuş lineer regresyonlar verilmiştir. Kırmızı, sağlıklı lineer regresyonu, mavi ise hasta lineer regresyonu göstermektedir. Bu şekle bakılarak aralarındaki yoğunluk farkı görülebilmektedir. Sonuç olarak, hasta ve

sağlıklı yenidoğanlara ait spektral imzalar incelenerek yenidoğanların sağlık durumlarının tespit edilebilmesi mümkün olmuştur.



Şekil 4.7. Hasta ve sağlıklı yenidoğanlara ait (a) spektral imzaların ortalaması (b) spektral imzaların ortalamalarının lineer regresyonları

Tablo 4.3'te Şekil 4.7 (a)'daki hasta ve sağlıklı bebeklerden elde edilmiş spektral verilerinin istatistiksel değerleri gösterilmiştir. Bu istatistiksel değerler hasta ve sağlıklı bebeklerin durumu hakkında bilgiler vermektedir. Örneğin, sağlıklı yenidoğanların yoğunluklarının *minimum* değerleri hasta olanlara göre çok daha küçük değerdedir. Ayrıca, *maksimum* değerleri genel olarak daha yüksek olduğu gözükmektedir. *Ortalama* ve *medyan* değerlerine göre kıyaslanacak olursa sağlıklı yenidoğanlarına ait istatistiksel veriler hastalıklı yenidoğanlara oranla daha küçük değerdedir. Spektral imzalara ait standart sapma değerleri tabloda verilmiştir.


Tablo 4.3. Hasta ve sağlıklı yenidoğanların spektral verilerinin istatistiksel değerleri

Denek	Veri İstatistikleri				
	Minimum	Maksimum	Ortalama	Medyan	Standart sapma
Hasta-1	0.2967	1.386	0.8251	0.9724	0.3179
Hasta-2	0.2398	1.128	0.6018	0.6885	0.2209
Hasta-3	0.3175	1.085	0.766	0.8085	0.2422
Hasta-4	0.1918	1.237	0.5874	0.6854	0.2395
Hasta-5	0.1989	1.376	0.5785	0.6521	0.2341
Hasta-6	0.1697	1.069	0.5609	0.6437	0.2414
Hasta-7	0.1984	2.467	0.8059	0.781	0.4604
Sağlıklı-1	0.1151	1.729	0.6396	0.5312	0.4547
Sağlıklı-2	0.1443	1.227	0.4508	0.485	0.2115
Sağlıklı-3	0.09863	1.825	0.5228	0.4304	0.3747

Bu çalışmada kullanılan veri sayısının sınırlı olmasından dolayı elde edilen istatistiksel veriler çok belirleyici olmayabilir. Bu yüzden yapay zekâ algoritmaları kullanılarak daha belirleyici sonuçlar elde edilmesi mümkündür.

4.3. İki Boyutlu Evrişimli Sinir Ağları Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi

Bu çalışmada yenidoğan bebeklerin sağlık durumlarının tespit edilmesi için 2B-ESA kullanılmıştır. Hiperspektral görüntü analizi için 14 hasta hiperküp ve 3 sağlıklı yenidoğandan farklı zamanlarda alınmış 14 sağlıklı hiperküp, yani toplamda 28 hiperküp ele alınmıştır.



Şekil 4.8. 2B-ESA için önerilen sistemin blok diyagramı


Önerilen sistemin blok diyagramı Şekil 4.8'de gösterilmiştir. Her bir hiperküpün farklı dalga boylarında 204 görüntü elde edilmiştir. Bu çalışmada 28 hiperküp, yani 5712 görüntü sınıflandırma işlemi için kullanılmıştır. Bu görüntülerin 2856'sı hasta yenidoğanlara, geriye kalan 2856'sı ise sağlıklı yenidoğanlara aittir. Sınıflandırma işlemi için eğitim ve test verileri 5-katlamalı çapraz doğrulama yöntemi kullanılarak beş farklı parçaya bölünmüştür. Daha sonra, eğitim verileri oluşturulan ESA modeli ile eğitildikten sonra, test verileri ile test edilip sınıflandırma işlemi gerçekleştirilmiştir.

4.3.1. 2B-ESA model tasarımı

Tasarlanan 2B-ESA modelindeki temel ilke; yenidoğanlara ait hiperspektral görüntüler sınıflandırılırken, modelin aşırı öğrenmesinin önüne geçmek ve yüksek doğruluk oranında sonuçlar elde etmektir. Bunun için, bu çalışmada 7x7, 5x5 ve 3x3 boyutunda konvolüsyon katmanları kullanılmış, her konvolüsyon katmanından sonra maksimum havuzlama katmanı kullanılarak boyut azaltılmış, aşırı öğrenmenin önüne geçmek için unutturma katmanı kullanılmış ve tam bağlı katmanlar ile ağ daha derin hale getirilerek sınıflandırma doğruluk oranlarının artırılması sağlanmıştır. Oluşturulan 2B-ESA yapısı tasarımı ve parametreler aşağıdaki bölümlerde ayrıntılı olarak açıklanmıştır.

4.3.1. Ağ yapısı

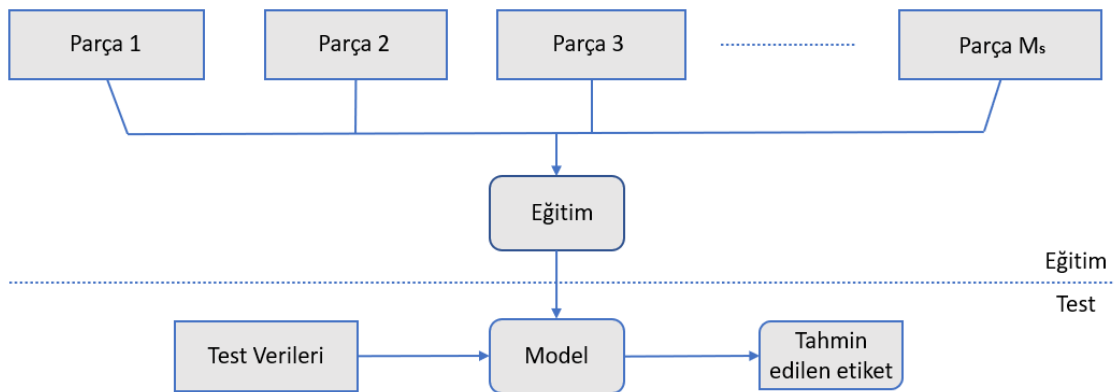
Ağ yapısı Şekil 4.9'da gösterilmiştir. İlk olarak yenidoğanlardaki hastalıkların gövde bölgesinde oluşmasından dolayı, bu bölgeden 128x128'lik ilgi alanları seçilmiştir. Ağ yapısında toplamda 5 konvolüsyon katmanı vardır. Giriş verisinin boyutu 128x128'dir. Giriş verileri birinci konvolüsyon katmanına gönderilir. İlk konvolüsyon katmanında 128 filtre vardır ve filtre boyutu 7x7 olarak belirlenmiştir. Ayrıca her bir konvolüsyon katmanından sonra 2x2 boyutunda maksimum havuzlama katmanı kullanılmış ve boyut küçültülmüştür. İkinci konvolüsyon katmanında filtre sayısı 128 ve filtre boyutu 5x5 olarak alınmıştır. Sonraki 3 konvolüsyon katmanında sırasıyla 64, 32 ve 32 adet filtre uygulanmış ve tüm bu filtrelerin boyutu 3x3 olarak belirlenmiştir. Ayrıca her konvolüsyon katmanından sonra ReLU aktivasyon fonksiyonu kullanılmıştır. Son durumda verilerin boyutu 4x4'e kadar düşürülmüştür. Bu aşamadan sonra veriler düzleştirilerek bir boyutlu tensörler haline dönüştürülmüştür. Bu işlemde sonra beş tane tam bağlı katman kullanılmış ve 2. ve 3. tam bağlı katmandan sonra unutturma katmanı kullanılarak aşırı öğrenmenin önüne geçilmiştir. Unutturma katmanının değeri 0.4 olarak belirlenmiştir. Tam bağlı katmanın ilk beş katmanı sırası ile 512, 256, 128, 64 ve 16 nöron içerirken çıkış katmanı olan altıncı katman 1 nöron içermektedir. Son olarak toplamda 2 sınıf (hasta ve sağlıklı) olduğu için sigmoid fonksiyonu kullanılarak sınıflandırma işlemi yapılmıştır.



Şekil 4.9. 2B-ESA model yapısı

4.3.2. Parametre öğrenme süreci ve hiperspektral görüntü analizi için uygulama

Model eğitilirken veriler rasgele parçalara ayrılmıştır. Tüm parçalar eşit sayıda veri içerecek şekilde ayarlanmış ve bu değer 60 olarak belirlenmiştir. 2B-ESA, *Adam optimizer* (Kingma ve Ba, 2015) kullanılarak eğitilmiştir. İlk başta *öğrenme oranı* 0.0001 olarak seçilmiş (Li ve ark., 2017) ve model 100 epoch'ta eğitilmiştir. Eğitim ve test işlemleri Şekil 4.10'da gösterilmiştir. Burada model eğitildikten sonra test verileri modele gönderilir ve tahmin edilen etiket, sigmoid fonksiyonu sonucunda bulunan değerle kıyaslanıp sınıflandırılır.



Şekil 4.10. Parametre öğrenme sürecinin gösterilmesi ve hiperspektral analizin uygulanması

4.3.3. 5-katlamalı çapraz doğrulama

Bu çalışmada 5-katlamalı çapraz doğrulama yöntemi kullanılarak tüm veri 5 parçaya bölünmüştür. Oluşturulan her bir parça farklı dalga boyları arasındaki görüntü verilerini içermektedir. Bu durum hem sonuçların daha doğru değerlendirilmesi hem de hangi dalga boylarındaki verilerin daha iyi sonuçlar verdiğinin göstergesidir. 5 parçaya ayrılmış farklı eğitim ve test verilerinin sayısı Tablo 4.4'te detaylandırılmıştır.

Tablo 4.4. 5-katlamalı çapraz doğrulama yöntemi kullanılarak spektral bantlara göre oluşturulan eğitim ve test verileri

Veri setleri	Spektral Bantlar (nm)		Görüntü Sayısı		
	Eğitim	Test	Eğitim	Test	Toplam
I	513.4–1000	400–510.48	4592	1120	5712
II	400–510.48 ve 631.15–1000	513.4–628.18	4592	1120	5712
III	400–628.18 ve 750.54–1000	631.15–747.54	4592	1120	5712
IV	400–747.54 ve 871.6–1000	750.54–868.55	4592	1120	5712
V	400–868.55 ve 994.31–1000	871.6–991.22	4592	1120	5712

Tablo 4.4'de de gösterildiği gibi eğitim ve test verileri oluşturulurken farklı bantlar kullanılması amaçlanmıştır. I. verisetinde 513.4-1000 nm arasındaki uzamsal görüntüler eğitim için 400-510.48 nm arasındaki uzamsal görüntüler ise test için kullanılmıştır. II. verisetinde 400–510.48 nm ve 631.15–1000 nm arasındaki uzamsal görüntüler eğitim için 513.4–628.18 nm arasındaki uzamsal görüntüler ise test için kullanılmıştır. III. verisetinde 400–628.18 nm ve 750.54–1000 nm arasındaki uzamsal görüntüler eğitim için 631.15–747.54 nm arasındaki uzamsal görüntüler ise test için kullanılmıştır. IV. verisetinde ise 400–747.54 nm ve 871.6–1000 nm arasındaki uzamsal görüntüler eğitim için 750.54–868.55 nm arasındaki uzamsal görüntüler test için kullanılmıştır. Son olarak, V. verisetinde 400–868.55 ve 994.31–1000 nm arasındaki uzamsal görüntüler eğitim için 871.6–991.22 nm arasındaki uzamsal görüntüler ise test için kullanılmıştır. Tabloda gösterilen tüm eğitim ve test verilerinin %50'si hasta, %50'si sağlıklı olarak alınmıştır.

4.3.4. 2B-ESA sonucunda elde edilen sınıflandırma sonuçları


Bu çalışmada sınıflandırma işlemi 14 hasta ve 14 sağlıklı hiperküp, toplamda 5712 hiperspektral görüntü kullanılarak gerçekleştirilmiştir. 5-katlamalı çapraz doğrulama yöntemi kullanılarak beş farklı veri seti için ayrı ayrı karmaşıklık matrisleri oluşturulmuştur. Karmaşıklık matrisinden genel doğruluk, kappa katsayısı, hassasiyet ve özgüllük değerleri

elde edilmiştir. Bu değerler sınıflandırma performansını değerlendirmek için kullanılmıştır. Tüm veri setleri için elde edilen sonuçlar Tablo 4.5'te gösterilmiştir.

Tablo 4.5. 2B-ESA için sınıflandırma sonuçları

Veri seti	Karmaşıklık matrisi	Genel doğruluk	Kappa katsayısı	Hassasiyet	Özgüllük
I	$\begin{bmatrix} 492 & 68 \\ 79 & 481 \end{bmatrix}$	86.88%	73.75%	87.86%	85.89%
II	$\begin{bmatrix} 560 & 0 \\ 0 & 560 \end{bmatrix}$	100%	100%	100%	100%
III	$\begin{bmatrix} 560 & 0 \\ 40 & 520 \end{bmatrix}$	96.43%	92.86%	100%	92.86%
IV	$\begin{bmatrix} 560 & 0 \\ 27 & 533 \end{bmatrix}$	97.59%	95.18%	100%	95.18%
V	$\begin{bmatrix} 470 & 90 \\ 77 & 483 \end{bmatrix}$	85.09%	70.18%	83.93%	86.25%

Tablo 4.5'te görüldüğü gibi birinci veri setinde hasta verilere ait 560 hiperspektral görüntünün 492'si, sağlıklı verilere ait 560 hiperspektral görüntünün 481'i doğru olarak sınıflandırılmıştır. Burada genel doğruluk %86.88, kappa katsayısı %73.75, hassasiyet %87.86 ve özgüllük %85.89 olarak elde edilmiştir. İkinci veri setinde ise verilerin tamamı doğru sınıflandırılmış, tüm performans kriterleri için %100 başarı oranı elde edilmiştir. Üçüncü veri setinde hasta verilere ait 560 hiperspektral görüntünün 560'ı ve sağlıklı verilere ait 560 hiperspektral görüntünün 520'si doğru olarak sınıflandırılmıştır. Burada elde edilen performans kriterleri: genel doğruluk %96.43, kappa katsayısı %92, hassasiyet %100 ve özgüllük %92.86'dır. Dördüncü veri setinde ise hasta verilere ait 560 hiperspektral görüntünün 560'ı ve sağlıklı verilere ait 560 hiperspektral görüntünün 533'ü doğru bir şekilde sınıflandırılmıştır. Bu veri setindeki performans kriterleri genel doğruluk %97.59, kappa katsayısı %95.18, hassasiyet %100 ve özgüllük %95.18'dir. Son olarak beşinci veri setinde hasta verilere ait 560 hiperspektral görüntünün 470'i ve sağlıklı verilere ait 560 hiperspektral görüntünün 483'ü doğru bir şekilde sınıflandırılmıştır. Burada genel doğruluk %85.09, kappa katsayısı %70.18, hassasiyet %83.93 ve özgüllük %86.25 olarak elde edilmiştir. Tüm veri setleri için elde edilen sonuçlar, Şekil 4.11'de ayrıntılı olarak gösterilmiştir.



Şekil 4.11. Performans değerlerinin karşılaştırılması


Bu çalışmada en iyi sonuç ikinci veri setinde, %100 oranında bir başarı elde edilerek gerçekleştirilmiştir. Ayrıca sonuçların değerlendirilmesi için 5 katlamalı çapraz doğrulama yöntemi kullanılmış ve tüm karmaşıklık matrislerinin toplanması sonucu elde edilen karmaşıklık matrisi Tablo 4.6'da gösterilmiştir. Sonuç olarak genel doğruluk %93.19, kappa katsayısı %86.40, hassasiyet %94.35 ve özgüllük %92.04 değerinde elde edilmiş ve sınıflandırma işlemi gerçekleştirilmiştir.

Tablo 4.6. Tüm karmaşıklık matrislerinin toplanması sonucu elde edilen genel değerlendirme sonuçları

Karmaşıklık matrisi	Genel doğruluk	Kappa katsayısı	Hassasiyet	Özgüllük
$\begin{bmatrix} 2642 & 158 \\ 223 & 2577 \end{bmatrix}$	%93.19	%86.40	%94.35	%92.04


4.4. Üç Boyutlu Evrişimli Sinir Ağları Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi

Hiperspektral verilerin sınıflandırılmasında uzamsal özelliklerin yanı sıra spektral özelliklerde büyük önem taşımaktadır. 2B-ESA kullanılarak yapılan çalışmada verilerden sadece uzamsal özellikler çıkarılmıştır. Bu çalışmada ise 3B-ESA kullanılarak hiperspektral verilerden hem uzamsal hem de spektral özelliklerin elde edilmesi amaçlanmış ve bu işlem sonucunda daha anlamlı özellik haritaları çıkarılmıştır. Bu çalışmanın amacı yenidoğanlara ait hacimsel verilerin (hiperküpler) sınıflandırılmasıdır.



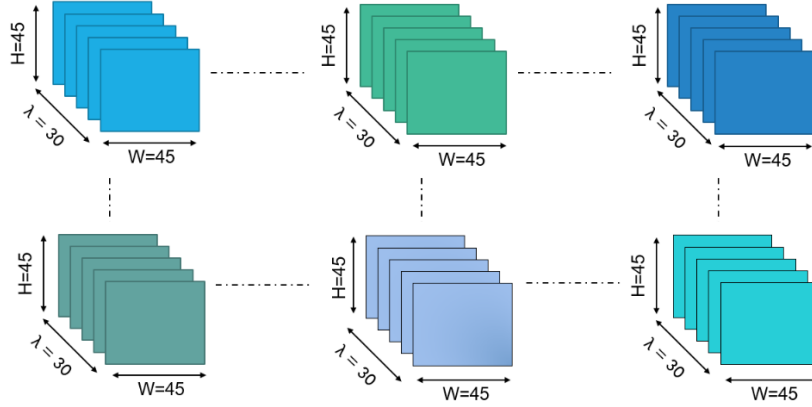
Şekil 4.12. 3B-ESA için önerilen sistemin blok diyagramı

Önerilen sistemin blok diyagramı Şekil 4.12'de gösterilmiştir. Bu çalışmada sınıflandırma işlemi 16 hasta hiperküp ve 3 sağlıklı yenidoğandan farklı zamanlarda alınmış 16 sağlıklı hiperküp, yani toplamda 32 hiperküp kullanılarak gerçekleştirilmiştir. Tüm verilerden $45 \times 45 \times 204$ 'lük ilgi alanları seçilmiş ve ayrı ayrı 3 boyutlu veri olarak kaydedilmiştir. Başka bir ifadeyle, Şekil 4.13'te görüldüğü gibi, her bir yenidoğana ait $45 \times 45 \times 204$ boyutunda veriler elde edilmiştir. Burada W ve H uzamsal boyutu, λ ise band sayısını ifade etmektedir.




Şekil 4.13. 32 farklı yenidoğandan elde edilen 3B ilgi alanları

Daha sonra, veri boyutunun çok büyük olmasından dolayı, hesaplama maliyetinden kurtulmak için uzamsal boyut değişmeyecek şekilde tüm 3B verilere Temel Bileşenler Analizi ayrı ayrı uygulanarak verilerin boyutları azaltılmıştır. Bu işlem sonucunda 45x45x30 boyutunda yeni hiperküpler oluşturulmuştur (Şekil 4.14).



Şekil 4.14. TBA sonucunda elde edilen 3B veriler

Bu çalışmada Şekil 4.12’de ve Tablo 4.7’de görüldüğü gibi 3B-ESA mimarisi 3 konvolüsyon, 2 havuzlama, 1 düzleştirme ve 4 tam bağlı katman kullanılarak oluşturulmuştur. Ayrıca her tam bağlı katmandan sonra unutturma katmanı kullanılarak aşırı öğrenmenin de önüne geçilmiştir. Şekil 4.15’te gösterildiği gibi 3 boyutlu konvolüsyon katmanları kullanılıp hem uzamsal hem de spektral özellikler elde edilerek özellik haritaları çıkarılmıştır.



Şekil 4.15. 3B-ESA Model Yapısı

Tablo 4.7. 3B-ESA Modeli

Katman	Tip
Konvolüsyon	Conv3d
Max havuzlama	Maxpool3d
Konvolüsyon	Conv3d
Max havuzlama	Maxpool3d
Konvolüsyon	Conv3d
Düzleştirme	Flatten
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı

Bu çalışma için ilk konvolüsyon katmanı 5x5x7 boyutunda 128 farklı filtre, ikinci konvolüsyon katmanı 3x3x5 boyutunda 64 farklı filtre ve son konvolüsyon katmanı ise 3x3x3 boyutunda 32 farklı filtre içermektedir. Kullanılan iki havuzlama katmanının boyutu 2x2x2 şeklindedir. Düzleştirme katmanından sonra eklenen ilk ağ katmanı 128, ikincisi 64, üçüncüsü 32, dördüncüsü 16 nöron içermekte ve çıkış ağ katmanı 1 nöron içermektedir. İlk 4 ağ katmanından sonra kullanılan unutturma katmanlarına ait değerler ise 0.4 olarak belirlenmiştir.

Hiperspektral görüntülemeyle elde edilen hiperküplerin 3B-ESA ile hasta ve sağlıklı olarak sınıflandırılması için 24 hiperküp eğitim, 8 hiperküp ise test olarak ayrılmıştır. Bu çalışmada 4-katlamalı çapraz doğrulama kullanılmıştır. Sınıflandırma sonucunu gösteren toplam karmaşıklık matrisi Tablo 4.8’de verilmiştir. Oluşturulan ağ 16 hasta hiperküpün 15 ini doğru olarak ve 16 sağlıklı hiperküpün tümünü doğru olarak sınıflandırmıştır. Sonuç olarak genel doğruluk %96.88, kappa katsayısı %93.76, hassasiyet %93.75 ve özgüllük %100 olarak elde edilmiştir.


Tablo 4.8. 3B-ESA ile hiperküplerin sınıflandırılmasına ait karmaşıklık matrisi

		Tahmin edilen sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	15	1
	Sağlıklı	0	16

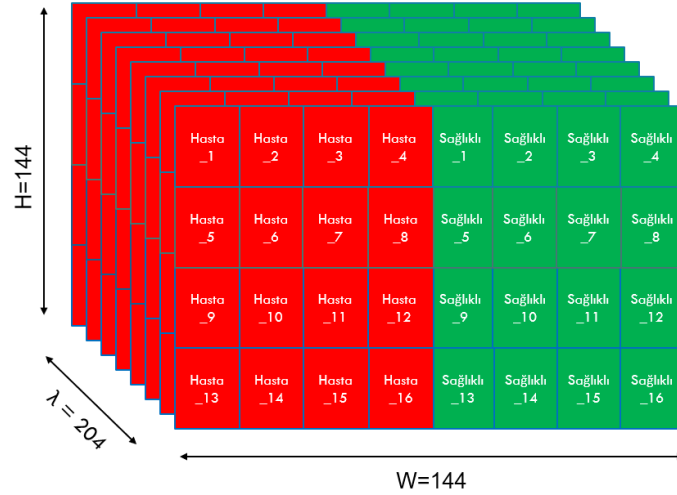
Bu çalışmada, batch boyutu 2 olarak belirlenmiş ve model 100 epoch’ta eğitilmiştir.

4.5. Komşuluk Çıkarma Yöntemi Kullanılarak Yenidoğan Bebeklerin Sağlık Durumlarının Tespit Edilmesi

Bu çalışmada komşuluk çıkarma yöntemi kullanılarak yenidoğan bebeklerin sağlık durumlarının tespit edilmesi hedeflenmiştir. Önerilen sistemin blok diyagramı Şekil 4.16'da gösterilmiştir. Sınıflandırma için bir önceki çalışmada olduğu gibi 32 hiperküp ele alınmış ve ilgi alanları seçilmiştir. Bu ilgi alanlarının boyutu $36 \times 18 \times 204$ olarak belirlenmiştir. Toplamda 32 hiperküpten elde edilen ilgi alanları tek bir hiperküp oluşturmak için birleştirilmiştir. Oluşturulan bu hiperküpün boyutu $144 \times 144 \times 204$ 'tür (Şekil 4.17). Burada kırmızı olan bölgeler hasta yenidoğanları gösterirken, yeşil olanlar ise sağlıklı yenidoğanları göstermektedir. Tek bir hiperküp elde edilmesinin amacı *komşuluk çıkarma* yöntemini uygulamaktır.

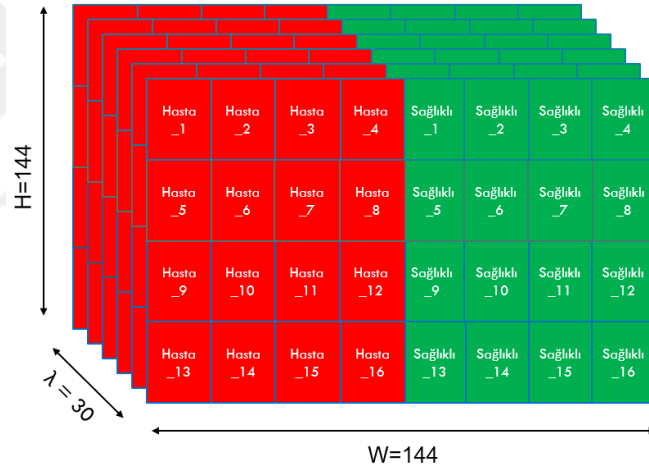


Şekil 4.16. Komşuluk çıkarma yöntemi için önerilen sistemin blok diyagramı




Şekil 4.17. 32 yenidoğana ait hiperküplerin birleştirilmesi sonucu oluşan tek hiperküp

Şekil 4.17'deki hiperküpe uzamsal boyut değişmeyecek şekilde TBA yöntemi uygulanıp spektral boyut 30'a indirgenerek boyut azaltılmıştır. Oluşan yeni hiperküp Şekil 4.18'de gösterilmiştir.



Şekil 4.18. TBA sonucunda elde edilen yeni hiperküp

Etiketleri oluşturmak için kırmızı bölgede bulunan hasta yenidoğanlardan elde edilen piksellerin hepsine 0 etiketi atanmış ve aynı şekilde yeşil bölgedeki tüm piksellere 1 etiket değeri atanarak gerçek etiketler oluşturulmuştur. Yani, $144 \times 72 = 10368$ tane etiket 0, $144 \times 72 = 10368$ tane etiket değeri 1 olacak şekilde toplamda $144 \times 144 = 20736$ tane 2'li etiket değeri oluşturulmuştur. Oluşturulan etiket değerleri Şekil 4.19'da gösterilmiştir. Daha sonra ayrı ayrı bu pikseller merkez noktası olacak şekilde $S_x S_y S_z$ boyutunda 3B mini küpler oluşturulmuş ve oluşan bu küplere merkez noktasındaki etiket değerleri atanmıştır. Oluşturulan bu mini küpler Şekil 4.20'de ayrıntılı bir şekilde gösterilmiştir. Burada tüm pikseller dahil edileceği için öncelikle sıfır ekleme işlemi yapılarak çerçeve l boyutunda genişletilmiştir.



Şekil 4.21. Komşuluk çıkarma yöntemi için kullanılan 3B-ESA model yapısı

Tablo 4.9. Komşuluk çıkarma yöntemi için 3B-ESA Modeli

Katman	Tip
Konvolüsyon	Conv3d
Konvolüsyon	Conv3d
Konvolüsyon	Conv3d
Düzleştirme	Flatten
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı
Unutturma	-
Tam bağlı katman	Ağ katmanı


Bu çalışmada Şekil 4.21’de ve Tablo 4.9’da gösterildiği gibi birinci konvolüsyon katmanı 5x5x7 boyutunda 128 farklı filtre, ikinci konvolüsyon katmanı 3x3x5 boyutunda 64 farklı filtre ve son konvolüsyon katmanı ise 3x3x3 boyutunda 32 farklı filtre içermektedir. Burada havuzlama yapılmamıştır. Düzleştirme katmanından sonra eklenen ilk tam bağlı katman 128, ikincisi 64, üçüncüsü 32, dördüncüsü 16 nöron içermekte ve çıkış ağ katmanı 1 nöron içermektedir. İlk 4 ağ katmanından sonra kullanılan unutturma katmanı değerleri ise 0.4 olarak belirlenmiştir.

4.5.1. Tüm verilerin %50'sinin eğitim %50'sinin test olarak kullanılmasıyla elde edilen sınıflandırma sonuçları

İlk aşamada, oluşturulan 20736 adet üç boyutlu verinin %50'si eğitim, %50'si ise test için kullanılmıştır. Oluşturulan ağ toplam 5184 hasta verinin tümünü ve 5184 sağlıklı verinin tümünü doğru olarak sınıflandırmıştır. Sınıflandırma sonucunu elde edilen karmaşıklık matrisi Tablo 4.10'da gösterilmiştir. Sınıflandırma sonucu olarak genel doğruluk %100, kappa katsayısı %100, hassasiyet %100 ve özgüllük %100 olarak elde edilmiştir. Ayrıca Şekil 4.22'de gerçek etiket değerlerinin bulunduğu ve sınıflandırma sonucu elde edilen değerlerin bulunduğu şekiller verilmiştir. Bu şekillerden de yola çıkarak tüm verilerin doğru sınıflandırıldığı görülebilmektedir.

Tablo 4.10. %50 eğitim, %50 test için karmaşıklık matrisi

		Tahmin edilen sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	5184	0
	Sağlıklı	0	5184



Şekil 4.22. %50 eğitim, %50 test için (a) gerçek etiket değerleri (b) sınıflandırma sonucu elde edilen değerler


Bu çalışmada batch boyutu 100 olarak belirlenmiş ve model 100 epoch'ta eğitilmiştir.

4.5.2. Tüm verilerin %10'unun eğitim %90'ının test olarak kullanılmasıyla elde edilen sınıflandırma sonuçları

İkinci olarak ise oluşturulan 20736 verinin %10'u eğitim, %90'ı ise test için kullanılmış ve daha az eğitim verisi ele alınarak yöntemin verimliliği test edilmiştir. Oluşturulan ağ, toplam 9331 hasta verinin 9315'ini ve 9331 sağlıklı verinin ise tümünü doğru olarak sınıflandırmıştır. Sınıflandırma sonucunu gösteren karmaşıklık matrisi Tablo 4.11'de gösterilmiştir. Sonuç olarak genel doğruluk %99,91, kapa katsayısı %99,83, hassasiyet %99,82 ve özgüllük %100 olarak elde edilmiştir. Geliştirilen bu yöntemle az sayıda eğitim verisiyle bile yüksek başarı oranları elde edileceği gösterilmiştir. Ayrıca Şekil 4.23'de gerçek etiket değerlerinin bulunduğu ve sınıflandırma sonucu elde edilen şekiller verilmiştir. Burada da görüldüğü gibi dikdörtgen içinde kalan hasta 16 piksel sağlıklı olarak sınıflandırılmış ve onların haricindeki tüm pikseller doğru olarak sınıflandırılmıştır.

Tablo 4.11. %10 eğitim, %90 test için karmaşıklık matrisi

		Tahmin edilen sınıf	
		Hasta	Sağlıklı
Gerçek Sınıf	Hasta	9315	16
	Sağlıklı	0	9331



Şekil 4.23. %10 eğitim, %90 test için (a) gerçek etiket değerleri (b) sınıflandırma sonucu elde edilen değerler

Bu çalışmada batch boyutu 100 olarak belirlenmiş ve model 100 epoch'ta eğitilmiştir.

6. SONUÇLAR VE ÖNERİLER

6.1 Sonuçlar

Bu tez çalışmasında HSG ve derin öğrenme yöntemleri kullanılarak yenidoğanların sağlık durumlarının tespit edilmesi amaçlanmıştır. Bu zamana kadar literatürde HSG ve derin öğrenme kullanılarak yenidoğanlarla ilgili yapılmış bir çalışma yoktur. Elde edilen sonuçlar bir ilk niteliği taşımaktadır.

Derin öğrenme yöntemleri kullanılmadan önce hasta ve sağlıklı yenidoğanlara ait hiperspektral görüntülerden ilgi alanları seçilmiş ve bu ilgi alanlarından spektral imzalar çıkarılmıştır. Çıkarılan bu imzalar incelendiğinde hasta ve sağlıklı yenidoğanlar arasında bariz bir şekilde farklılıklar olduğu gözlemlenmiştir. Bu durum HSG'nin yenidoğanların sağlık durumlarının tespitinde iyi sonuçlar vereceğini göstermiştir. Bunun sonucunda elde edilen hiperspektral verilerden anlamlı özelliklerin çıkarılıp sınıflandırılma işleminin yapılması için derin öğrenme yöntemlerinden biri olan evrişimli sinir ağı kullanılmıştır.

İlk olarak 2B-ESA ile yapılan çalışmada, farklı dalga boylarında elde edilen toplam 5712 hiperspektral görüntü kullanılmıştır. Daha sonra 5-katlamalı çapraz doğrulama yöntemi kullanılarak görüntüler beş parçaya bölünerek farklı veri setleri oluşturulmuştur. Her bir veri seti için farklı dalga boylarında veriler eğitim ve test verilerini içermektedir. Tasarlanan ağ modeli oluşturulan veri setleriyle ayrı ayrı eğitilmiş ve test verileri kullanılarak test edilmiştir. Sınıflandırma işlemi sonunda en iyi sonuçlar, eğitim için 400–510.48 ve 631.15–1000 nm aralığındaki HS görüntülerin test için ise 513.4–628.18 nm aralığındaki HS görüntülerin kullanıldığı uygulamada elde edilmiştir. Sonuç olarak tüm görüntüler doğru olarak sınıflandırılmış ve performans değerleri (genel doğruluk, kapa katsayısı, hassasiyet ve özgüllük) %100 olarak bulunmuştur. Genel değerlendirme için 5-katlamalı çapraz doğrulama sonucu oluşan tüm karmaşıklık matrislerindeki değerlerin toplanmasıyla yeni karmaşıklık matrisi oluşturulmuştur. Bunun sonucunda ise genel doğruluk %93.19, kapa katsayısı %86.40, hassasiyet %94.35 ve özgüllük %92.04 oranı elde edilmiştir.

İkinci olarak 3B-ESA yöntemi kullanılarak yenidoğanların sağlık durumunun tespiti gerçekleştirilmiştir. Bu çalışma için 16 hasta hiperküp ve 16 sağlıklı hiperküp, toplamda 32 hiperküp sınıflandırma için kullanılmıştır. TBA yöntemi kullanılarak uzamsal boyut değişmeyecek şekilde spektral boyut 204'ten 30'a düşürülerek eğitim ve

test verileri oluşturulmuştur. Tasarlanan 3B-ESA modeli ile TBA sonucunda elde edilen veriler eğitilmiştir. 2B-ESA'dan farklı olarak 3B konvolüsyon katmanları kullanılmış, uzamsal özelliklere ilave olarak spektral özelliklerde çıkarılmıştır. Bu çalışmada 4-katlamalı çapraz doğrulama yöntemi kullanılmıştır. Sınıflandırma sonucu olarak 16 hasta verinin 15'i, 16 sağlıklı verinin ise tümü doğru olarak sınıflandırılmıştır. Oluşturulan karmaşıklık matrisine göre genel doğruluk %96.88, kappa katsayısı %93.76, hassasiyet %93.75 ve özgüllük %100 olarak elde edilmiştir. Az sayıda veri ile çalışılmasına rağmen 2B-ESA yöntemine göre daha iyi sonuçlara ulaşılmıştır.

Son olarak komşuluk çıkarma yöntemi kullanılarak yenidoğanların sağlık durumlarının tespiti gerçekleştirilmiştir. Komşuluk çıkarma yöntemi yeni bir yöntem olup piksel odaklı sınıflandırma için kullanılmıştır. Bu yöntem için elde edilen tüm hiperküpler birleştirilerek tek bir hiperküp oluşturulmuş ve bu hiperküpe TBA uygulanarak boyut azaltılmıştır. Daha sonra bu hiperküp üzerinde 33x33 boyutunda tüm pikselleri tarayacak şekilde mini küpler elde edilmiştir. Etiket değeri olarak küplerin orta noktasına gelen etiket değerleri atanmıştır. İlk aşamada oluşturulan toplam 20736 küpün %50'si eğitim %50'si test için kullanılmıştır. Sınıflandırma sonucunda 5184 hasta verinin tümü ve 5184 sağlıklı verinin tümü doğru sınıflandırılarak tüm performans kriterleri için %100 oranında başarı elde edilmiştir. Daha sonra sistemin verimliliğini test etmek için daha az eğitim verisi kullanılarak toplam verinin %10'u eğitim, %90'ı test için kullanılmıştır. Sınıflandırma sonucunda 9331 hasta verinin 9315'i doğru, 9329 sağlıklı verinin ise tamamı doğru sınıflandırılmıştır. Burada performans kriterleri genel doğruluk %99,91, kappa katsayısı %99.83, hassasiyet %99.82 ve özgüllük %100 olarak elde edilmiştir. Bu sonuç komşuluk çıkarma yöntemi kullanarak az eğitim verisi ile bile yüksek başarımlar elde edilebileceğini göstermiştir.

Bu tez kapsamında ileriye dönük olarak, elde edilen tüm sonuçlar HSG yöntemi ile insan etkisinden bağımsız bir teşhis sistemi geliştirilmesi için umut vericidir.

6.2 Öneriler

Bu tez çalışmasında hiperspektral veriler yenidoğan yoğun bakım ünitesindeki hasta ve sağlıklı bebeklerden elde edilmiştir. Sınıflandırma işlemi için sadece gerçek veriler kullanılmış, veri artırımı yöntemleri kullanılmamıştır. Az sayıdaki veriler için veri artırma yöntemleri kullanılarak modelin daha fazla veri ile eğitilip test edilmesi sağlanabilir. Bunun için çekişmeli üretici ağ (ÇÜA) yapısı kullanılması önerilmektedir. Bu yapı ile elde bulunan görüntülerden sentetik yeni görüntüler elde edilebilir.

Hiperspektral verilere 2B-ESA ve 3B-ESA ayrı ayrı uygulanarak verilerin sınıflandırılması işlemi gerçekleştirilmiştir. 2B-ESA kullanılarak verilerden sadece uzamsal özellikler elde edilmektedir ve hesaplama maliyeti düşüktür. 3B-ESA ile hem uzamsal hem de spektral özellikler elde edilmektedir ve 2B-ESA'ya nazaran hesaplama maliyeti yüksektir. Bu nedenle, gelecek dönem çalışmalarında 3B-ESA'ya 2B-ESA entegre edilerek hibrit bir model tasarlanması düşünülmektedir. Bu sayede daha anlamlı spektral ve uzamsal özellikler çıkarmanın yanı sıra hesaplama maliyetinin düşürülüp daha iyi sonuçların elde edilmesi sağlanacaktır.

Komşuluk çıkarma yöntemi uygulamasında oluşturulan mini küplerin boyutu 33x33 olarak seçilmiştir. Gelecek dönem çalışmalarında farklı boyutta mini küpler çıkarılarak mini küp boyutunun sınıflandırma performansına etkileri incelenebilir.

Ayrıca, eğitim ve test için yeterli veri sayısının olmadığı veya güçlü işlem ünitelerinin bulunmadığı durumlarda öğrenim aktarması önerilmektedir.

KAYNAKLAR

- Adam, E., Mutanga, O., ve Rugege, D., 2010, Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review, *Wetlands Ecology and Management*, 18(3), 281-296.
- Ahmad, M., 2020, A fast 3D CNN for hyperspectral image classification, *IEEE Geoscience and Remote Sensing Letters*, 1-5.
- Akbari, H., Uto, K., Kosugi, Y., Kojima, K., ve Tanaka, N., 2011, Cancer detection using infrared hyperspectral imaging, *Cancer science*, 102(4), 852-857.
- 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.
- Baltussen, E. J., Kok, E. N., de Koning, S. G. B., Sanders, J., Aalbers, A. G., Kok, N. F., Beets, L., Flohil, C. C., Bruin, S. C., Kuhlmann, K. F. D., Sterenborg ve H. J., Ruers, T. J. M., 2019, Hyperspectral imaging for tissue classification, a way toward smart laparoscopic colorectal surgery, *Journal of Biomedical Optics*, 24(1).
- Chang, C. I., 2003, Hyperspectral imaging: techniques for spectral detection and classification, *Springer Science & Business Media*, p.
- Edelman, G. J., Gaston, E., Van Leeuwen, T. G., Cullen, P. J., ve Aalders, M. C. G., 2012a, Hyperspectral imaging for non-contact analysis of forensic traces, *Forensic Science International*, 223(1-3), 28-39.
- Edelman, G., Van Leeuwen, T. G., ve Aalders, M. C., 2012b, Hyperspectral imaging for the age estimation of blood stains at the crime scene, *Forensic Science International*, 223(1-3), 72-77.
- Edelman, G. J., 2014, Spectral analysis of blood stains at the crime scene, PhD thesis, *Faculty of Medicine*, University of Amsterdam.
- Fischer, C., ve Kakoulli, I., 2006, Multispectral and hyperspectral imaging technologies in conservation: current research and potential applications, *Studies in Conservation*, 51, 3-16.
- Freeberg, J. A., Benedet, J. L., MacAulay, C., West, L. A., ve Follen, M., 2007, The performance of fluorescence and reflectance spectroscopy for the in vivo diagnosis of cervical neoplasia; point probe versus multispectral approaches, *Gynecologic Oncology*, 107(1), 248-255.
- Golbabaee, M., Arberet, S. ve Vandergheynst, P., 2013, Compressive source separation: Theory and methods for hyperspectral imaging, *IEEE Transactions on Image Processing*, 22(12), 5096-5110.
- Gowen, A. A., O'Donnell, C., Cullen, P. J., Downey, G., ve Frias, J. M., 2007, Hyperspectral imaging—an emerging process analytical tool for food quality and safety control, *Trends in Food Science & Technology*, 18(12), 590-598.

- Halicek, M., Lu, G., Little, J. V., Wang, X., Patel, M., Griffith, C. C., El-Deiry, M. W., Chen, A. Y., ve Fei, B., 2017, Semisupervised Hyperspectral Image Classification Based on Generative Adversarial Networks, *Journal of Biomedical Optics*, 22(6), 1-4.
- Halicek, M., Little, J. V., Wang, X., Chen, A. Y., ve Fei, B., 2019, Optical biopsy of head and neck cancer using hyperspectral imaging and convolutional neural networks, *Journal of Biomedical Optics*, 24(3).
- He, K., Zhang, X., Ren, S., ve Sun, J., 2014, Spatial pyramid pooling in deep convolutional networks for visual recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904-1916
- Hestir, E. L., Khanna, S., Andrew, M. E., Santos, M. J., Viers, J. H., Greenberg, J. A., Rajapakse, S. S. ve Ustin, S. L., 2008, Identification of invasive vegetation using hyperspectral remote sensing in the California Delta ecosystem, *Remote Sensing of Environment*, 112(11), 4034-4047.
- Hu, W., Huang, Y., Wei, L., Zhang, F., ve Li, H., 2015, Deep convolutional neural networks for hyperspectral image classification, *Journal of Sensors*, 2015.
- Joel, M. ve Tuan, V. D., 2003, Optical properties of tissue, *Biomedical Photonics Handbook*, Florida, 1-76.
- Kho, E., de Boer, L. L., Post, A. L., Van de Vijver, K. K., Józwiak, K., Sterenborg, H. J., ve Ruers, T. J., 2019, Imaging depth variations in hyperspectral imaging: Development of a method to detect tumor up to the required tumor-free margin width, *Journal of Biophotonics*, 12(11).
- Kingma, D. P., ve Ba, J., 2015, Adam: A method for stochastic optimization, *International Conference on Learning Representations (ICLR)*, 1-15.
- Kraemer, H. C., 1980, Extension of the kappa coefficient, *Biometrics*, 207-216.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, 1097-1105.
- Kumar, A., Kim, J., Lyndon, D., Fulham, M., ve Feng, D., 2016, An ensemble of fine-tuned convolutional neural networks for medical image classification, *IEEE Journal of Biomedical and Health Informatics*, 21(1), 31-40.
- Kurtuldu, H., Oktan, A. D., Candan, H., ve Cihangiroğlu, B. S., 2018, Red Blood Cell Analysis by Hyperspectral Imaging, *Natural and Applied Sciences Journal*, 1(2), 1-7.
- Lawn, J. E., Blencowe, H., Oza, S., You, D., Lee, A. C., Waiswa, P., Lalli, M., Bhutta, Z., Barros, A. J. D., Christian, P., ve Mathers, C., 2014, Every Newborn: progress, priorities, and potential beyond survival, *The Lancet*, 384(9938), 189-205.
- LeCun, Y., Bottou, L., Bengio, Y., ve Haffner, P., 1998, Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.

- LeCun, Y., Bengio, Y., ve Hinton, G., 2015, Deep learning, *Nature*, 521(7553), 436-444.
- Li, B., Beveridge, P., O'Hare, W. T., ve Islam, M., 2014, The application of visible wavelength reflectance hyperspectral imaging for the detection and identification of blood stains, *Science & Justice*, 54(6), 432-438.
- Li, Y., Xie, W., ve Li, H., 2017, Hyperspectral image reconstruction by deep convolutional neural network for classification, *Pattern Recognition*, 63, 371-383.
- Liang, H., 2012, Advances in multispectral and hyperspectral imaging for archaeology and art conservation, *Applied Physics A*, 106(2), 309-323.
- Lu, G., Halig, L. V., Wang, D., Qin, X., Chen, Z. G. ve Fei, B., 2014, Spectral-spatial classification for noninvasive cancer detection using hyperspectral imaging, *Journal of Biomedical Optics*, 19(10).
- Lu, G., ve Fei, B., 2014, Medical hyperspectral imaging: a review, *Journal of Biomedical Optics*, 19(1).
- Lu, G., ve Fei, B., 2019., Medical hyperspectral imaging: a review, *IEEE Journal Of Selected Topics in Applied Earth Observations and Remote Sensing*, 19(1), 1-23.
- Luo, Y., Zou, J., Yao, C., Zhao, X., Li, T., ve Bai, G., 2018, HSI-CNN: a novel convolution neural network for hyperspectral image, in *2018 International Conference on Audio, Language and Image Processing (ICALIP)*, 464-469.
- Ma, L., Lu, G., Wang, D., Wang, X., Chen, Z. G., Muller, S., Chen, A., ve Fei, B., 2017, March, Deep learning based classification for head and neck cancer detection with hyperspectral imaging in an animal model, In *Medical Imaging 2017: Biomedical Applications in Molecular, Structural, and Functional Imaging International Society for Optics and Photonics*, 10137.
- Manley, M., 2014, Near-infrared spectroscopy and hyperspectral imaging: non-destructive analysis of biological materials, *Chemical Society Reviews*, 43(24), 8200-8214.
- Manolakis, D. G., Lockwood, R. B., ve Cooley, T. W., 2016, Hyperspectral imaging remote sensing: physics, sensors, and algorithms, *Cambridge University Press*, p.
- Martin, M. E., Wabuyele, M. B., Chen, K., Kasili, P., Panjehpour, M., Phan, M., Overholt, B., Cunningham, G., Wilson, D., DeNovo, R. C., ve Vo-Dinh, T., 2006, Development of an advanced hyperspectral imaging (HSI) system with applications for cancer detection, *Annals of Biomedical Engineering*, 34(6), 1061-1068.
- Mei, S., Ji, J., Bi, Q., Hou, J., Du, Q., ve Li, W., 2016, July, Integrating spectral and spatial information into deep convolutional neural networks for hyperspectral classification, in *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 5067-5070.
- Patterson, M.S., Wilson, B.C. ve Wyman, D.R., 1991, The propagation of optical radiation in tissue I. Models of radiation transport and their application, *Lasers in Medical Science*, 155-168.

- Roblyer, D. M., Richards-Kortum, R. R., Sokolov, K. V., El-Naggar, A. K., Williams, M. D., Kurachi, C., ve Gillenwater, A., 2008, Multispectral optical imaging device for in vivo detection of oral neoplasia, *Journal of Biomedical Optics*, 13(2).
- Roggan, A., Dorschel, K., Minet, O., Wolff, D., ve Muller, G., 1995, The optical properties of biological tissue in the near infrared wavelength range, *Laser-Induced Interstitial Therapy*, 10-44.
- Roy, S. K., Krishna, G., Dubey, S. R., ve Chaudhuri, B. B., 2019, HybridSN: Exploring 3-d-2-d cnn feature hierarchy for hyperspectral image classification, *IEEE Geoscience and Remote Sensing Letters*, 1-5.
- Sakota, D., Nagaoka, E., ve Maruyama, O., 2015, August, Hyperspectral imaging of vascular anastomosis associated with blood flow and hemoglobin concentration, in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 4246-4249.
- Sasha, M., Jelena, M., ve Michael, F., 2011, Reflectance spectroscopy, *Handbook of Biomedical Optics*, CRC Press, p.
- Scherer, D., Muller, A. ve Behnke, S., 2010, Evaluation of pooling operations in convolutional architectures for object recognition, *International Conference on Artificial Neural Networks (ICANN)*, 92–101.
- Schuler, R. L., Kish, P. E., ve Plese, C. A., 2012, Preliminary observations on the ability of hyperspectral imaging to provide detection and visualization of bloodstain patterns on black fabrics, *Journal of Forensic Sciences*, 57(6), 1562-1569.
- Simonyan, K., ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *International Conference on Learning Representations (ICLR)*, 1-14.
- Smith, L. I., 2002, A tutorial on principal components analysis, *OUCS-2002-12*, New Zealand, 1-28.
- Sorg, B. S., Moeller, B. J., Donovan, O., Cao, Y., ve Dewhurst, M. W., 2005, Hyperspectral imaging of hemoglobin saturation in tumor microvasculature and tumor hypoxia development, *Journal of Biomedical Optics*, 10(4).
- SPECIM, 2020a, Hyperspectral Imaging, <https://www.specim.fi/library/what-is-hyperspectral-imaging/>: [Erişim Tarihi: 01.06.2020]
- SPECIM, 2020b, Specim IQ <https://www.specim.fi/downloads/iq/manual/software/iq/topics/specim-iq-introduction.html>: [Erişim Tarihi: 28.06.2020]
- Sun, Y., Xue, B., Zhang, M., ve Yen, G. G., 2019, Evolving deep convolutional neural networks for image classification, *IEEE Transactions on Evolutionary Computation*, 24(2), 394-407.
- Szegedy, C., Reed, S., Erhan, D., Anguelov, D., ve Ioffe, S., 2015, Scalable, high-quality object detection, 1-10.

- Tuan, V. D. ve Brian, M. C., 2003, Fluorescence spectroscopy for biomedical diagnostics, *Biomedical Photonics Handbook*, CRC Press, p.
- Wang, L. V. ve Wu, H. I., 2009, Biomedical Optics: Principles and Imaging, John Wiley and Sons Inc., p.
- Wanto, A., Windarto, A. P., Hartama, D., ve Parlina, I., 2017, Use of Binary Sigmoid Function And Linear Identity In Artificial Neural Networks For Forecasting Population Density, *International Journal Of Information System & Technology*, 1(1), 43-54.
- Welch, A. J., van Gemert, M. J., ve Star, W. M., 2010, Definitions and overview of tissue optics, *Optical-Thermal Response of Laser-Irradiated Tissue*, Springer, Dordrecht, 27-64.
- WHO, 2018, Preterm birth, <https://www.who.int/news-room/fact-sheets/detail/preterm-birth>: [Erişim Tarihi: 1 Haziran 2020]
- Wu, D., ve Sun, D. W., 2013, Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review—Part II: Applications, *Innovative Food Science & Emerging Technologies*, 19, 15-28.
- Yu, S., Jia, S., ve Xu, C., 2017, Convolutional neural networks for hyperspectral image classification, *Neurocomputing*, 219, 88-98.
- Yu, C., Zhao, M., Song, M., Wang, Y., Li, F., Han, R., ve Chang, C. I., 2019, Hyperspectral Image Classification Method Based on CNN Architecture Embedding With Hashing Semantic Feature, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(6), 1866-1881.
- Yue, Q., ve Ma, C., 2016, Deep learning for hyperspectral data classification through exponential momentum deep convolution neural networks, *Journal of Sensors*, 1-8.
- Zhang, Y., Chen, Y., Yu, Y., Xue, X., Tuchin, V. V., ve Zhu, D., 2013, Visible and near-infrared spectroscopy for distinguishing malignant tumor tissue from benign tumor and normal breast tissues in vitro, *Journal of Biomedical Optics*, 18(7).
- Zhang, Y. D., Dong, Z., Chen, X., Jia, W., Du, S., Muhammad, K., ve Wang, S. H., 2019, Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation, *Multimedia Tools and Applications*, 78(3), 3613-3632.
- 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.

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

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

YEREL ETİK KURULU KARARLARI

Toplantı Sayısı: 2019/09

Toplantı Tarihi : 04.09.2019

Karar Sayısı 2019/215 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 02.09.2019 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.





T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI
YEREL ETİK KURULU

Toplantı Sayısı: 2019/09

Toplantı Tarihi: 04.09.2019

Karar Sayısı 2019/215 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 Yenidoganlar İçin Ön-Teşhis Sisteminin Geliştirilmesi" başlıklı araştırmasının değerlendirilme talebi ile ilgili 02.09.2019 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç.Dr.Murat CEYLAN'ın "Hiperspektral Görüntüleme ve Yapay Zeka Kullanılarak Yenidoganlar İçin Ön-Teşhis Sisteminin Geliştirilmesi" adlı araştırmasının kabulüne oy birliği ile karar verildi.
Yardımcı Araştırmacılar: Hanifi SOYLU, Murat KONAK.

Prof.Dr.Hüsnü ALPTEKİN
Başkan

Prof.Dr.Ali ÜNLÜ
Başkan Yrd.

Prof.Dr.Mehmet ÖÇ
Üye

Prof.Dr.Kamil Hakan DOĞAN
Üye

(12.inci)
Prof.Dr.Yavuz SELVİ
Üye

(12.inci)
Prof.Dr.H.Haldun EMİROĞLU
Üye

Prof.Dr.A.Kasım BALTACI
Üye

Prof.Dr.Özcan KILIÇ
Üye

Doç.Dr.Oğuzhan ARUN
Üye

Doç.Dr.Kemal Macit HİSAR
Üye

Doç.Dr.Metin GÜNDÜZ
Üye

S.Selcen ÇELİK
Sekreteryaya



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mücahit CİHAN
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Konya / 01.06.1993
Telefon : 05365662062
Faks :
E-Posta : mcihan@ktun.edu.tr

EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	: Zeki Özdemir Anadolu Lisesi,	Meram,	Konya	2011
Üniversite	: Mevlâna Üniversitesi,	Selçuklu,	Konya	2015
Yüksek Lisans	: Konya Teknik Üniversitesi,	Selçuklu,	Konya	Devam ediyor

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2016	Hedefsan Elektronik Asansör Turizm Sanayi ve Ticaret Limited	Ar-ge Şefi
2016-2018	Başakkent Yapı Denetim Limited Şirketi	Elektrik Kontrol Mühendisi
2018-2019	İnönü Üniversitesi Mühendislik Fakültesi	Araştırma Görevlisi
2019-Devam	Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi	Araştırma Görevlisi

UZMANLIK ALANI

Hiperspektral görüntüleme, görüntü işleme, derin öğrenme

YABANCI DİLLER

İngilizce (YÖKDİL=88,75)

YAYINLAR

- Mücahit Cihan, Murat Ceylan, Hiperspektral Görüntüleme Kullanarak Hasta ve Sağlıklı Yenidoğanların Spektral Ayrımı (Ön Çalışma), SİU-2020-28. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.
- Mücahit Cihan, Murat Ceylan, Ahmet Haydar Örnek, Spectral-Spatial Classification for Noninvasive Health Status Detection of Neonates using Hyperspectral Imaging and Deep Convolutional Neural Networks, Medical Physics. (Hakem değerlendirmesinde)
- Mücahit Cihan, Murat Köseoğlu, Monitoring System for Solar Panel using Xbee ZB Module based Wireless Sensor Networks, International Journal of Engineering Research & Technology, May-2019, Vol. 8 Issue 05, pp. 290-295, ISSN: 2278-0181.