



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**Prematüre Yenidoğanlarda Vaka Önleme ve
Yönetimi İçin Dijital İkiz**

Mahmut ÇEVİK

Yüksek Lisans TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Nisan-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mahmut ÇEVİK tarafından hazırlanan “Prematüre Yenidoğanlarda Vaka Önleme ve Yönetimi İçin Dijital İkiz” adlı tez çalışması 07/04/2025 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

İmza

Başkan

Doç. Dr. Kemal TÛTÛNCÛ
Selçuk Üniversitesi

.....

Danışman

Prof. Dr. Murat CEYLAN
Konya Teknik Üniversitesi

.....

Üye

Dr. Öğr. Üyesi Ahmet SOLAK
Konya Teknik Üniversitesi

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

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

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Mahmut ÇEVİK

Tarih: 07.04.2025

ÖZET

YÜKSEK LİSANS TEZİ

PREMATÜRE YENİDOĞANLARDA VAKA ÖNLEME VE YÖNETİMİ İÇİN DİJİTAL İKİZ

Mahmut ÇEVİK

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

Danışman: Prof. Dr. Murat CEYLAN

2025, 74 Sayfa

Jüri

**Doç. Dr. Kemal TÜTÜNCÜ
Prof. Dr. Murat CEYLAN
Dr. Öğr. Üyesi Ahmet SOLAK**

Yeni doğan prematürelere anne karnında gelişimini tamamlamadan dünyaya gelmektedir. Bu bebekler gelişimlerinin tamamlanması ve süreçlerinin izlenmesini Yenidoğan Yoğun Bakım Ünitesinde (YYBÜ) geçirmektedir. Bu süre içerisinde hastalıklara çok daha yatkın olan prematürelere için medikal parametreler ve laboratuvar bulguları sürekli olarak izlenmekte ve kayıt edilmektedir. Bazı vakalar ortaya çıktıktan birkaç saat sonrasında bebeğin ölümüyle sonuçlanabilecek kadar hızlı ilerlemektedir. Bu sebeple vaka ortaya çıkmadan önce tespit etmek ve vaka yönetimi için stratejiler geliştirilmesini sağlamak önem arz etmektedir. Dijital ikizler fiziksel bir nesnenin veya sürecin sensör değerlerinin dijital ortama aktarılmasıyla sanal bir temsiline oluşturulmasıdır. Dijital ikizler ile yapay senaryolar üretmek gerçek hayat simülasyonları oluşturmak da mümkündür. Yapay zeka dijital ikiz modellerine ileriye yönelik tahminler ve çıkarımlar yapabildiğini sağlayan özellikler kazandırmaktadır. Bu tez çalışmasında Selçuk Üniversitesi YYBÜ'de kalan 47 prematüre bebekten elde edilen laboratuvar bulguları, medikal parametreler ve hiperspektral görüntüler ile çalışılmıştır. Alınan tüm görüntü ve parametreler zaman etiketli olarak kayıt edilmiştir. Bu veriler ile bebeklerin mevcut ve geçmiş medikal parametrelerine bakarak ileriye yönelik CRP, bilirubin ve hemoglobin değerlerini tahmin eden zaman seri analizleri ve zaman etiketli hiperspektral görüntüler ile hastalık tahmini yapan yapay zeka modelleri geliştirilmiştir. Laboratuvar bulgularının ileriye yönelik tahmini için kullanılan zaman seri analizi modellerinin geliştirilmesinde LSTM, Xgboost ve LSTM-Çok Başlı Dikkat Mekanizması (ÇBD) yöntemlerinden faydalanılmıştır. LSTM sinir ağı ile geliştirilen zaman seri analizi modelinde %29.09 CRP, %36.36 bilirubin ve %46.63 R-Kare doğruluğuna erişilmiştir. Xgboost modellerinde bilirubin için 9.76, hemoglobin için 16.8 Ortalama Karesel Hata (OKH) değerine ulaşılmıştır. LSTM-ÇBD modelinde CRP, Bilirubin ve Hemoglobin değerleri için R-Kare doğruluğu sırasıyla %91.78, %66.76 ve %77.62 değerlerine ulaşılmıştır. Hiperspektral Görü Dönüştürücü (HSViT) ile zaman etiketli hiperspektral görüntülerde hastalık tahmini yapan yapay zeka modeli geliştirilmiştir. Hiperküp veri kümesine 5, 50, 100 olmak üzere farklı seviyelerde Temel Bileşen Analizi (TBA) uygulanmış ve modeller bu veri setleri ile eğitilmiştir. En iyi model performansını %98.92 doğruluk, %96.48 kesinlik, %99.50 duyarlılık ve %97.95 F1-Skor ile 50 temel bileşene indirgenen veri seti ile eğitilen model göstermiştir. Bu tez çalışması ile yenidoğan prematürelere dijital ikiz ile vaka önleme ve takibi için yapay zeka modelleri ile ileriye yönelik tahminlerin yapılabileceği ve bu tahminlerin hastalık teşhisinde bir erken uyarı sistemi olarak kullanılabileceği kanıtlanmıştır.

Anahtar Kelimeler: Dijital İkiz, Hiperspektral Görüntüleme, Görü Dönüştürücü, Çok-Başlı Dikkat, LSTM, XGboost, Yenidoğan Laboratuvar Bulguları, Medikal Parametre, Zaman Seri Analizi

ABSTRACT

MASTER THESIS

DIGITAL TWIN FOR CASE PREVENTION AND MANAGEMENT IN PREMATURE NEONATES

Mahmut ÇEVİK

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

Advisor: Prof. Dr. Murat CEYLAN

2025, 74 Pages

Jury

Assoc. Prof. Dr. Kemal TÜTÜNCÜ

Prof. Dr. Murat CEYLAN

Asst. Prof. Dr. Ahmet SOLAK

Premature newborns are infants who are born before fully completing their developmental processes in the womb. These infants spend a critical period in the Neonatal Intensive Care Unit (NICU), where their growth and development are closely monitored. During this time, premature infants are highly susceptible to various medical conditions, making it essential to continuously track and record their medical parameters and laboratory findings. Some medical conditions can progress so rapidly that they might lead to the infant's death within hours after the onset. Therefore, early detection before the occurrence of such cases and developing strategies for effective case management are critically important. Digital twins represent physical objects or processes by transferring sensor data into a digital environment, creating virtual representations. Through digital twins, it is also possible to generate artificial scenarios to simulate real-life conditions. Artificial intelligence (AI) enhances digital twin models by enabling forward-looking predictions and inferences. In this thesis, laboratory findings, medical parameters, and hyperspectral images from 47 premature infants treated at Selçuk University's NICU were analyzed. All collected data, including images and parameters, were recorded with timestamps. Based on this data, AI models were developed for forecasting future CRP, bilirubin, and hemoglobin values through time series analyses using current and past medical parameters, as well as disease prediction using timestamped hyperspectral images. Long Short-Term Memory (LSTM), XGBoost, and LSTM-Multi-Head Attention (MHA) mechanisms were utilized to develop time series analysis models for predicting future laboratory findings. The LSTM-based time series analysis model achieved R-squared accuracies of 29.09% for CRP, 36.36% for bilirubin, and 46.63% for hemoglobin predictions. The XGBoost model obtained Mean Squared Errors (MSE) of 9.76 for bilirubin and 16.8 for hemoglobin predictions. Using the LSTM-MHA model, R-squared accuracies of 91.78%, 66.76%, and 77.62% were achieved for CRP, bilirubin, and hemoglobin, respectively. Additionally, a Hyperspectral Vision Transformer (HSViT) model was developed for disease prediction using timestamped hyperspectral imagery. Principal Component Analysis (PCA) was applied to the hypercube dataset at different levels 5, 50, and 100 components and models were trained on these reduced datasets. The best-performing model was trained on a dataset reduced to 50 principal components, achieving an accuracy of 98.92%, precision of 96.48%, sensitivity of 99.50%, and an F1-score of 97.95%. This thesis demonstrates that artificial intelligence models integrated with digital twins can effectively predict future medical parameters and diseases in premature newborns, providing a promising early-warning system for disease prevention and management.

Keywords: Digital Twin, Hyperspectral Imaging, Vision Transformer, Multi-Head Attention, LSTM, XGBoost, Neonatal Laboratory Results, Vital Signs, Time Series Analysis

ÖNSÖZ

Yüksek lisans tez aşaması süreci boyunca tecrübelerini, bilgisini ve desteğini esirgemeyen kıymetli danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Öğretim Üyesi Sayın Prof. Dr. Murat CEYLAN'a, başta beraber çalışma fırsatı bulduğum Sayın Dr. Öğr. Üyesi Mücahit CİHAN olmak üzere değerli bölümümüz öğretim üyelerine teşekkürlerimi sunarım. Ayrıca yenidoğan bebeklerin medikal parametreleri ve laboratuvar bulgularının elde edilmesinde yardımcı olan Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesi öğretim üyeleri Prof. Dr. Hanifi SOYLU ve Doç. Dr. Murat KONAK'a teşekkür ederim. Son olarak tüm tez sürecinde manevi olarak her zaman yanımda olan aileme ve sevgili arkadaşım Beyzanur Yüksel'e teşekkür ederim.

Mahmut Çevik
KONYA-2025

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. Yenidoğanlarda Medikal Belirteçler..... | 7 |
| 3.1.1. CRP..... | 7 |
| 3.1.2. Hemoglobın | 8 |
| 3.1.3. Bilirubin..... | 8 |
| 3.1.4. Ateş..... | 9 |
| 3.1.5. Nabız..... | 9 |
| 3.1.6. Oksijen Satürasyonu | 10 |
| 3.1.7. Solunum Sayısı | 11 |
| 3.2. Hiperspektral Görüntüleme..... | 12 |
| 3.3. Dijital İkiz..... | 15 |
| 3.3.1. Dijital İkiz Ortamı..... | 15 |
| 3.3.2. Dijital İkiz ve Yapay Zekâ..... | 16 |
| 3.4. Zaman Seri Analizi | 17 |
| 3.5. Xgboost..... | 18 |
| 3.6. LSTM..... | 21 |
| 3.7. Çoklu-Başlı Dikkat Mekanizması..... | 23 |
| 3.8. Görü Dönüştürücü Ağlar | 25 |
| 3.8.1. Görüntü Yamaları Oluşturma | 26 |
| 3.8.2. Yama Gömme İşlemi..... | 26 |
| 3.9. Temel Bileşen Analizi | 27 |
| 3.10. Savitzky-Golay Yumuşatma Filtresi..... | 29 |
| 3.11. Aktivasyon Fonksiyonları..... | 30 |
| 3.11.1. Sigmoid..... | 30 |
| 3.11.2. Tanh (Hiperbolik Tanjant)..... | 31 |
| 3.11.3. ReLu..... | 31 |
| 3.12. Değerlendirme Metrikleri | 33 |
| 3.12.1. Karmaşıklık Matrisi | 33 |
| 3.12.2. Ortalama Karesel Hata..... | 35 |
| 3.12.3. Ortalama Mutlak Hata | 35 |
| 3.12.4. R-Kare Skoru | 36 |
| 3.13. K-Kat Çapraz Doğrulama | 37 |
| 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA..... | 39 |

| | | |
|-----------------------|---|-----------|
| 4.1. | Yenidoğan Medikal Belirteci Verilerinin Elde Edilmesi..... | 40 |
| 4.2. | Yenidoğan Laboratuvar Bulgularının Zaman Seri Analizi Modelleri ile Tahmini..... | 41 |
| 4.2.1. | LSTM Tabanlı Modeller ile Zaman Seri Analizi..... | 41 |
| 4.2.2. | XgBoost ile Zaman Seri Analizi Modeli | 47 |
| 4.2.3. | LSTM ve Dikkat Mekanizması Ağları ile Zaman Seri Analizi | 51 |
| 4.3. | Zaman Seri Analizi Yöntemleri Çıktılarının Karşılaştırması | 55 |
| 4.4. | Hiperspektral Verilerde Zaman Seri Analizi Verilerinin Elde Edilmesi | 56 |
| 4.5. | Hiperspektral Veriler ile İleriye Yönelik Hastalık Tahmini Modelleri | 57 |
| 4.5.1. | Görü Dönüştürücü ile TBA Uygulanmamış Hiperspektral Verilerde Hastalık Tahmini..... | 59 |
| 4.5.2. | Görü Dönüştürücü ile TBA Uygulanmış Hiperspektral Verilerde Hastalık Tahmini..... | 62 |
| 4.6. | Hiperspektral Verilerde Hastalık Tahmini Modelleri Karşılaştırma | 62 |
| 5. | SONUÇLAR VE ÖNERİLER..... | 64 |
| 5.1 | Sonuçlar | 64 |
| 5.2 | Öneriler | 66 |
| KAYNAKLAR..... | | 67 |
| EKLER..... | | 72 |

SİMGELER VE KISALTMALAR

Simgeler

- y_i : Gerçek değerler
- \hat{y}_i : Tahmin edilen değerler
- $\mathcal{L}(\emptyset)$: XGBoost'ta regülarizasyon objesi
- Ω : Ek düzenlilik terimi
- h_m : Tahmin modeli
- f_k : Tahminleyici modeli
- η : Öğrenme oranı
- σ : Sigmoid aktivasyon fonksiyonu
- $\tanh(x)$: Hiperbolik tanjant fonksiyonu
- X_t : RNN/LSTM'de t anındaki giriş
- W_h : Gizli katmanın ağırlığı
- W_i : Giriş katmanının ağırlığı
- h_t : t anındaki çıkış
- C_t : LSTM hücresi geçmiş bilgi yolu girişi
- C_{t-1} : LSTM hücresi geçmiş bilgi yolu çıkışı
- W_f : LSTM'deki unutma kapısının ağırlık matrisi
- b_f : LSTM'deki unutma kapısının bias değeri
- $f(x)$: Aktivasyon fonksiyonları için genel matematiksel gösterim
- $\max(0,x)$: ReLU aktivasyon fonksiyonu

Kısaltmalar

| | |
|-------|--|
| AUC | : Alıcı Çalışma Karakteristiği Altındaki Alan |
| AUROC | : Alıcı Çalışma Karakteristiği Altındaki Alan (ROC Eğrisi) |
| BKND | : Bilirubin Kaynaklı Nörolojik Disfonksiyon |
| BPD | : Bronkopulmoner Displazi |
| CI | : Göğüs Empedansı |
| CRP | : C-reaktif proteini |
| ÇBD | : Çoklu-Başlı Dikkat |
| DDI | :Doğal Dil İşleme |
| DSÖ | : Dünya Sağlık Örgütü |
| EKG | : Elektrokardiyogram |
| GBS | : Geç Başlayan Sepsis |
| Hb | : Hemoglobin |
| IKK | : Intrakranial kanama |
| IoT | : Nesnelerin İnterneti |
| IVH | : İntraventriküler Kanama |
| KAK | : Kalp Atım Karakteristiği |
| KKKH | : Kritik Konjenital Kalp Hastalığı |
| KOKH | : Kök Ortalama Karesel Hata |
| KSA | : Konvülsiyonel Sinir Ağı |
| LSTM | : Uzun-Kısa Süreli Bellek |
| LWIR | : Uzak Kızılötesi |
| MWIR | : Orta Kızılötesi |
| NASA | : National Aeronautics and Space Administration (Ulusal Havacılık ve Uzay Dairesi) |
| NEC | : Nekrotizan Enterokolit |
| NIR | : Yakın Kızılötesi |
| OBHO | : Otoregresif Bütünleşik Hareketli Ortalama |
| OHO | : Otoregresif Hareketli Ortalama |
| OKH | : Ortalama Karesel Hata |
| OMH | : Ortalama Mutlak Hata |
| PLS | : Perinatal Yaşam Destek |
| RDS | : Respiratuvar Distres Sendromu |

| | |
|---------|---|
| RNN | : Özyinelemeli Sinir Ağları |
| SPO2 | : Oksijen Satürasyonu |
| TBA | : Temel Bileşen Analizi |
| TÜBİTAK | : Türkiye Bilimsel ve Teknolojik Araştırma Kurumu |
| UNICEF | : Birleşmiş Milletler Çocuklara Yardım Fonu |
| PCA | : Temel Bileşen Analizi |
| VHT | : Sanal İnsan İkizi (Virtual Human Twin) |
| VIS | : Görünür ışık |
| Xgboost | : Aşırı Gradyan Güçlendirme |
| YYBÜ | : Yenidoğan Yoğun Bakım Ünitesi |
| ZSA | : Zaman Seri Analizi |
| HSViT | :Hiperspektral Görü Dönüştürücü |

1. GİRİŞ

Dünya Sağlık Örgütü (DSÖ) ve Birleşmiş Milletler Çocuklara Yardım Fonu (UNICEF)'in yayınladığı verilere göre dünyada 2010-2020 yılları arasındaki 10 yılda yaklaşık 152 milyon erken (gebeliğin 37. haftasından önce) doğum gerçekleşmiştir (WHO ve UNICEF, 2023). Erken doğum 5 yaşından küçük çocuk ölümlerinin en büyük sebeplerinden biri olarak kaydedilmektedir. Yaklaşık 5 yaşından küçük çocuk ölümlerinin 5'te 1'i prematüre bebeklerdir. 2010-2020 yılları arasındaki erken doğum oranlarındaki değişim %0.14 olarak görülmektedir (Ohuma ve ark., 2023). Bu oran erken doğum oranlarının azalma trendinde olmadığını göstermektedir. Erken doğum sayıları ve buna bağlı ölüm sayılarının yüksekliği incelendiğinde prematüre bebeklerde vaka önleme sistemleri ve erken teşhis olanaklarının önemi görülmektedir.

Dijital ikiz nesnelerin, sistemlerin veya süreçlerin gerçek dünya verileri ile anlık olarak incelenmesini sağlayan dijital eşliklerinin yaratılmasıdır. Dijital ikiz kavramı ilk olarak 2002 yılında Grieves tarafından Michigan Üniversitesi'nde yapılan bir sunumda ortaya atılmıştır (Gravies ve Vickers, 2016). NASA'nın dijital ikizi teknoloji yol haritalarına dahil etmesiyle beraber kavram popülerlik kazanmıştır (Piascik ve ark., 2010). Dijital ikizin erken bir yaklaşımı olarak kabul edilen uygulamada NASA Apollo 13 uzay aracında yaşanan patlamanın sebebi yer ekiplerinin uzay aracından anlık gelen sensör verilerini analiz etmesi ile hızla çözümlenmiştir (Uri, 2020). Zhang ve ark., (2022), katı yakıtlı roket motorlarında motorun sıcaklık, nem gibi sensör verilerinin incelenerek motorların yıpranma tahminlerinin ve bakım stratejilerinin gerçekleştirilebilirliğini göstermişlerdir. Dijital ikiz sadece fiziksel nesnelerin değil iş süreçlerinin yönetilmesinde verimliliğin artırılmasında gerçek hayat simülasyonları ve optimizasyonları için de kullanılmaktadır. Zhang ve ark., (2023), yaptıkları çalışmada bir kâğıt üretiminde enerji kullanımı ve üretim verimliliğini artırmak için fabrika kâğıt yapımı işlemlerinin dijital ikizlerini oluşturmuşlardır. Enerji, inşaat, üretim gibi birçok alanda dijital ikiz üzerine çalışmalar gerçekleştirilmiştir (Borowski, 2021; Tuhaise ve ark., 2023; Alexopoulos ve ark., 2020).

Sağlık alanında kişiselleştirilmiş tıp, ilaç, hastane hasta yönetimi optimizasyonları gibi birçok alanda dijital ikizden faydalanılmaktadır (Sun ve ark., 2023). Avrupa Komisyonu, 2023'de yayınlanan "Avrupa Sanal İnsan İkizleri Girişimi" çerçevesi ile Avrupa'da geliştirilen insan dijital ikizi projelerini geliştirmek ve birleştirmek için desteklerini açıklamıştır (Avrupa Komisyonu, 2023). Ayrıca komisyonunun yayınladığı

Sanal İnsan İkizi (VHT) manifestosu ile insan dijital ikizi teknolojilerinin iyileştirilmesi, kişiselleştirilmiş tıp ve ilaç sektörünün geliştirilmesi ile sağlık kaynaklarına erişimi adil ve evrensel hale getirmeyi hedefledikleri vurgulanmıştır. İnsan dijital ikizi kişilerin sadece hastalık süreçlerinin izlenmesi ve tedavileri için kullanılmamaktadır. Giyilebilir tıbbi cihazların gelişmesi ile kişilerin fiziksel durumları ile ilgili düzenli veri elde edilebilmeye başlanmıştır. Liu ve ark., (2019), yaptıkları çalışmada yaşlılar için giyilebilir tıbbi cihazlar ile hasta takibi ve teşhisi için bulut tabanlı bir çerçeve önermişlerdir. Elayan ve ark., (2021), hastaların kalp ritmi sorunlarının teşhisinde elektrokardiyogram (EKG) veri seti ile eğitilen beş farklı makine öğrenmesi algoritmasını karşılaştırarak bir yapay zekâ modeli geliştirmiş ve bağlama duyarlı bir dijital ikiz sistemi tasarlamışlardır.

Fiziksel bir nesne veya sistemin yaşam döngüsünün dijital bir ortama aktarılması ve sanal bir tasvirinin oluşturulması için birçok farklı teknolojinin beraber çalışması gerekmektedir. Nesnenin fiziksel reaksiyonlarının elde edilmesi için sensör verilerinden faydalanılmaktadır. Sensör verilerinin toplanması, iletilmesi için Nesnelerin İnterneti (IoT) teknolojilerinden (Minerva ve ark., 2020), verilerin depolanması ve yönetilmesi için bulut teknolojilerinden yararlanılmaktadır (Liu ve ark., 2019). Toplanan verilerin anlamlandırılması ve ileriye yönelik çıktılarının tahmin edilmesi için yapay zekâ yöntemleri kullanılmaktadır (Lv ve Xie, 2022). Scheuermann ve ark. (2020), psikolojik olarak zorlu koşullarda görev yapan personelin sensör verilerinden yararlanarak dijital ikizlerini oluşturmuş ve bu dijital ikizler aracılığıyla “Random Forest Regressor” modeli kullanarak potansiyel stres durumlarını analiz etmişlerdir. Alexopoulos ve ark., (2019) yaptıkları çalışmada endüstriyel üretim süreçlerinde yapay zeka modellerinin geliştirilmesinde zaman ve maliyet tasarrufu sağlamak için dijital ikiz ile yapay zeka modeli için sentetik veriler üreten bir çerçeve yayınlamışlardır. Bu çalışma ile birlikte dijital ikiz ve yapay zekanın tek yönlüden ziyade çift yönlü fayda sağladıkları gösterilmiştir.

Zaman seri analizi yöntemleri, zaman etiketleri ile kaydedilen durumların davranışlarını inceleyerek ileriye yönelik tahminleri gerçekleştirilebilmektedir. Bu ileriye yönelik tahminler dijital ikizin gerçek hayat simülasyonu mantığı ile örtüşmektedir. Bu sebeple dijital ikiz yaklaşımlarında zaman seri analizi yöntemlerine sıklıkla başvurulmaktadır. Zhang ve ark., (2022), yaptıkları çalışmada makine öğrenmesine dayalı zaman serisi analizi yöntemlerinden olan LSTM ağları kullanılarak hamile kadınların gebelik boyunca sürekli sağlık verileri takip edilmiş ve erken doğum riskleri

tahmin ettirmişlerdir. Bu çalışma erken doğum tahminine yönelik zamansal modelleme ve dijital ikiz yaklaşımlarının uygulanabilirliğini göstermesi açısından değerlidir.

Dijital ikiz yaklaşımlarının gelişimi incelendiğinde yenidoğan prematüre bebeklerde oluşabilecek hastalıkların erken teşhisinde ve vaka yönetiminde umut verici bir teknoloji olduğu söylenebilmektedir. Ancak yenidoğan prematürelerde düzenli takip edilen medikal parametreler, laboratuvar bulguları ve hiperspektral görüntüleme ile yapılan bir dijital ikiz çalışmasına rastlanmamıştır. Bu tez kapsamında yenidoğan prematüre bebeklerin yenidoğan bakım ünitesinde kaldıkları süre boyunca elde edilen medikal parametreleri, laboratuvar bulguları ve hiperspektral görüntüleri kaydedilmiştir. Elde edilen veri setleri ile bebeklerin ileriye yönelik laboratuvar bulgularının tahmin edilmesi için yapay zekâ tabanlı zaman seri analizi modelleri ve hiperspektral görüntüler ile ileriye yönelik hastalık sınıflandırması için görü dönüştürücü tabanlı modeller geliştirilmiştir. Yenidoğan prematüre bebeklere ait medikal parametreler ve hiperspektral görüntüler Selçuk Üniversitesi Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesinde (YYBÜ) bulunan hasta ve sağlıklı yenidoğan bebeklerden elde edilmiştir. Yenidoğan prematüre bebeklerin YYBÜ’de buldukları süre boyunca elde edilen veriler zaman etiketli olarak kaydedilmiştir.

2. KAYNAK ARAŞTIRMASI

Örnek ve arkadaşları (2019) yaptıkları çalışmada 19 sağlıklı 19 sağlıksız 38 yenidoğandan elde edilen 380 termal görüntüden olan veri seti ile eğitilmiş sağlıklı-sağlıksız ikili sınıflandırma yapan Konvolüsyonel Sinir Ağı (KSA) modeli önermişlerdir. Elde edilen 380 termal görüntü veri artırma yöntemleri ile 30,400'e çoğaltılmıştır. Eğitilen KSA modeli %99.73 duyarlılık, %99.43 özgüllük, %99.58 doğruluk ve 0.996 AUC değerlerine ulaşmıştır.

Kumar ve arkadaşları (2020), yenidoğan hastalıklarının tespitinde yapay zeka yaklaşımları kullanımının önemini vurgulamıştır. Yenidoğan prematürelere hayati bulgularının erken aşama hastalık teşhisinde karar destek sistemi olarak kullanılabileceği vurgulanmıştır. Kalp atım hızı ve değişkenliği, oksijen saturasyonu, solunum hızı ve kan basıncı gibi hayati bulguların yapay zeka modelleri ile analizinin erken aşama sepsis, nekrotizan enterokolit (NEC), bronkopulmoner displazi (BPD) ve intraventriküler kanama (IVH) gibi prematüre hastalıklarının teşhisinde kullanım potansiyeli ele alınmıştır.

Cabrera-Quiros ve arkadaşları (2021) yaptıkları çalışmada geç başlayan sepsisin tahmininde prematürelere solunum, hareket özellikleri, kalp hızı değişkenlikleri ve Elektrokardiyogram (EKG), göğüs empedansı (CI) verileri kullanarak makine öğrenmesi modelleri eğitmişlerdir. Toplanan veriler farklı kombinasyonlarla model eğitiminde kullanılmıştır. Eğitilen lojistik regresyon, naive bayes ve en yakın ortalama sınıflandırıcı modellerinden en yüksek doğruluk oranlarını lojistik regresyon modeli göstermiştir. Lojistik regresyon modeli ile sepsis ortaya çıkmadan yaklaşık 3 saat önce 0.79 ± 0.12 doğruluk oranı ile tahmin edebilmiştir.

Cihan ve arkadaşları (2022) yaptıkları çalışmada YYBÜ'de kalan 19 yenidoğan bebekten elde edilen hiperspektral görüntü küpleri ile sağlıklı-sağlıksız sınıflandırması yapan 3D-CNN modeli eğitmişlerdir. 16 sağlıksız bebekten 16, 3 sağlıklı bebekten 16 toplam 32 adet hiperspektral görüntü küpü elde edilmiştir. Bu veriler uzamsal boyutu temel bileşen analizi (TBA) ile azaltılmış ve ilgi alanı çıkarma tekniği ile 5760 25x25x51 boyutlarında hiperküpler haline getirilmiştir. Geliştirilen 3D-CNN sınıflandırma modeli %98 doğruluk, %97.22 duyarlılık ve %98.78 özgüllük değeri elde etmiştir.

Van Willigen ve arkadaşlarının (2022), yaptığı çalışma incelendiğinde yenidoğan prematüre bebekler için geliştirilecek dijital ikizde mevcutta kullanılan fetal dolaşım sistemi matematiksel modellerinin yeterlilikleri değerlendirilmiştir. Çalışmada ekstrem

prematüre bebeklerin gelişiminde anne karnını simüle eden içi sıvı dolu inkübatör olan perinatal yaşam destek (PLS) sisteminin geliştirilmesi bağlamında dijital ikizin nasıl bir rol oynayabileceğini detaylandırılmaktadır. Mevcutta kullanılan fetal dolaşım matematiksel modellerinin hiçbirinin tek başına bir dijital ikizin tüm gereksinimlerini karşılayamadığı sonucuna varılmıştır. Ancak birçok farklı yaklaşımın birlikte modellenmesi ile fetal büyüme ve oksijen taşınımı gibi süreçleri simüle edebilen kapsamlı bir dijital ikiz yaratılabileceği vurgulanmıştır. Geliştirilen dijital ikiz ile PLS sistemi çıktılarının bebeğin fetal büyüme ve hastalık tespitinde sağlık çalışanlarına bir karar destek sistemi ve simülasyon ortamı oluşturma potansiyeline sahiptir.

Sizemore ve arkadaşları (2024), yeni doğan prematüre bebeklerin gaita örneklerinden alınan mikrobiyota örneklerinde 16s rRNA profillerinin karakteristiğini tahmin eden bir dijital ikiz geliştirmişlerdir. 16S rRNA'nın dizisi, bakterilerin tanımlanmasında ve sınıflandırılmasında yaygın olarak kullanılmaktadır. Çalışmada 16S ribozomal RNA dizilimi ile 88 prematüre bebeğin 398 dışkı örneğinden elde edilen 91 mikrobiyal sınıfa ait veriler incelenmiştir. Bu çalışma sonucunda bebeklerin belirli bir süre dışkı örnekleri alındıktan sonra takip edilen mikrobiyal sınıfların ileri tarihli olabilecek değerlerinin tahminleri yapılabilmektedir. Nörogelişimsel sorunları olan bebeklerin tahmini için AUC oranları %75,7'ye kadar ulaşmıştır. Suboptimal gelişim riski taşıyan bebeklerin yaklaşık %42,9'u için erken mikrobiyal müdahaleler önerilmiştir. Bu tahminler sonucunda bebeklerin sindirim rahatsızlıkları gibi birçok rahatsızlıkları bu dijital ikiz ile tespit edilebilmektedir. Bu ileri yönlü üretken model tahminleri ile bakteriyel karakteristikler erken aşamalarda gözlemlenerek ileriye dönük izleme ve tedavi prosedürlerinin geliştirilebileceği kanıtlanmıştır.

Li ve Arkadaşları (2024), yaptıkları çalışmada 459 prematüre bebekten elde edilen doğum öncesi faktörler ve doğum sonrası medikal parametre sağlık kayıtları ile bebeklerin yaşam oranlarını tahmin eden makine öğrenmesi modelleri eğitmişlerdir. Çalışmanın amacı prematüre bebek yaşam oranlarını mevcutta kullanılan risk değerlendirme metriklerine göre daha yüksek oranda tahmin ederek sağlık çalışanları için klinik karar destek sistemi geliştirmektir. Aynı veri seti ile eğitilen farklı makine öğrenmesi modelleri içerisinde en iyi performansı %91 Alıcı Çalışma Karakteristiğinin Altında Kalan Alan (AUROC) değeri ile rastgele orman modeli göstermiştir. Rastgele orman modeli daha önce kullanılan risk skorlarına kıyasla (SNAPPE-II vs.) daha yüksek doğruluk değeri elde etmiştir.

Yapılan kaynak arařtırmasında da görüldüğü üzere yenidođan prematürelere farklı veriler ile hastalık tespiti yapan birçok çalıřma gerçekleştirilmiřtir. Yapılan çalıřmalar prematürelere gerçekteřen durumları veya verilerinin analizi ile çıktı üretmektedir. İleriye yönelik laboratuvar bulguları ve hastalık tahmini gerçekteřiren ve hastalık gerçekteřmeden prematürenin durumunun ne olacađını gösteren bir dijital ikiz yaklařımı görülmemektedir. Bu yönüyle gerçekteřtirilen tez çalıřması yenidođan prematürelere vaka önleme ve yönetimi için dijital ikiz yaklařımı ile bir ilk niteliđi tařımaktadır.



3. MATERYAL VE YÖNTEM

3.1. Yenidoğanlarda Medikal Belirteçler

Prematüre doğum bebeğın gebeliğın 37. haftasından daha önce doğması olarak tanımlanmaktadır. 34-36 haftalar arasındaki doğumlar geç preterm, 32-34 haftalar arasındaki doğumlar orta preterm ve 32. haftadan daha erken olan doğumlar erken preterm olarak isimlendirilmektedir. Prematüre doğumların büyük çoğunluğu geç preterm döneminde gerçekleşmektedir. Prematüre bebeklerde fizyolojik ve nörobilişsel gelişimler anne karnında tamamlanamamaktadır. Bu sebeple prematüreler gelişimlerini tamamlama süreçlerinde Yenidoğan Yoğun Bakım Ünitesinde (YYBÜ) kalmaktadır. YYBÜ’de kalan pretermilerin takibi ve gelişiminin izlenmesi için hayati parametreleri ve laboratuvar bulguları takip edilmektedir. Hayati parametre zamansal eğilimleri belirli hastalıkların ortaya çıkmasından önce tespit edilebilir paternler üretebilmektedir. Fairchild ve arkadaşları (2013) yaptıkları çalışmada prematüre bebeklerin Geç Başlayan Sepsis (GBS) teşhisinde Kalp Atım Karakteristiğı (KAK) monitörizasyonunu önermişlerdir. Araştırma sonucunda elde edilen bulgularda GBS geçiren hastaların teşhisten önceki haftasında KAK indeksinde belirgin artışlar tespit edilmiştir. Ayrıca yapılan çalışmada elde edilen sonuçların sağlık personellerine gösterildiğı vakalarda sepsise bağılı 30 günlük mortalite oranlarının %11,8, gösterilmediğı vakalarda ise mortalite oranının %19,6 olduğı ölçülmüştür. Prematüre bebeklerde hayati parametreler ve laboratuvar bulguları karakteristikleri bebeklerin hastalıklarının erken teşhisinde ve sağlık çalışanları için karar destek sistemi oluşturmada önemli olduğunu göstermektedir.

3.1.1. CRP

C-reaktif protein (CRP) yenidoğanlarda pratikte en sık kullanılan enfeksiyon belirteçidir. CRP inflamasyon, enfeksiyon veya doku nekrozu mevcut olduğunda yükselen karaciğer tarafından üretilen bir faz proteindir. Özellikle yenidoğan prematürelerde sepsis (kan zehirlenmesi) veya daha lokal olarak beyin zarı, solunum veya idrar yolları enfeksiyonları gibi rahatsızlıkların erken tespiti için CRP değerleri sürekli olarak takip edilmektedir. Prematüre bebekler normal doğum süresinde doğan bebeklere göre medikal belirteçleri farklılık gösterebilmektedir. Chiesa ve arkadaşları (2011) 221’i erken doğmuş 210’u zamanında doğmuş bebekler ile yaptıkları çalışmada gebelik yaşının CRP değerleri üzerinde anlamlı bir etkiye sahip olduğunu gözlemlemişler ve prematüre

bebekler için yeni CRP referans aralıkları önermişleridir. Doğum sonrası 6-8 saat aralığında elde edilen ilk CRP sonuçlarının enfeksiyon tespitinde tek başına zayıf bir belirteç olduğu gözlenmiştir (Yochpaz ve ark., 2020). CRP değerleri diğer laboratuvar bulguları ve medikal belirteçlerle birlikte izlendiğinde daha doğru bir değerlendirme parametresi olmaktadır.

3.1.2. Hemoglobin

Hemoglobin (Hb), kanda bulunan kırmızı kan hücrelerinde (alyuvarlar) oksijen iletiminden sorumlu olan proteindir. Akciğerler ile solunan havada bulunan oksijenin hücrelere taşınımının %97'sini hemoglobin sağlamaktadır. Yenidoğan bebeklerde fetal Hb'den yetişkin Hb sentezine geçiş sırasında doğal olarak Hb'e bağlanan oksijen miktarı artar. Bebeklerde ortaya çıkan hemoglobin düşüklüğü yani anemi hastalığı yenidoğan prematürelere daha şiddetli ve yaygındır (Ahel ve ark., 2008). Bu yüzden özellikle anemi (kansızlık) gibi hastalıkların teşhisinde hemoglobin değerinin takibi gereklidir. Varal (2020) yaptığı çalışmada bronkopulmoner displazi (BPD) hastalığı olan 65 ve BPD olmayan 93 bebekten elde edilen 1. 7. ve 14. gün Hb seviyeleri takip etmiştir. BPD olan bebeklerde BPD olmayanlara göre 1. ve 7. günlerdeki Hb seviyeleri anlamlı şekilde düşük bulunurken 14. günde anlamlı fark bulunamamıştır. Hb değeri yenidoğan prematürelere doğum sonrası YYBÜ sürecinde takip edilen önemli bir laboratuvar bulgusudur. Prematürelere kansızlık ve solunum hastalıklarının erken teşhisinde önemli rol oynayan kriterlerden biri olarak kaydedilmektedir.

3.1.3. Bilirubin

Bilirubin değeri kanda hemoglobinin yıkımı sonucunda ortaya çıkan bir maddedir. Kanda kırmızı kan hücrelerinde bulunan hemoglobinin karaciğerde yıkımı gerçekleşir. Bilirubin kana karışır ve karaciğerlerde işlenerek gaita (dışkı) yoluyla vücuttan atılır. Bebeklerde sarılık gibi bilirubin yüksekliğine bağlı hastalıklar fototerapi gibi tedaviler ile hayati risk taşıma seviyesinde değildir. Buna rağmen yenidoğan prematürelere bilirubin yüksekliği ve tedavi yoğunluğu fizyolojik ve nörolojik gelişiminin tamamlanmaması sebebiyle Bilirubin Kaynaklı Nörolojik Disfonksiyon (BKND) riski taşımaya devam etmektedir (Vinod ve ark., 2013). Prematüre bebeklerde karaciğerlerin tam olarak gelişmemesi bilirubin değerlerinin olması gerekenden çok yüksek olmasına sebep

olabilmektedir. Bu durum bilirubin nörotoksitesitesi riskini artırmaktadır (Watcho, 2016). Bu yüzden prematüre bebeklerde total bilirubin değeri sürekli olarak takip edilmektedir.

3.1.4. Ateş


Hastalıklara karşı daha savunmasız olan yenidoğan prematürelere termoregülasyonunu sağlamakta zorluk çekebilmektedir. Yüksek veya düşük ateş prematürelere mortalite oranları ile ilişkilendirilmektedir. Lyu ve arkadaşları (2015) yaptıkları çalışmada 33 haftadan erken doğmuş prematüre bebeklerde en düşük olumsuz durum oranının 36,5°C ve 37,2°C arasında olduğu ve daha yüksek veya daha düşük sıcaklık ölçümlerinde ciddi nörolojik hasarların, NEC ve BPD gibi hastalıkların arasında ilişkiler tespit edilmiştir. Ciddi viral enfeksiyonlar, bakteriyel patojenler ve birçok neden ateşin oluşumuna etki edebilir. Yenidoğan prematürelere hipotermi riski normal doğumlara göre daha yüksektir (İmamoğlu, 2019).

3.1.5. Nabız

Nabız kalp kasının düzenli olarak ritmik bir şekilde kasılıp gevşemesi ile damarlara uygulanan kuvvettir. Kalbin kasılıp gevşeme hareketi sırasında damarlarda oluşturduğu basınç ile damarlar elastik yapısı sayesinde genişleyip daralmaktadır. Nabız nabız oksimetresi ile veya yüze yakın bölgelerdeki damarların el ile hissedilmesi ile ölçülebilir. Nabız sayısı ve ritmi özellikle kalp rahatsızlıkları veya dolaşım sorunları gibi hastalıkların tespitinde ve takibinde önemli rol oynamaktadır. Yenidoğan prematürelere düşük periferik perfüzyon ve zayıf sinyal kalitesi nabız ve kalp atım hızının ölçümünü etkiler. Nabız ölçümünde birçok yöntem mevcuttur; palpasyon (elle hissederek), perküsyon (parmaklarla vurarak) ve oskültasyon (steteskopla dinleyerek) fiziki yöntemlere girmektedir. Nabız oksimetresi ayak veya el parmaklarına takılır ve kalp atım hızı, nabız, oksijen saturasyonu gibi parametrelerin ölçülmesine yardımcı olmaktadır. Elektrokardiyografi (EKG) altın standart ölçüm parametresidir. Johnson ve arkadaşları (2020) yaptıkları çalışmada kalp atım hızı ölçümünde kullanılan farklı tekniklerin değerlendirmesini yapmışlardır. Fiziksel muayene ölçümleri hızlı olsa da hata paylarının yüksek olduğu not edilmiştir. EKG ölçümü altın standart olarak kabul edilmektedir ama yenidoğan prematürelere elektrotların yerleştirilmesi ve düzenli takip zorluğu dikkat

çekmektedir. Nabız oksimetresi yeni doğum anında 1-2 dakikalık veri alma gecikmesi yaşansa da sürekli ölçüm kolaylığı sağladığı not edilmiştir.

Bu tez çalışmasında elde edilen nabız ve oksijen satürasyonu bilgileri Şekil 3.1’de görülen nabız oksimetresi ile elde edilmiştir.



Şekil 3.1. a. Nabız oksimetresi cihazı, b. Oksimetrenin üst probundan yayılan 660nm kırmızı ışık, c- üst probtan yayılan 940nm infrared ışık, d. Emilen ışık miktarını ölçen fotodedektör

Nabız oksimetresi dokulardan geçen 660nm kırmızı ışık ve 940nm kızılötesi ışık yaymaktadır. Emilen kırmızı ve kızılötesi ışık miktarına göre kanın oksijen doygunluğu hesaplanmaktadır. Nabız oksimetresi sadece arteriyel (nabza bağlı) kan akışını ölçtüğü için nabız ölçümünde kullanılmaktadır.


3.1.6. Oksijen Satürasyonu

Oksijen satürasyonu (SPO₂) kanda taşınan oksijen miktarının yüzdesi olarak hesaplanmaktadır. Yenidoğan prematüre bebeklerde doğumdan sonra ve ileriki yaşamında en büyük sorunlardan biri olarak solunum rahatsızlıkları göze çarpmaktadır (Pramana ve ark., 2011). Prematüre bebeklerin doku oksijenlenme değerlerine göre oksijen satürasyonu değerleri ayarlanmaktadır. Oksijen satürasyonu yüksek veya düşük doku oksijenlenmesini ve buna bağlı rahatsızlıkları önlemek için her YYBÜ’de kalan bebeğe özgü olarak ayarlanmakta ve takip edilmektedir. Manja ve arkadaşları (2015) 3152 yenidoğan bebek üzerinde yaptıkları çalışmada SPO₂ değerini Kritik Konjenital Kalp Hastalığı (KKKH) taramasında kullanmışlardır. KKKH taraması yapılan ve yapılmayan yenidoğanlar karşılaştırılmıştır. Tarama sonucunda pozitif veren sonuçlar ekokardiyografi ile doğrulanmıştır. Taramadan önce klinik muayene ile 12 olarak tespit edilen KKKH vakası tarama sonrasında 16’ya çıkmıştır. Tarama yapılmayan klinik

muayenelerde bir vaka atlanırken tarama sürecinde vaka atlanmamıştır. Tarama öncesi dönemde klinik nedenlerle %37,3 ekokardiyografi yapılırken, tarama sonrası dönemde bu oran %31,8'e düşmüştür. SPO2 değeri Şekil 3.1'de görülen nabız oksimetresi ile ölçülebilmektedir. Bu sayede sürekli ve düzenli takip edilmektedir. Yapılan çalışmalarda da görüldüğü üzere SPO2 değeri solunum rahatsızlıkları başta olmak üzere hastalıkların erken tanısında önemli rol oynamaktadır.

3.1.7. Solunum Sayısı

Yenidoğan prematürel zamanında doğan bebeklere göre daha az gelişmiş solunum kontrolüne sahiptir (Sale, 2010). Bu durum prematürel apne, hemoglobin desatürasyonu ve bradikardiye daha yatkın hale getirmektedir. Belirli bir süre kesilen solunum bebeklerde hipoksi, merkezi depresyon gibi rahatsızlıklara yol açabilmektedir (Sun ve ark. 2019). Bu yüzden solunum sayısı bebeklerde düzenli olarak takip edilmelidir. YYBÜ'de aktif olarak solunum sayıları başucu monitörleri ile elde edilmektedir. Başucu monitörü ve bebek kuvüzü (incubator) Şekil 3.2'de görülmektedir. YYBÜ'lerde başucu monitörlerinden hemşirelerin not alması ile günde 6-8 kez kaydedilmektedir. Warburton ve ark. (2019) yaptıkları çalışmada 94 prematüre bebekten elde edilen günde 8 kez hemşire ve 2204 kez monitör kaydı sonuçları karşılaştırılmıştır. Monitörle kaydedilen SpO2 <%90 oranı %5'in üzerinde olan bebeklerin, üç gün içinde solunum desteğinde artış gerektirme olasılığı 3.7 kat daha fazla bulunmuştur. Takipne (hızlı nefes alma durumu) (Solunum hızı>70) oranı %30'un üzerinde olan bebeklerde, solunum desteği ihtiyacında artış riski 2.8 kat daha fazla bulunmuştur. Hemşire kayıtları ise hipoksi olaylarının %46,6'sını ve takipne olaylarının %27,8'ini kaçırmıştır. Sürekli veri alınabilen medikal parametrelerin anlık takibinin elle kayıtlara göre daha iyi sonuçlar ürettiği ve karar destek sistemlerinde iyi bir yardımcı olabileceği görülmektedir.



Şekil 3.2. Başucu monitörü ve bebek kuvözü gösterim

3.2. Hiperspektral Görüntüleme

Hiperspektral görüntüleme spektrometre aracılığı ile bir yüzeye gönderilen ışığın yüzey tarafından yansıma veya soğurma bilgilerinin kaydedilerek “Hiperküp” elde edilmesidir. Bu hiperküp üzerinde iki boyut (x, y) mekânsal koordinatları temsil ederken üçüncü boyut dalga boyu (λ) bilgisini göstermektedir. Hiperspektral görüntüler farklı dalga boyu aralığında yüksek spektral çözünürlüğe sahip yüzlerce banttandır. (Villa ve ark., 2011). Farklı cisimler veya yüzeyler karakteristik spektral değerlere sahiptir. Bu sayede hiperspektral görüntüleme farklı spektral imzalara sahip nesnelerin ayrıştırılmasında, sınıflandırılmasında sıklıkla kullanılmaktadır (Edelman ve ark., 2012; Vasefi ve ark., 2016; Halicek ve ark., 2019).

Hiperspektral görüntüleme kullanılan spektrometrenin teknik özelliklerine bağlı olarak farklı dalga boyları arasında yüzlerce spektral banttandır. Spektral çözünürlük spektrometrenin çalıştığı dalga boyları arasındaki örneklem sıklığını tanımlamak için kullanılır. Hiperspektral görüntüleme Şekil 3.3’de görüldüğü üzere görünür ışıktan (VIS) başlayarak yakın kızılötesi (NIR), orta kızılötesi (MWIR) ve uzak kızılötesi (LWIR) dalga boyları aralığındaki spektral bilgilerin kaydedilmesi ile oluşturulabilir.



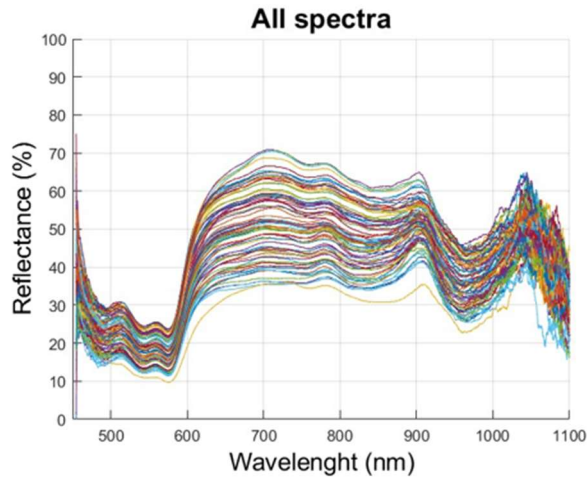
Şekil 3.3. Hiperspektral görüntüleme için dalga boyu aralığı

Bu çalışmada 480-1100nm aralığındaki görünür ve yakın kızılötesi alanı kapsayan alanda ölçüm yapabilen “Broadcom Qmini VIS/NIR – Miniature USB Spectrometer (AFBR-S20M2VN)” Spektrometresi kullanılmıştır. Kullanılan Broadcom Qmini spektrometresi noktasal ölçüm yapan bir spektrometredir. Tablo 3.1’de spektrometreye ait teknik özellikler yer almaktadır.

Tablo 3.1. AFBR-S20M2VN Qmini VIS/NIR Spektrometre Teknik Özellikler

| | |
|------------------------|-------------------|
| Spektral Ölçüm Aralığı | 480-1100 nm |
| Spektral Çözünürlük | ~1,5 nm |
| Pozlama Süresi | 3 μ s – 600 s |
| Dinamik Aralık | 1300:1 |
| Odak Uzaklığı | 50mm |
| Izgara | 300 lines/mm |

Her bir yenidoğan prematüre çekiminde 100 adet noktasal görüntüleme gerçekleştirilmiştir. Bu 100 hiperküp 10x10 olarak yeniden boyutlandırılarak hiperspektral görüntüler oluşturulmuştur. Şekil 3.4’de örnek bir tüm uzamsal alanlara ait ölçümleri içeren spektral değerler grafiği görülmektedir.




Şekil 3.4. Uzamsal Spektral Değerler Grafiği

Spektrometre tabanlı hiperspektral ölçümlerde, özellikle yansıma değerini elde etmek için bir referans kullanmak gerekmektedir. Bu çalışmada referans olarak BaSO₄ (Baryum Sülfat) bazlı bir beyaz standart kullanılmıştır. BaSO₄, geniş dalga boyu aralığında yüksek yansıtma özelliği gösteren ve nispeten pürüzsüz bir spektral eğriye sahip olan bir malzemedir. Kalibrasyon; ışıksız bir ortamda yapılan ölçümle “karanlık referans”, BaSO₄ üzerinden yansıyan ışık ölçümü ile “beyaz referans” alınarak gerçekleştirilmektedir. Daha sonrasında yapılan ölçümlerde yansıma değeri aşağıdaki eşitlikte görüldüğü gibi hesaplanmaktadır.

$$Yansıma = \frac{\text{Ölçüm Sinyali} - \text{Karanlık Referans}}{\text{Beyaz Referans} - \text{Karanlık Referans}} \quad (3.1)$$

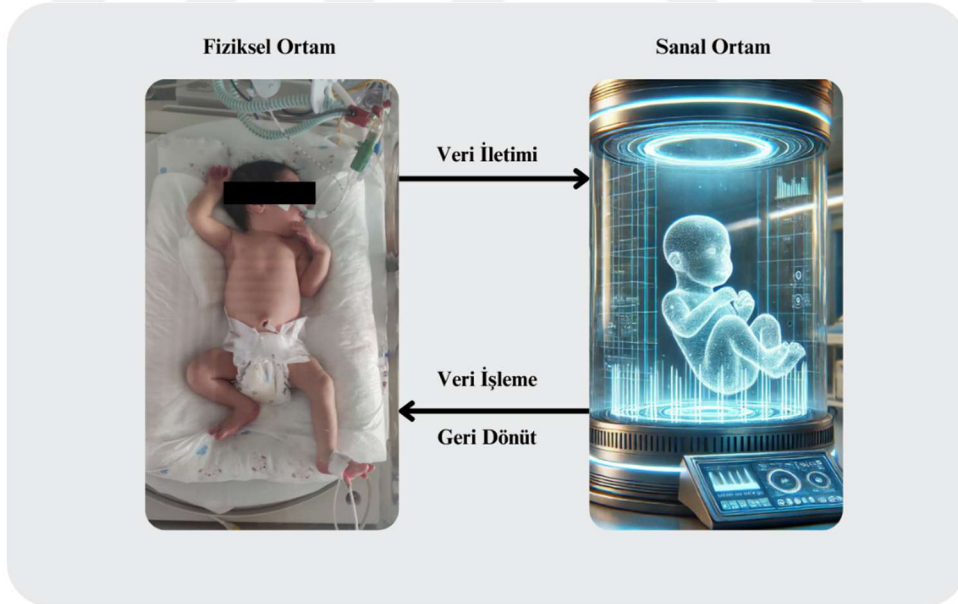
Bebekler üzerinde yapılan ölçümler Şekil 3.5’de görülen çekim ortamında gerçekleştirilmiştir. Beyaz ve karanlık referanslar gerçekleştirildikten sonra halojen ışık kaynağından yansıyan ışık miktarını ölçen spektrometre verileri sinyale dönüştürmektedir. USB kablo ile bilgisayara aktarılan sinyaller işlenerek yansıma değerleri oluşturularak kaydedilmektedir.



Şekil 3.5. Hiperspektral Ölçüm Düzenegi

3.3. Dijital İkiz

Dijital ikiz fiziksel varlıkların veya süreçlerin gerçek zamanlı elde edilen verileri ile durumlarını dijital ortama aktararak temsilini oluşturma olarak tanımlanabilmektedir. Dijital ikiz fiziksel bir üründen sağlanan veriler ile sanal ortamdaki temsiline kaynak sağlar. Sanal ortamda toplanan veriler fiziksel nesne için senaryolar oluşturur, farklı parametreler altında nesnenin davranışlarını ve tepkilerini ölçerek birebir gerçek ortam senaryoları oluşturmaktadır. Bu sayede dijital ikiz nesnenin veya iş sürecinin tam bir dijital yansımını oluştururken oluşabilecek hataları, olumsuzlukları olay gerçekleşmeden tahmin edebilmeye olanak sağlamaktadır. Bu noktada dijital ikiz ve simülasyon birbiri ile karıştırılabilmektedir. Simülasyon teknolojilerinde bir nesnenin fiziksel kanunlara göre dış etmenler ihmal edilerek vereceği tepkiler, yapabileceği hareketler ve cevaplar tanımlanırken, dijital ikiz bir nesnenin o anda yaptığı hareketlerin ve daha önce edinilmiş tecrübelerine göre verebileceği tepkilerin bulunduğu ortam ve şartlar dikkat altına alınarak dijital ortamda gösterimidir. Şekil 3.6'da dijital ikiz ortamının tasviri görülmektedir.

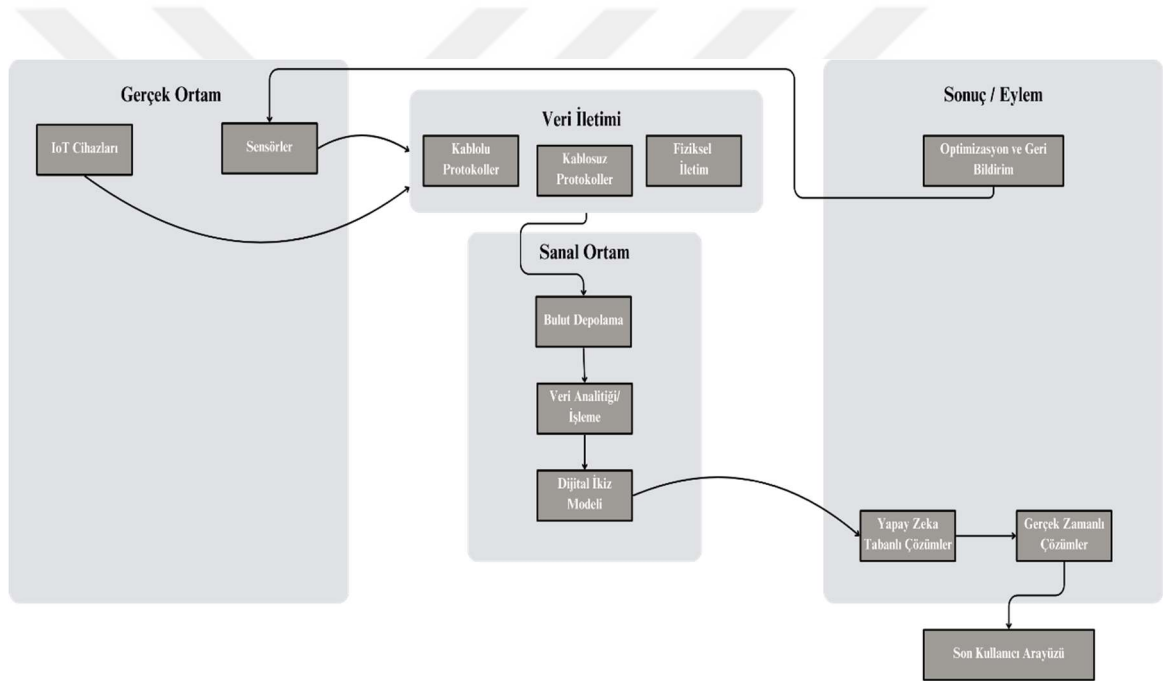


Şekil 3.6. Dijital ikizde fiziksel ve sanal ortam arası etkileşim

3.3.1. Dijital İkiz Ortamı

Dijital ikiz aynı anda birden fazla teknoloji ve sistemin birlikte çalışması ile işlem yapmaktadır. Fiziksel nesne veya süreçlerin gerçek zamanlı tepkilerini izleyebilmek için

sensör verilerinden faydalanılmaktadır. Sensör verilerinin elde edilmesi için birden fazla yöntem kullanılabilir. Sensör verilerini depolama alanları ile bağlayarak iletim sağlayan Nesnelerin İnterneti (IoT) teknolojilerinden faydalanılmaktadır. Ayrıca sensör verileri kablolu veya kablosuz iletişim protokolleri ile depolama sistemlerine iletilmektedir. Depolama sistemi olarak genellikle bulut depolama teknolojileri kullanılmaktadır. Dijital ortama iletilerek depolanan veriler ön işleme tabi tutularak anlamlı ve işlenebilir veriler çıkarılmaktadır. Elde edilen veriler yapay zeka tabanlı çözümler ile ileriye yönelik tahminler, simülasyonlar, farklı senaryolar üzerinden sonuçları seçerek gerçek zamanlı olarak kullanıcıya iletilmektedir. Şekil 3.7’de bir dijital ikiz sisteminin gerçek ve sanal ortamlar arasında nasıl haberleştiği ve genel işleyişini temsil eden blok diyagramı görülmektedir.



Şekil 3.7. Dijital ikizin işleyişini ve bileşenlerini temsil eden akış şeması

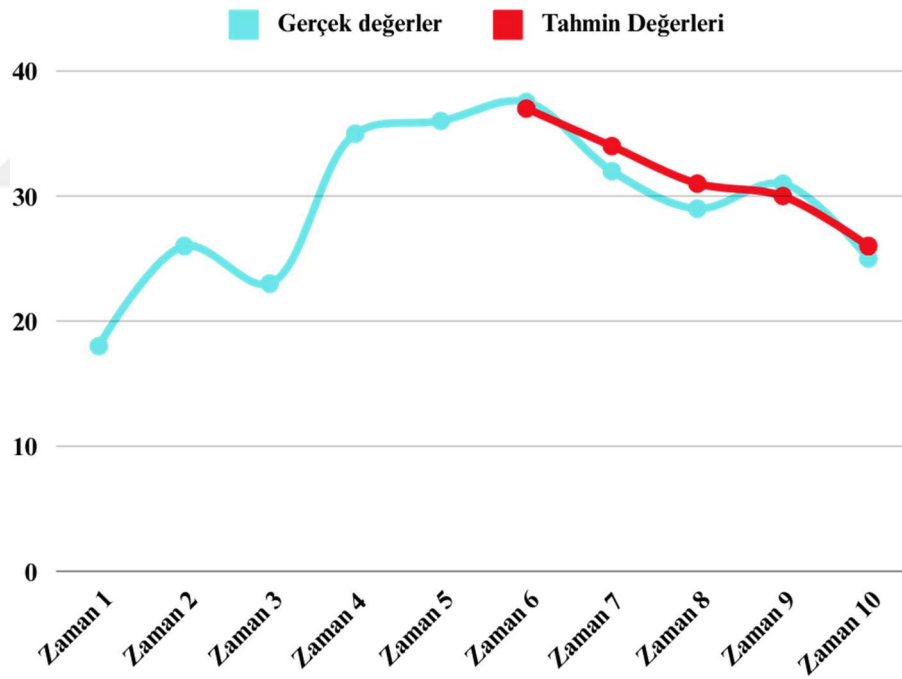
3.3.2. Dijital İkiz ve Yapay Zekâ

Nesnelerin gerçek zamanlı veya düzenli elde edilen verilerini sürekli alan ve analiz eden dijital ikiz çok yüksek miktarda veri sayılarına ulaşmaktadır. Yapay zeka ile dijital ikiz modelleri bu yüksek miktarda veriyi anlamlandırıp analiz edebilmektedir (Cotriss, 2022). Yapay zeka dijital ikiz modellerine sistemlerin gelecek davranışlarının tahmin edilmesi, geçmiş verileri analiz ederek örnek senaryolarda sistem davranışlarının çıkarılması gibi yetenekler sağlamaktadır. Havacılık (Yurkevich ve Stepanovskaya, 2021), akıllı şehir yönetimi (Shahat ve ark., 2021) ve kişiselleştirilmiş tıp (Björnsson ve

ark., 2020) gibi birçok alanda dijital ikiz ve yapay zeka birlikte kullanılarak çözüm üretilmiştir.

3.4. Zaman Seri Analizi

Zaman Seri Analizi (ZSA) mevcutta var olan verilerin özelliklerini çeşitli algoritmalar ve derin öğrenme gibi yöntemlerle değişim trendlerini analiz ederek ileriye yönelik tahminler yapan sistemlerdir (Sapankevych ve Sankar, 2009). ZSA çözümlerinden finans (Sezer ve ark., 2020), iklim (Dimri ve ark., 2020), medikal (Penfold ve ark., 2013) ve meteoroloji (Vakhare ve ark., 2020) gibi birçok farklı alanda faydalanılmaktadır. ZSA yöntemleri, bilgisayarların hesaplama kabiliyetlerinin artması ile çok yüksek sayıda zaman etiketli veriyi birlikte analiz edebilmektedir. Şekil 3.8'de örnek bir tek boyutlu zaman seri analizi grafiği görülmektedir.



Şekil 3.8. Örnek zaman seri analizi grafiği

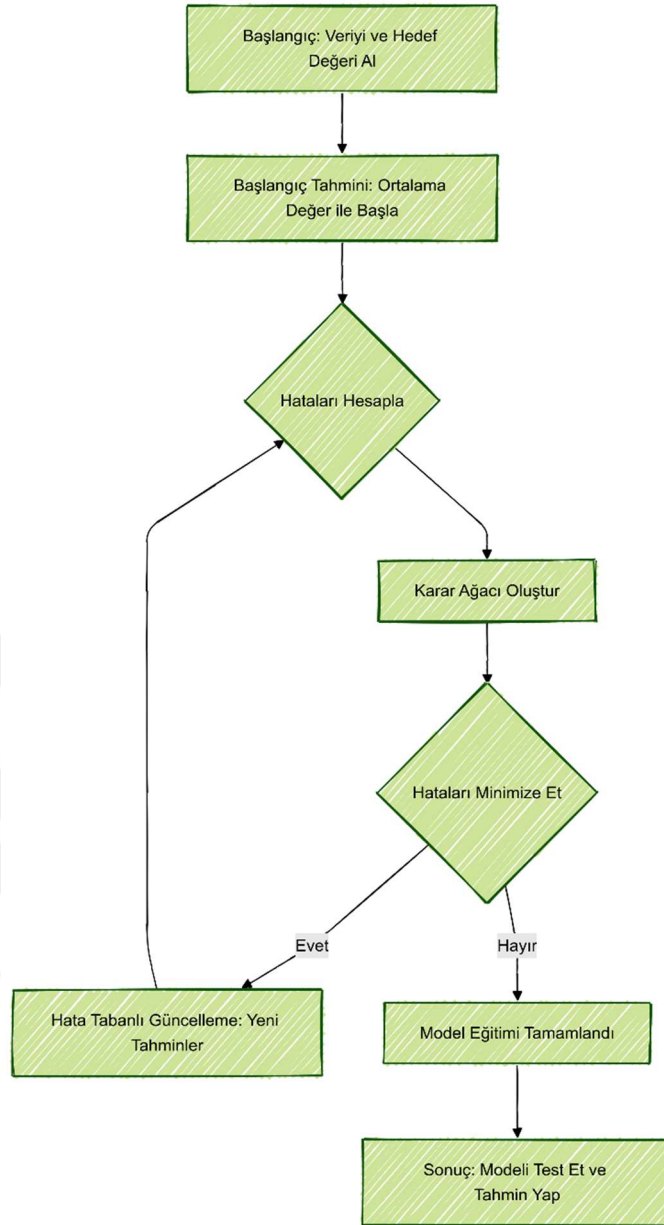
Şekil 3.8'de görülen örnek ZSA grafiğinde satırlar zaman etiketli verileri göstermektedir. Zaman etiketleri elde edilen verilerin düzenli veya düzensiz zamanlarda alınan örneklerini göstermektedir. ZSA modelleri zaman etiketli verilerin değişimlerini ve karakteristiğini farklı algoritma ve yapay zeka teknikleri ile öğrenmektedir. Modeller belirli zaman adımlarını inceledikten sonra ileriye yönelik tahminler üretmektedir. Şekil

3.8’de görülen çizgi grafiğinde mavi çizgi gerçek değerleri temsil ederken kırmızı çizgi tahmin değerlerini temsil etmektedir.

ZSA yöntemleri ilk olarak daha çok doğrusal verilerin analizi için kullanılan Otoregresif Hareketli Ortalama (OHO) yöntemleri ile geliştirilmeye başlanmıştır (Box ve ark.,2015). Daha sonrasında OHO yöntemine verilerin durağan olmayan zamansal farklılıklarını da dikkate alan entegrasyon teriminin eklenmesi ile geliştirilen Otoregresif Bütünleşik Hareketli Ortalama (OBHO) yöntemleri ile gelişmeye devam etmiştir (Makrıdakıs ve Hibon, 1997). Elde edilen verilerin doğrusal olmaması sebebiyle geliştirilen lineer ZSA modelleri yetersiz kalmaktadır. Makine öğrenmesi ve yapay zeka modellerinin gelişmesiyle birlikte ZSA yaklaşımlarında makine öğrenmesi tabanlı modeller geliştirilmeye başlanmıştır (Ahmed ve ark., 2010). Derin öğrenme yöntemleri doğrusal olmayan çözümlerde var olan derin ağ yapıları sayesinde yüksek doğrulukta temsil gücü elde edebilmektedir. Derin öğrenme modelleri karmaşık nöron bağlantıları sayesinde her gizli katmanında veriyi temsil eden katmanlı özellikler çıkarmaktadır. ZSA problemleri yüksek veri sayıları ve karmaşık temsil gereksinimi duyması sebebiyle derin öğrenme yöntemleri ile çözümlenmeye uygundur (Lim ve Zohrem, 2021). Dönüştürücü ağları özellikle metinden anlam çıkarma ve metin üretme alanlarında kullanılan yapay zeka modelleri olarak görülmektedir. Metin verileri diğer veri setlerine kıyasla sıralı gelen verilerde anlamsal olarak bağlılık göstermektedir. Aynı bağlılık ZSA verilerinde de gözlenmektedir. Bu sayede transformers temelli modeller zaman serisi verileri için kullanım alanı bulmuştur (Ahmed ve ark., 2023). Transformers ağlara benzer olarak Uzun-Kısa Süreli Bellek (LSTM) hücre yapılı derin öğrenme modelleri de zaman seri analizi çalışmalarında kullanılmaktadır (Siami-Namini ve ark., 2018; Kumar ve ark., 2021).

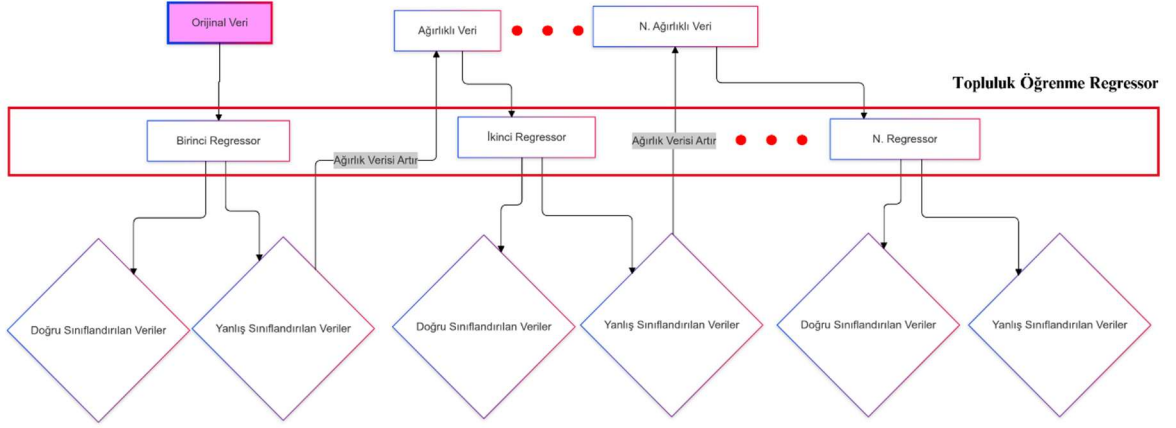
3.5. Xgboost

Aşırı Gradyan Güçlendirme (Xgboost) ağaç güçlendirme algoritmalarının gelişmiş bir örneğidir. Xgboost algoritmaları veri ölçeklendirme ve disk dışı işlem kapasiteleriyle çok yüksek sayıda veriler ile çalışmasını kolaylaştıran bir makine öğrenmesi yaklaşımıdır. Xgboost temelde karar ağaçları ile çalışır. Şekil 3.9’da Xgboost modellerinin temel model eğitim şeması görülmektedir.

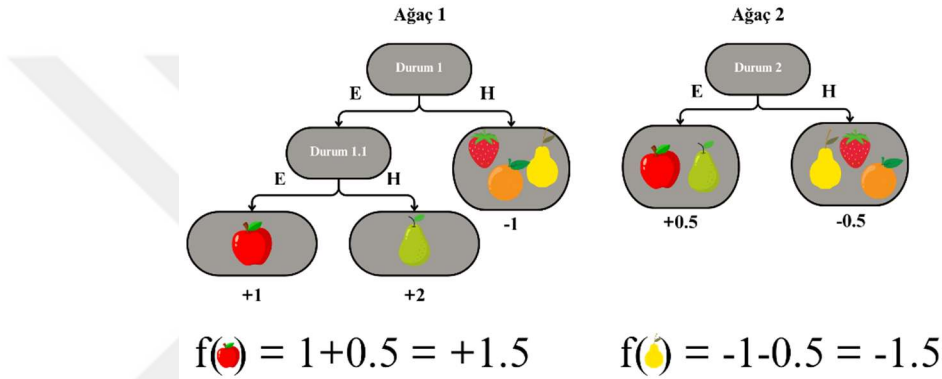


Şekil 3.9. XGboost Model Eğitim Diyagramı

Sıralı bir şekilde oluşturulan karar ağaçları ana veri setinden oluşturulan rastgele alt veri setleri ile eğitime başlar. Karar ağacının hatalı çıktıları ağırlıklandırılarak diğer karar ağacına aktarılır. Bu sayede öğrenme güçlendirilir. Belirlenen N adet karar verici ağaç bir araya getirilerek topluluk öğrenme modelini oluşturmaktadır. Xgboost modelleri regresyon, sınıflandırma, derecelendirme gibi farklı makine öğrenmesi problemleri üzerine çalışabilmektedir. Şekil 3.10'da örnek N dallı bir Xgboost modelinin eğitim sırasında gerçekleştirdiği öğrenme şeması görülmektedir.



Şekil 3.10. XGboost regressor modeli N dallı topluluk öğrenme modeli



Şekil 3.11. Xgboost topluluk öğrenme modelinde belirli bir örnek için tahmin algoritması.

Şekil 3.11’de Xgboost modelindeki karar ağaçlarının nihai tahminin nasıl oluşturulduğu görülmektedir. Model öğrenimini sağlamak için nihai tahmin değerleri ve gerçek değerler arasında farkın minimize edilmesi gerekmektedir. Bu sayede modelde kullanılan fonksiyon seti öğrenilebilmektedir. Aşağıdaki matematiksel ifadede $\mathcal{L}(\emptyset)$ regülasyon objesi minimize edilecek şekilde güncellenmektedir.

$$\mathcal{L}(\emptyset) = \sum_i l(y_i, \hat{y}_i) + \Omega(f_k) \quad (3.2)$$

$l(y_i, \hat{y}_i)$ ifadesi tahmin ve gerçek değerler arasındaki farkı ölçen değıştirilebilir bir kayıp fonksiyonudur. Ω ifadesi ek düzenlilik terimidir ve aşırı uyumu önlemek için ağırlıkların yumuşatılmasına yardımcı olmaktadır. Genellikle f_k karar ağacı olan bir modeldir. Xgboost modeli adım adım öğrenme işlemi gerçekleştirir ve her bir adımda bir önceki adımın tahminleyicilerini alarak o adımdaki hata değerlerinin öğrenme oranları ile birleştirilerek devam eder. Aşağıdaki ifadede basit bir adım öğrenme matematiksel ifadesi görülmektedir.

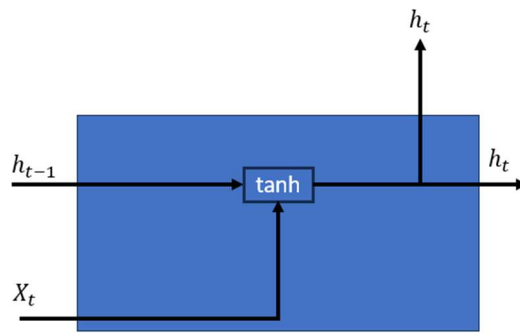
$$h_m(x) = h_{m-1}(x) + \eta f_m(x) \quad (3.3)$$

h_{m-1} : önceki tahmin modelini, f_m : m. adımdaki tahminleyiciyi ve η : öğrenme oranının göstermektedir. Öğrenme oranı modeli adım adım iyileştirmek için kullanılan bir küçültme faktörüdür. Her iterasyondaki tahminleyici ile bir önceki tahmin modelinin çıktısının toplamı o iterasyondaki tahmin modelini oluşturmaktadır. Bu sayede model geçmiş tahminleyicilerin çıktıları ile öğrenme yetisi kazanmaktadır. Aşağıdaki matematiksel ifadeye nihai öğrenme modeli görülmektedir.

$$h_M(x) = h_0(x) + \eta \sum_{m=1}^M f_m(x) \quad (3.4)$$

3.6. LSTM

Özellikle doğal dil işleme, metin analizi ve zaman serisi verileri gibi geçmiş verilerin hafızada tutulup gelen veriler ile birlikte ağırlıklandırılarak sonuç üretiminin beklendiği problemler için, Özyinelemeli Sinir Ağları (RNN), evrimsel sinir ağlarına kıyasla oldukça etkili sonuçlar sağlamıştır. RNN yapısı, önceki bir nöron katmanından elde edilen çıkış değerinin aynı nöron için giriş olarak yeniden kullanılmasıyla bir hafıza işlevi görmektedir. Şekil 3.12’de, RNN sinir ağı yapısının temel yapı taşı olan bir hücre modeli yer almaktadır.




Şekil 3.12. RNN sinir ağı yapısına ait en küçük birim (hücre)

Burada h_{t-1} hücrenin bir önceki çıktısını, X_t yeni gelen girişi ve h_t çıkışı temsil etmektedir. Şekil 3.8’deki sinir ağı hücre yapısının çıktı fonksiyonu aşağıdaki şekildedir.

$$h_t = \tanh(W_h * h_{t-1} + W_i * X_t) \quad (3.5)$$

Burada W_h gizli katmanın ağırlığını W_i giriş katmanının ağırlığını temsil etmektedir.

Veri setini boyutlarının büyüdüğü ve özellik sayısının arttığı durumlarda, RNN yapılarının hafıza kapasitesi yetersiz kalmaktadır. Ayrıca bu durumlarda gradyan sönmesi (vanishing gradient) problemi ortaya çıkmaktadır. Gradyan sönmesi problemi öğrenilen bilginin ağırlık ilk nöronlarında kaybolmasına neden olmaktadır. Hochreiter ve Schmidhuber (1997), RNN'lerin bu temel sorunlarını çözmek amacıyla LSTM ağlarını geliştirmiştir. LSTM ağları, RNN'lerle benzer bir yapıya sahip olmakla birlikte, giriş ve çıkış katmanlarına ek olarak unutma katmanı içermektedir. Şekil 3.13'de LSTM'nin yapısı gösterilmektedir.



Şekil 3.13. LSTM Sinir Ağı Yapısına ait En Küçük Birim (Hücre)

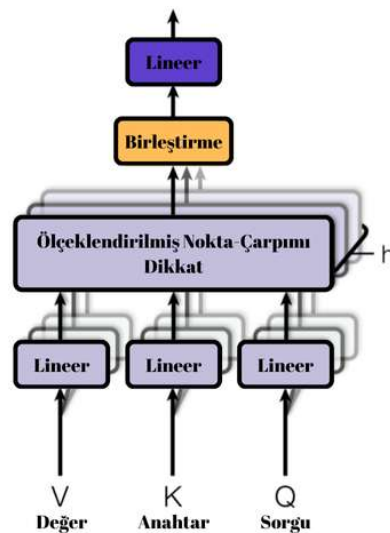
RNN hücrelerine benzer şekilde giriş ve çıkışlar benzer temsil edilmektedir. X_t giriş bilgisi ve h_t çıkış bilgisidir. C_t girişi ve C_{t-1} çıkış ağı LSTM'i RNN'den ayıran en temel parçadır. LSTM hücreleri bu yol ile geçmişte görülen verilerden elde edilen bilgileri taşımaktadır. Bu bilgi yolu sayesinde LSTM ağları geçmiş bilgileri hafızasında taşıyarak gelecek girişler ile birlikte değerlendirilmesini sağlamaktadır. Sigmoid fonksiyonu σ ifadesi ile temsil edilmektedir. Sigmoid fonksiyon $[0,1]$ aralığında değer almaktadır. Unutma kapıları (forget gate) hücrenin ilk kısmındaki aktivasyon işlemi ile geçmişten gelen hangi bilgilerin hafızada tutulup tutulmayacağına karar verilmesini sağlayan birimlerdir. Aşağıdaki eşitlikte unutma kapılarının matematiksel eşitlikleri verilmektedir.

$$\text{unutma kapısı} = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (3.6)$$

W_f ağırlık değerini, b_f bias değerini temsil etmektedir. Giriş ve çıkış kapıları ise RNN yapısına benzerlik göstermektedir.

3.7. Çoklu-Başlı Dikkat Mekanizması

Çok Başlı Dikkat Mekanizması (ÇBD) bir dikkat işleminin paralel birçok baş üzerinden hesaplanmasını sağlayan mekanizmalardır. ÇBD mekanizması farklı alt uzaylarda hesaplanan dikkat ilişkileri ile hem global hem de lokal bağlamlar çıkarılmasını sağlamaktadır. Bu da zaman serisi gibi yaklaşımlarda verilerin farklı zaman birimlerindeki ilişkilerinin farklı yaklaşımlar ile paralel olarak ortaya çıkarılmasını sağlayabilmektedir. Bu yaklaşım ilk olarak Vaswani ve arkadaşları tarafından öne sürülmüştür (Vaswani ve ark., 2017). ÇBD mekanizmasını temelde paralel olarak işlem yapan öz-dikkat birimleri oluşturmaktadır. Öz-Dikkat mekanizması sıralı bir verideki (zaman seri verisi, kelime dizisi veya görüntüdeki piksel sıralamaları) elemanların birbirleri arasındaki anlamsal bağlamların etkileşiminin yakalanmasını sağlayan birimleridir. LSTM/RNN gibi ardışık bağımlılıklara önem veren sistemlerin aksine öz-dikkat mekanizması her bir veri noktası arasındaki ilişkiyi hesaplayarak verilerin anlamlılık düzeyini "dikkat ağırlıkları" ile öne çıkarmaktadır. Öz-dikkat mekanizması sorgu (query), anahtar (key) ve değer (value) matrislerini kullanmaktadır. Öz-dikkat mekanizması denmesinin sebebi ise bu üç matrisin modelin girdisinden basit bit tamamen bağılı lineer katmanlar uygulanarak oluşturulmasından dolayıdır. Şekil 3.14'de öz-dikkat mekanizmasının yapısı görülmektedir.




Şekil 3.14. "Çoklu Başlı Dikkat" Mekanizmasının Temel Dikkat Birimi

Her bir tokenize edilmiş girdi ifadesi vektörize edilerek matrisler şeklinde tutulur. Q, V ve K değerleri farklı ilişkilere bakmak için kendi ağırlık matrisleri ile dönüştürülmektedir.

$$\begin{aligned} Q &= XW^Q \\ K &= XW^K \\ V &= XW^V \end{aligned} \quad (3.7)$$

Yukarıdaki eşitlikte X, gömme işlemi uygulanmış girdiler vektörü ile oluşan matris ifadesidir. W^Q , W^K ve W^V değerleri sırasıyla sorgu, anahtar ve değer değerlerinin ağırlık matrisleridir. Sorgu bilgisi girdide ne arandığını, anahtar ne sunulduğunu ve değer ise sunulan bilginin kendisini temsil etmektedir. Farklı projeksiyonlar ile özelleştirilen Q, K ve V değerleri “Ölçeklenmiş Nokta Çarpımı Dikkat” mekanizmasına sokulmaktadır. Bu mekanizma girdi bileşenleri arasındaki anlamsal ilişkinin ifade edilmesini sağlamaktadır. Şekil 3.15’de Ölçeklenmiş Nokta Çarpımı Dikkat mekanizmasının işlem akışı görülmektedir.



Şekil 3.15. Ölçeklenmiş Nokta-Çarpımı Dikkat

Nokta-Çarpımı Dikkat mekanizmasının arka planındaki fikir girdi verilerinin birbirleri arasındaki benzerlik puanını hesaplamaktır. Her bir sorgu ve anahtar vektörü arasındaki nokta çarpımını alarak benzerlik puanı oluşturmaktadır. Oluşturulan benzerlik puanı softmax fonksiyonundan geçirilerek 0-1 aralığında olasılıksal olarak dağılımı çıkarılır. Bu olasılıksal dağılım her bir girdi ifadesinin birbirleri arasındaki dikkat önemini temsil etmektedir. Aşağıdaki eşitlikte matematiksel olarak gösterimi görülmektedir.

$$Dikkat(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3.8)$$

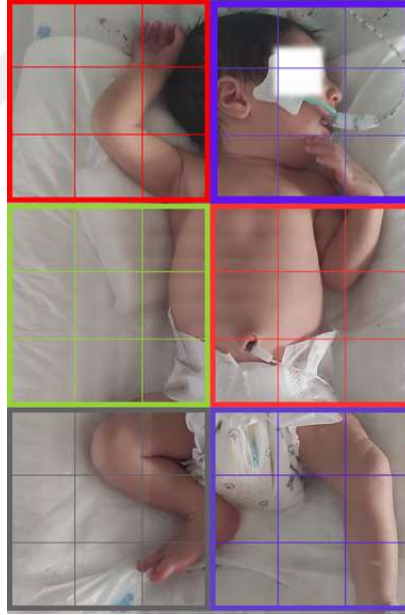
Burada d_k dikkat mekanizmasındaki anahtar ve sorgu vektörleri için projeksiyon boyutlarıdır. d_v ise değer vektörünün projeksiyon boyutudur. Gömme vektörünün uzunlukları arttıkça sorgu ve anahtar değerlinin projeksiyon boyutlarının büyümesi model eğitimini softmax fonksiyonunda satürasyon ve gradyan dengesizliği gibi sorunları ortaya çıkarabilmektedir. Uygulanan ölçekleme işlemi $\left(\frac{1}{\sqrt{d_k}}\right)$ bu büyümeyi normalize edip gradyanların dengeli kalmasını ve softmax fonksiyonundaki satürasyon problemine çözüm sunmaktadır.

3.8. Görü Dönüştürücü Ağlar

Literatürde görüntü işleme alanındaki yaygın yaklaşım genellikle Konvolüsyonel Sinir Ağı (KSA) olmuştur. KSA'lar görüntülere filtreler uygulayarak komşu pikseller arası anlamsal ifadeleri çıkarabilmektedir. Bu yaklaşım ile KSA derinleştikçe görüntülerdeki soyut özellik çıkarımları başarılı bir şekilde gerçekleştirilebilmektedir. KSA komşu pikseller arası ilişkilerin temsili ve ağ derinleştikçe özellik kayıplarının yaşanabilmesi model esnekliklerini kısıtlamaktadır. Transformatör ağlar ilk olarak Doğal Dil İşleme (DDİ) alanında Vaswani ve arkadaşları tarafından tanıtılmıştır (Vaswani ve ark., 2017). DDİ alanında cümlelerin tokenize edilerek gömme vektörlerine dönüştürülmesi ve öz-dikkat ağları ile kelimeler arasındaki anlamsal bağların çıkarılması sağlanmıştır. Tokenize edilen kelimeler Sorgu, anahtar ve değer vektörleri ile temsil edilmesi ile sadece ardışık gelen ifadeler arasında değil tüm kelimelerin birbirleri arasındaki önem değerleri ağırlıklandırılabilmiştir. Bu gelişme ile transformatör ağların görüntüler üzerinde kullanımı da araştırılmaya başlanmıştır. Dosovitskiy ve arkadaşları tarafından geliştirilen Vision Transformatör ağlar ile 224x224 boyutundaki görüntüler 16x16 yamalara bölünerek kelime benzeri tokenler olarak transformatör ağlarda işlenmesi önerilmiştir (Dosovitskiy ve ark. 2021). Bu yaklaşım sayesinde görüntülerden elde edilen yamaların metinlerdeki kelime yaklaşımına benzerlik kurarak transformatör ağlarda kullanılması sağlanmıştır. Bu yaklaşım, öz-dikkat tabanlı bir mimariyle doğrudan ham piksel verisi üzerinde başarılı sonuçlar elde edilebileceğini göstermiş ve KSA dışı bir çerçeve sunmuştur.

3.8.1. Görüntü Yamaları Oluşturma

Transformatör ağ tabanlı modeller genel olarak DDİ alanında kullanılmaktadır. Metinleri oluşturulan kelimeler tokenize edilerek gömme vektörlerine dönüştürülür. Bu sayede dikkat mekanizmaları bu kelime vektörleri arasındaki anlamsal ilişkileri çıkarabilmektedir. Görüntüler piksel denilen dijital bir görüntüyü oluşturan en küçük birimlerden oluşmaktadır. Yatay ve dikey konumda sıralanan pikseller $n \times m$ boyutunda bir görüntü matrisini oluşturmaktadır. Bu görüntü matrisleri görü dönüştürücülere girdi olarak kullanılabilmesi için yama oluşturma işlemine girmektedir. RGB bir girdi görüntüsü ($H \times W \times C$) boyutunda olmaktadır. Görüntüler $P \times P$ boyutunda örtüşmesiz (non-overlapping) yamalara bölünmektedir. Elde edilen yama sayısı $\left(\frac{HW}{P^2}\right)$ şekilde hesaplanabilmektedir. Şekil 3.16'da bir görüntü yama oluşturma işlemi görülmektedir. 9×6 bir görüntü 3×3 lük ızgara ile bölünmüş ve 6 adet yama oluşturulmuştur.




Şekil 3.16. Girdi görüntüsü yama oluşturma işlemi

3.8.2. Yama Gömme İşlemi

Oluşturulan girdi yamaları düzleştirilir ve bir lineer katman aracılığıyla bir gömülü uzaya haritalanmaktadır. Elde edilen boyut “gömme boyutu” veya “ d_{model} ” olarak ifade edilmektedir. Gömme boyutu ayarlanabilir bir hiper parametredir. Metin tabanlı transformatörlerde olduğu gibi görü dönüştürücülerde de konum bilgisi (pozisyonel gömme) eklenerek hangi yamanın görüntünün hangi konumunda olduğu

modele öğretilir. Pozisyonel gömme bilgisi doğrudan yama gömme katmanına toplanır. Şekil 3.17’de yama ve pozisyonel gömme işlemleri görülmektedir.




Şekil 3.17. Yama ve Pozisyonel Gömme İşlemleri

3.9. Temel Bileşen Analizi


Temel Bileşen Analizi (TBA) istatistiksel analizlerde sıklıkla kullanılan bir boyut indirgeme yöntemidir. TBA yüksek boyutlu veri kümelerinin temsil yeteneğini koruyarak daha düşük boyutlu bir alt uzay temsilinin oluşturulmasıdır. Bu yüksek boyutlu veri kümesi ile aynı temsil gücüne sahip daha düşük boyutlu temel bileşenler veriyi daha anlaşılır hale getirmek ve özellikle yapay zeka uygulamalarında modellerin hesaplama maliyetlerini düşürmek için kullanılan verimli bir yöntemdir. TBA, yüksek boyutlu bir veri kümesini kovaryans matrisinin özvektörlerini kullanarak dönüştürmektedir. Verinin en yüksek varyansa sahip doğrultuları “temel bileşenler” olarak adlandırılmaktadır. İlk temel bileşenler, verinin toplam varyansının çoğunu kapsayabilmektedir, boyut indirgeme sürecinde çoğu zaman yalnızca bu ilk bileşenler kullanılmaktadır (Jolliffe, 2002).

Bu çalışmada kullanılan hiperspektral veriler yüzlerce dalga boyu kanalından gelen sinyale sahip veri kümelerinden oluşmaktadır. Şekil 3.18’de noktasal spektrometre ile elde ettiğimiz hiperspektral veriye ait bir örnek görülmektedir.



Şekil 3.18. Hiperspektral veri örneği

Yukarıdaki veri örneğinde de görüldüğü üzere alınan örneklerde aynı dalga boyu kanalları benzer karakteristiği göstermektedir. Bu kanallar arasında yüksek korelasyon bulunabilmektedir. TBA, kovaryans yapısını çözümlyerek kanalların lineer kombinasyonlarını oluşturmaktadır. Spektral bilgiyi birbirinden bağımsız (ya da az bağımlı) bileşenlere ayırabilmektedir. Şekil 3.19’da yukarıdaki sinyalin temel bileşen komponent sayısı 100 olarak seçilmiş bir TBA çıktısı görülmektedir.



Şekil 3.19. TBA uygulanmış ve boyutu azaltılmış ($n_{\text{kompanent}}=100$) hiperspektral sinyal

3.10. Savitzky-Golay Yumuşatma Filtresi

Birçok spektral ölçüm cihazı veri alınması sırasında gaussian gürültü veya cihazdan kaynaklanan gürültü benzeri anomalilikler içerebilir. Bu tür sinyal işleme problemlerinde sinyallerin gürültüden arındırılması TBA veya makine öğrenmesi modelleri gibi daha sonraki aşamalarda güvenilir analiz gerçekleştirme amacıyla yaygın olarak kullanılmaktadır. Savitzky ve Golay tarafından tanımlanan savitzky-golay yumuşatma ve farklılaştırma filtresi yerel polinom yaklaşımları sayesinde ham verilerin karakteristik özelliklerinin (pik, tepe yüksekliği, sinyal genişliği vb.) korumaya yarayan etkin bir yumuşatma yöntemi olmaktadır.


Savitzky-golay filtresi her $x(t)$ veri konumu için pencere genişliği $= 2M+1$ civarındaki komşu veriler ile aşağıdaki denklikte görülen polinom modeline uydurmaktadır.

$$y = a_0x^0 + a_1x^1 + \dots + a_kx^k \quad (3.9)$$

Burada k değeri polinom derecesiyken x değeri sabit uzunluktaki bir zaman kaymasıdır. Katsayılar (a_0, a_1, \dots) en küçük kareler yaklaşımı ile tahmin edilmektedir. Gerçek veri noktaları ile polinom değerleri arasındaki farkların karelerinin toplamının en aza indirilmesi en küçük kareler yaklaşımı olarak bilinmektedir ve aşağıdaki eşitlikteki gibi gösterilmektedir.

$$\text{Minimize } \sum_{i=-m}^m (y_{t+i} - \sum_{j=0}^k a_j x_{t+i}^j)^2 \quad (3.10)$$

Tahmin edilen katsayılar içerisindeki merkez nokta tahmin değeri a_0 yumuşatılmış veri olarak alınır. Bu işlem tüm veri üzerinde kaydırılarak devam edilmektedir. Aşağıda Şekil 3.20'de Savitzky-golay yumuşatma filtresi uygulanmış hiperspektral bir veri görülmektedir.



Şekil 3.20. Pencere boyutu 5 polinom derecesi 2 uygulanmış filtre (a) ve Pencere boyutu 10 polinom derecesi 4 uygulanmış filtre (b)

3.11. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları yapay sinir ağlarında nöronların çıktılarını belirli aralıklarda tutarak modelin karar alma yeteneğini artırmaktadır. Ayrıca her veri seti doğrusal özelliğe sahip olmamaktadır. Doğrusal olmayan özellikleri ayırt edebilmek için yapay sinir ağı modellerinde nöron çıktılarını doğrusal olmayan özellikler eklemektedir. Bu sayede sinir ağları karmaşık olmayan verileri modelleyebilmektedir.

3.11.1. Sigmoid

Sigmoid fonksiyonu nöronların çıktılarını 0-1 aralığında tutan bir aktivasyon fonksiyonudur. Sigmoid fonksiyonu en yaygın kullanılan aktivasyon fonksiyonlarından biridir. Sigmoid fonksiyon grafiği Şekil 3.11'de görüldüğü üzere "S" şeklini almaktadır.

Girdi değerleri çok büyük veya çok küçük değerler olsa da $(\infty, -\infty)$ sigmoid fonksiyonu 0 ve 1 değerlerine yaklaşır. Bu durum geri yayılım aşamasında gradyan sönmesi sorunlarına yol açabilmektedir. Sigmoid fonksiyonunun türevi en yüksek değerde bile ($x=0$) 0,25 değerini almaktadır. Bu durum derinleşen ağ yapısında geri yayılım sırasında alt katmanlara ulaşmadan gradyanların çok küçülerek kaybolmasına yol açmaktadır. Bu sorunların önlenmesi için ağırlıkların normalizasyonu veya gradyan kırpma yöntemleri kullanılabilir. Sigmoid fonksiyonu matematiksel ifadesi aşağıdaki eşitlikte görülmektedir.

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

3.11.2. Tanh (Hiperbolik Tanjant)

Tanh aktivasyon fonksiyonu sigmoid fonksiyonuna benzerdir. Nöron çıktılarını -1 ile 1 değerleri arasına sıkıştırır. Girdisi pozitif değerlerde arttıkça fonksiyon çıkış değeri 1'e, girdi negatif değerlerde arttıkça çıkış değerleri -1'e yaklaşmaktadır. Tanh fonksiyonu grafiği Şekil 3.11'de görülmektedir. Sigmoid fonksiyona göre türevleri daha etkin bir aralık sağlamaktadır. Bu açıdan gradyan sönmesi probleminde sigmoid fonksiyona göre daha iyi bir performans göstermektedir. Ancak yine giriş değerleri çok büyük veya çok küçük olduğunda türev sigmoid fonksiyonda olduğu gibi 0'a yaklaşmaktadır. Geri yayılımda bu durum gradyan sönmesine sebep olabilmektedir. Tanh aktivasyon fonksiyonunun matematiksel ifadesi aşağıda görülmektedir.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.12)$$


3.11.3. ReLu

ReLu aktivasyon fonksiyonu diğer aktivasyon fonksiyonlarına göre daha basit bir yapıya sahiptir ve hesaplama parametresi düşük ve hesaplama hızı yüksektir. Bu yüzden ReLu yapay sinir ağları modellerinde en çok kullanılan aktivasyon fonksiyonu olarak bilinmektedir. Girişten gelen pozitif değerleri aynı şekilde çıkışa aktarırken negatif giriş değerlerini 0 olarak çıkarmaktadır. ReLu gradyan sönmesini riskini nispeten ortadan

kaldırırken pozitif değerleri direk çıkarması ve türevi 1 olması sebebiyle çok derin sinir ağlarında tek başına sebep olmasa da gradyan patlaması (exploding gradient) sorunu ortaya çıkarabilir. Ayrıca belirli nöronları sürekli sıfıra atayarak ölü nöron problemi de ortaya çıkarabilmektedir. ReLu fonksiyonu aşağıdaki matematiksel ifade ile temsil edilmektedir.

$$f(x) = \max(0, x) \quad (3.13)$$

Yukarıda anlatılan ReLu fonksiyonunun olumsuzluklarını gidermek için ReLu fonksiyonlarının türevleri geliştirilmiştir. GeLu, LeakyReLu, Elu, ve PReLu gibi aktivasyon fonksiyonları ReLu fonksiyonunun türevleridir. LeakyRelu negatif girdiler " αx " şeklinde hesaplanmaktadır. Elu fonksiyonunda negatif değerler " $\alpha(e^x - 1)$ " fonksiyonu ile elde edilir. PReLu fonksiyonu LeakyReLu ifadesindeki sabit α değerinin öğrenilebilir bir parametre olarak tanımlamaktadır. GeLu özellikle üretken transformatör doğal dil işleme modellerinde başarıyla uygulanarak popülerlik kazanmıştır. GeLu bir girdiyi normal dağılımın kümülatif dağılım fonksiyonu aracılığıyla ağırlıklı olarak geçirir. ReLu'dan farklı olarak GeLu, negatif değerleri de "olasılık ağırlıklı" aktarır. Bu, öğrenmeyi daha düzgün hâle getirebilmektedir. Şekil 3.21'de çeşitli aktivasyon fonksiyonlarının grafiksel gösterimleri görülmektedir.



Şekil 3.21. Temel aktivasyon fonksiyonları grafiği

3.12. Değerlendirme Metrikleri

Bu tez çalışmasında eğitilen zaman seri analizi modellerinde hedef çıktılar regresyon ve sınıflandırma tahminlerini içermektedir. Bu yüzden değerlendirme metrikleri olarak regresyon modellerinde hata fonksiyonları olarak kullanılan Ortalama Karese Hata (OKH) ve Ortalama Mutlak Hata (OMH) değerleri kullanılmıştır. R-Kare skoru tahmin edilen değerlerin gerçek değerlerden ne kadar uzak olduğunun yüzdesel bir ifadesi olarak hesaplanmaktadır. R-Kare skoru regresyon model doğruluğunun yüzdesel olarak ifade edilmesini sağlamak için tercih edilmiştir. Sınıflandırma tahminlerinde değerlendirme metriği olarak karmaşıklık matrisi tabanlı doğruluk, kesinlik, duyarlılık ve F1 skoru hesaplanmaktadır.

3.12.1. Karmaşıklık Matrisi

İkili sınıflandırma problemlerinde makine öğrenmesi modellerinin performanslarının değerlendirilmesinde karmaşıklık matrisi kullanılmaktadır. Aşağıda basit bir karmaşıklık matrisi Tablo 3.2’de görülmektedir.

Tablo 3.2. Karmaşıklık Matrisi

| | Gerçek Pozitif (Positive) | Gerçek Negatif (Negative) |
|----------------|---------------------------|---------------------------|
| Tahmin Pozitif | TP | FP |
| Tahmin Negatif | FN | TN |

Gerçek pozitif; 1 etiketli veriler, gerçek negatif; 0 etiketli verileri temsil etmektedir. Tahmin pozitif; model tarafından 1 tahmin edilen veriler, tahmin negatif; model tarafından 0 tahmin edilen verilerdir. TP; gerçek pozitif olan bir değer model tarafından da pozitif olarak tahmin edilmesidir. TN; gerçek negatif verinin model tarafından negatif olarak tahmin edilmesidir. FP; gerçek pozitif olan verinin model tarafından pozitif olarak tahmin edilmesidir. FN; gerçek pozitif olan bir verinin model tarafından negatif olarak tahmin edilmesidir. Karmaşıklık matrisi; modelinizin hangi örneklerden hata yaptığını (FP, FN), hangi örnekleri başarıyla doğru sınıflandırdığını (TP, TN) açıkça gösterir.

3.12.1.1. Doğruluk (Accuracy)

Doğruluk (Accuracy), tüm veri içerisindeki doğru sınıflandırılmış verilerin tüm veri kümesine oranıdır. Hem pozitif hem de negatif sınıfları doğru tahmin etmenin genel bir göstergesidir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.14)$$

Pozitif ve negatif veri sayıları dengeli ise doğruluk değeri anlamlıdır. Aksi durumda doğruluk değeri tek başına yanıltıcı olabilmektedir.

3.12.1.2. Kesinlik (Precision)

Kesinlik değeri modelin pozitif olarak tahmin ettiği verilerin kaç tanesinin gerçekten pozitif olduğunu gösteren bir değerlendirme metriğidir. Hatalı tahmin edilen pozitif değerler özellikle sağlık alanı gibi kritik alanlarda önemlidir. Örneğin hatalı pozitif tahmini sağlıklı bir kişiyi hasta olarak etiketlenmesine yol açabilmektedir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.15)$$

Yanlış tahminleri düşük tutmak ve pozitif tahminlerin güvenilir olması isteniyorsa “Kesinlik” değerine odaklanılmaktadır.

3.12.1.3. Duyarlılık (Recall)

Duyarlılık veya Hassasiyet (Sensitivity), gerçekte pozitif olan örneklerin ne kadarını modelin doğru tahmin ettiğini ifade edilmesinde kullanılmaktadır. Duyarlılık gerçek pozitif örneklerin ne kadarı “pozitif” olarak tahmin edildiğini hesaplamaktadır.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.16)$$

FN değeri yüksekse, modelin pozitif örnekleri tahmin edemediği görülür. Bu durum duyarlılık değerini düşürmektedir. Geliştirilen problem çözümünde pozitif örneklerin doğru tahmin edilmesi kritikse, duyarlılık değeri yüksek olmalıdır.

3.12.1.4. F1-Skor

F1-Skoru kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak hesaplanmaktadır. Kesinlik ve duyarlılığı tek bir metrik ile özetlemektedir. F1-Skoru 0-1 arasında değişir ve 1 değeri en iyi model performansını göstermektedir.

$$F1 = 2 \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlı}} \quad (3.17)$$

3.12.2. Ortalama Karesel Hata

Regresyon modellerinde çıktı tahminleri ve gerçek değerler arasındaki farklar farklı metriklerle temsil edilmektedir. Ortalama Karesel Hata (OKH) tahmin edilen ve gerçek değerler arasındaki farkın karesel ortalamasını hesaplamaktadır. Her bir veri özellik kümesinden üretilen model çıktısı o veri noktasının hedef değeri ile karşılaştırılmaktadır. Bu karşılaştırma değerleri hata metrikleri olarak adlandırılmaktadır. Aşağıda OKH'nın matematiksel ifadesi görülmektedir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (Y_i - \check{Y}_i)^2 \quad (3.18)$$

Burada Y_i gerçek değeri \check{Y}_i tahmin edilen değerleri temsil etmektedir.

3.12.3. Ortalama Mutlak Hata

OKH hata değerinin karesini aldığı için aykırı değerlere karşı duyarlıdır. Aykırı değerlerin hata ifadeleri yüksek olduğu ve OKH fonksiyonunda hata ifadesi karesel olarak temsil edildiği için hata değerini çok yükseltebilir. Bu durumda Ortalama Mutlak Hata (OMH) veya Kök Ortalama Karesel Hata (KOKH) fonksiyonları kullanılabilir. Aşağıdaki eşitlikte OMH fonksiyonunun matematiksel ifadesi görülmektedir.

$$OMH = \frac{1}{n} \sum_{i=1}^n |Y_i - \check{Y}_i| \quad (3.19)$$

Burada Y_i gerçek değeri \hat{Y}_i tahmin edilen değerleri temsil etmektedir.

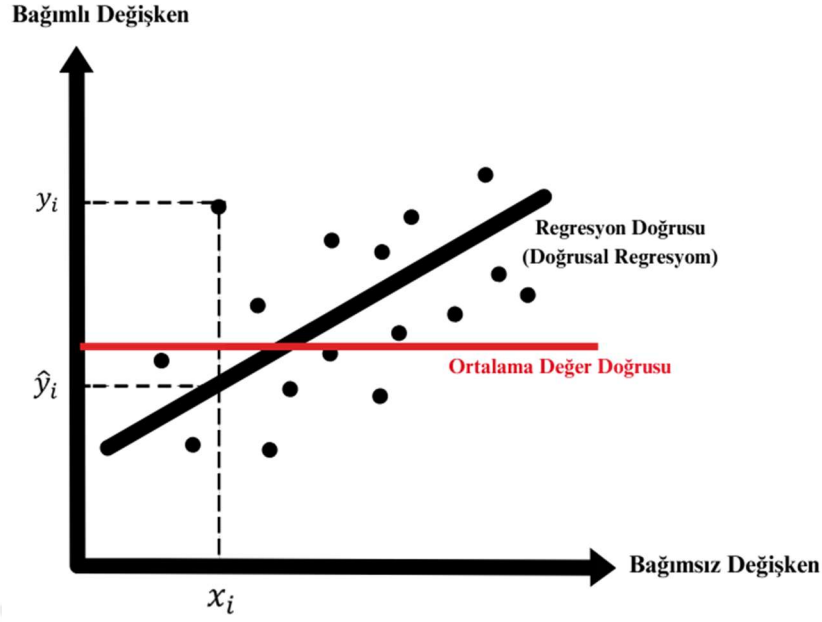
3.12.4. R-Kare Skoru

Regresyon modellerinde doğruluk ifadesi genellikle hata değerlerinin fonksiyonları olarak ifade edilmektedir. Bu fonksiyon çıktıları sifıra yaklaştıkça model performansının iyileştiği anlaşılmaktadır. Sınıflandırma problemlerinde ise doğruluk ifadeleri genellikle doğru tahmin edilen ve yanlış tahmin edilen sınıfların oransal olarak karşılaştırılmasıyla yüzdesel çıktı vermektedir. R-kare skoru regresyon modellerinde de sınıflandırma modellerinde olduğu gibi model doğruluğu değerlendirmesini yüzdesel olarak yapılmasını sağlayan bir hata değerlendirme fonksiyonudur. R-kare skoru 0 ile 1 arasında değer almaktadır. Skor 1'e yaklaştıkça modelin verileri açıklama seviyesinin yüksekliği anlaşılmaktadır. R-kare değeri 0'a yaklaştıkça modelin verilerin varyansını açıklamadığı ve bağımsız değişkenler ve bağımlı değişkenler arası ilişki tespit edilemediği görülmektedir. R-kare değeri 0'dan küçük değerler de alabilir. Bu durumda modelin bağımlı değişkenler ve bağımsız değişkenler arası kötü uyum sağladığını göstermektedir. Aşağıdaki matematiksel eşitlikte R-kare değeri hesaplama formülü görülmektedir.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y}_i)^2} \quad (3.20)$$

y_i : gerçek değerleri, \hat{y}_i : modelin tahmin ettiği değerleri ve \bar{y}_i gerçek değerlerin ortalamasını temsil etmektedir.

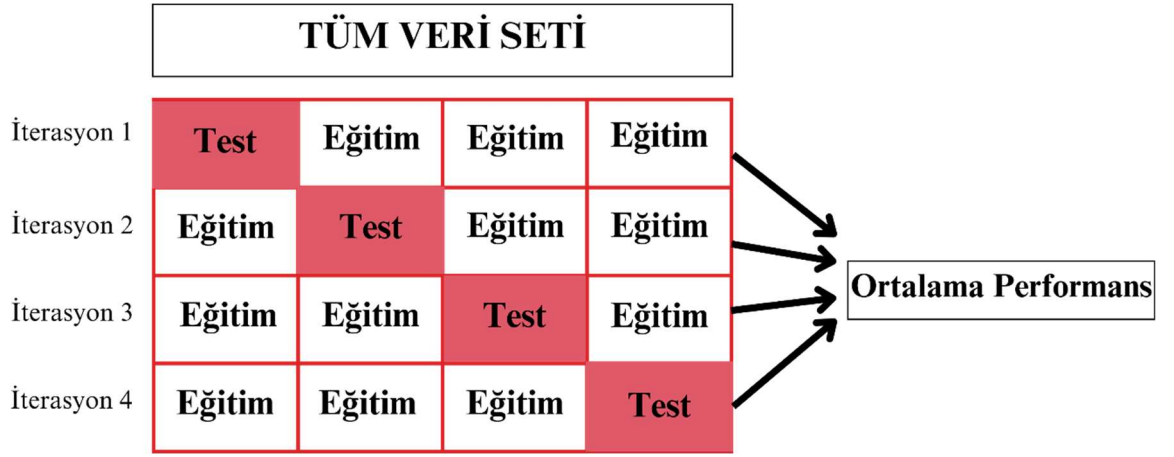
Şekil 3.22'de doğrusal bir regresyon modelinin grafiği görülmektedir. y_i , \hat{y}_i ve \bar{y}_i değerleri grafik üzerinde daha net anlaşılmaktadır.



Şekil 3.22. Tek bağımsız değişkenli doğrusal regresyon modelinin örnek bir grafiği

3.13. K-Kat Çapraz Doğrulama

K-Kat Çapraz Doğrulama bir veri setinin K adet kümeye bölünerek bir kümesinin test diğer kümelerinin eğitim verisi olarak ayarlanmasıdır. Bu işlem her bir kümenin test kümesi olacağı şekilde K kez tekrarlanır. Bu işlemin yapılmasının sebebi özellikle veri sayısının kısıtlı olduğu problemlerde model doğruluğunu artırmaktır. Ayrıca her bir kümeyi test seti olarak gösterilmesi yapay zeka modelinin veri setini temsil etme gücünü artırmaktadır. Şekil 3.23'de K=4 olarak ayarlanmış bir çapraz doğrulama işlemi örneği görülmektedir. Her bir iterasyonda elde edilen model performansı kaydedilir. Tüm iterasyonlar bittikten sonra model performansı her bir adımdaki model performanslarının ortalaması olarak kaydedilmektedir. Az sayıda veriye sahip problemlerde ayrıca modelin verileri ezberleme (overfitting) sorununu da ortadan kaldırmaktadır. K sayısı arttıkça daha güvenilir ve düşük varyanslı eğitim sağlasa da işlem süresi artmaktadır.

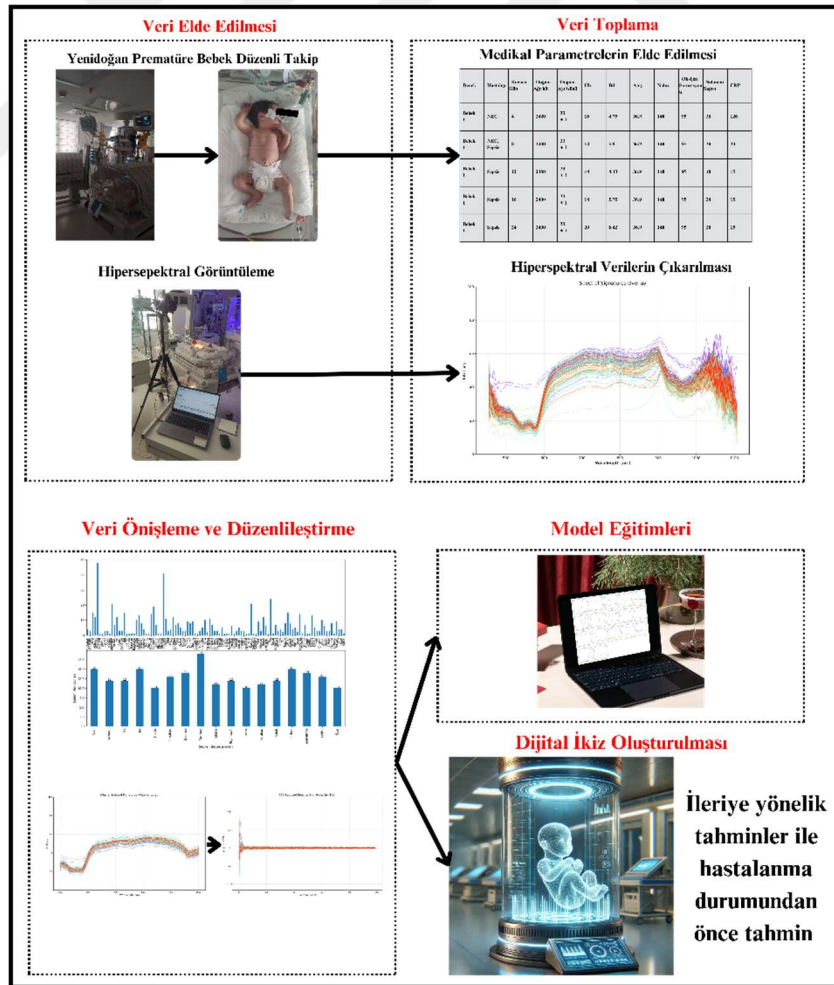


Şekil 3.23. K-Kat Çapraz Doğrulama işleminin işleyiş şeması



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde YYBÜ de yatan premature bebeklerden elde edilen medikal parametreler, laboratuvar bulguları ve hiperspektral verilerin veri alma süreçleri tanıtılmış ve ileriye yönelik medikal parametre tahminlerini gerçekleştirmek için geliştirilen LSTM tabanlı derin öğrenme, Xgboost ve paralel LSTM ve Çok-Başlı Dikkat Mekanizması modellerinin zaman seri analizi olarak geliştirilmesi, zaman etiketli hiperspektral verileri girdi olarak kabul eden Vision Transformatör ağların ileriye yönelik hastalık tahmini yapan yapay zeka modellerinin geliştirilme süreci anlatılmıştır. Bu geliştirilen yaklaşımlar ile yenidoğan premature bebeklerde vaka yönetimi ve önlenmesi için dijital ikiz oluşturma uygulamalarının detayları verilmiştir. Bu bölümdeki işlemlerde yazılım dili olarak Python kullanılmıştır. Model eğitimleri NVIDIA RTX 3050TI ekran kartına sahip 32GB RAM'e sahip bilgisayar üzerinden gerçekleştirilmiştir. Şekil 4.1'de tez çalışmalarına ait genel blok diyagramı görülmektedir.



Şekil 4.1. Tez çalışması akış diyagramı

4.1. Yenidoğan Medikal Belirteci Verilerinin Elde Edilmesi

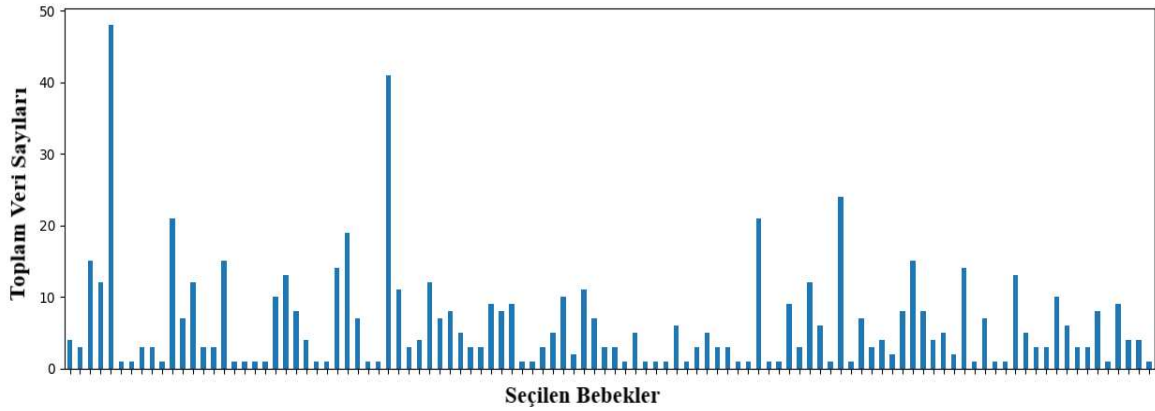
Yenidoğan prematüre bebeklere ait medikal belirteç ve laboratuvar bulguları parametreleri TÜBİTAK – 1001- Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı (Proje No: 122E021) kapsamında Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesindeki yenidoğanlardan elde edilmiştir. Proje araştırması, Etik Kurul Onayı (2022/125) ile elde edilmiştir. Etik kurulu raporu EK-1’de verilmiştir.

Yenidoğan prematürelere elde edilen medikal belirteç verileri bebeklerin bağlı oldukları başucu monitörlerinden hemşirelerin gün içerisinde 4-8 kez manuel olarak kaydettikleri verilerden elde edilmiştir. Medikal belirteç verileri veri kaydedilen son gün elde edilen son kayıt değerleri alınarak kaydedilmiştir. Laboratuvar bulguları bebeklerin kan tahlilleri sonucu elde edilen CRP, hemoglobin ve total bilirubin değerlerini içermektedir. Özellikle yenidoğan prematürelere kan tahlilleri bebeklerin fiziksel zayıflığı ve kan yetersizliği göz önünde bulundurularak ciddi gerekli görülmedikçe alınmamaktadır. Bu yüzden özellikle sağlıklı süreçteki bebeklerin laboratuvar bulgusu parametreleri bazı periyotlarda kaydedilememiştir. Bu boş veriler veri ön işleme süreçlerinde bir önceki verinin yazılması ile doldurulmuştur. Aşağıda Tablo 4.1’de bir bebek için alınan verilere ait örnek görülmektedir.

Tablo 4.1. YYBÜ’de kalan bir bebeğe ait zaman etiketli veri örneği

| Denek | Hastalığı | Kaçıncı Gün | Doğum Ağırlığı | Doğum Ayı/Günü | Hb | Bil | Ateş | Nabız | Oksijen Satürasyonu | Solunum Sayısı | CRP |
|---------------|-------------|-------------|----------------|----------------|----|------|------|-------|---------------------|----------------|-----|
| Bebek1 | NEC | 4 | 2400 | 33+1 | 16 | 4.75 | 36.9 | 140 | 95 | 38 | 126 |
| Bebek1 | NEC, Sepsis | 8 | 2400 | 33+1 | 14 | 5.8 | 36.9 | 140 | 95 | 30 | 30 |
| Bebek1 | Sepsis | 12 | 2400 | 33+1 | 14 | 4.43 | 36.9 | 140 | 95 | 40 | 15 |
| Bebek1 | Sepsis | 16 | 2400 | 33+1 | 18 | 5.75 | 36.9 | 140 | 95 | 24 | 15 |
| Bebek1 | Sepsis | 24 | 2400 | 33+1 | 20 | 6.42 | 36.9 | 140 | 95 | 20 | 15 |

Aşağıda Şekil 4.2’de verisi elde edilen tüm bebeklere ait veri kaydetme sıklıklarını gösteren grafik görülmektedir.



Şekil 4.2. Zaman etiketli verisi elde edilen tüm bebeklerin veri sayısı dağılımı.

4.2. Yenidoğan Laboratuvar Bulgularının Zaman Seri Analizi Modelleri ile Tahmini

Yenidoğanlardan elde edilen kan tahlili verileri prematürelerin kansızlık gibi hastalıklar veya kan alımının bebekler için acılı bir süreç olması sebebiyle sürekli gerçekleştirilememektedir. Zaman seri analizi modelleri ile bu laboratuvar bulgularının diğer medikal belirteçler ve/veya geçmiş ölçüm değerlerini izleyerek ileriye yönelik tahminlerinin gerçekleştirilmesi sağlanmaktadır.

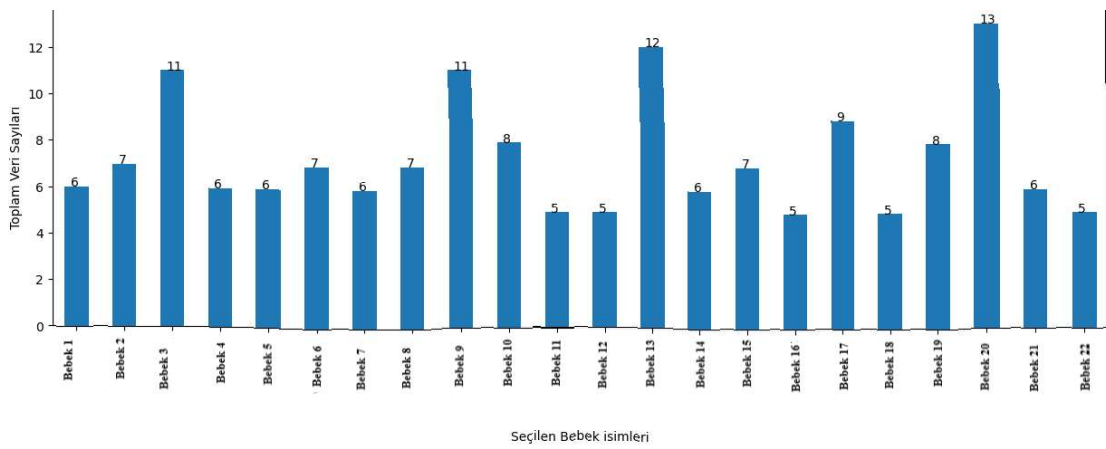
4.2.1. LSTM Tabanlı Modeller ile Zaman Seri Analizi

Yenidoğan yoğun bakımında yatan Sepsis, RDS, NEC, Pnömotoraks, Intrakranial kanama (IKK), diafragma ve hafif solunum sıkıntısı olan 22 bebek ile çalışma gerçekleştirilmiştir. Hafif solunum sıkıntısı yaşayan bebekler sağlıklı olarak kabul edilmiştir. Bebeklerin CRP, bilirubin ve hemoglobin değerleri kaydedilmiştir. Çalışmaya dahil edilen 22 bebeğin veri dağılımları Şekil 4.2’de görülmektedir. Bebeklere ait CRP, Bilirubin ve Hemoglobin değerlerinin grafikleri Şekil 4.3’de görülmektedir.



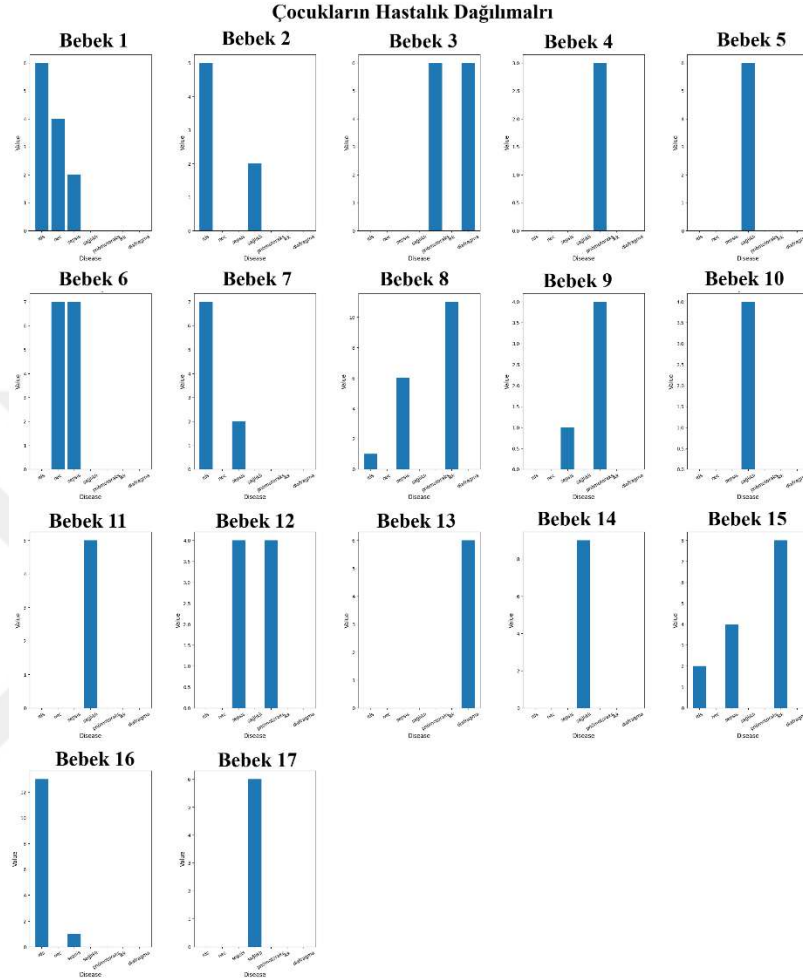
Şekil 4.3. CRP, Bilirubin ve Hemoglobin değerleri için zaman serisi grafikleri. (Yeşil çizgi CRP, turuncu çizgi Bilirubin, mavi çizgi Hemoglobin)

Bebeklerin veri dağılımındaki dengesizlik model performansını etkileyeceği için bebeklerin zaman seri etiketli verilerinden en az 5 en çok 15 adet elde edilen laboratuvar bulgusu verisi filtrelenmiştir. Şekil 4.4’de filtrelenmiş veri sayıları ile bebeklerin zaman etiketli veri sayısı dağılımı görülmektedir.



Şekil 4.4. Zaman etiketli veri sayısı 5-15 aralığında filtrelenmiş bebeklerin veri dağılımı

Bulguları toplanan bebeklerin verilerinin kaydedildiği anlarda sahip olduğu hastalıkların dağılımları Şekil 4.5’de görülmektedir. Filtreleme sonucunda 22 olan bebek sayısı 17’ye düşmüştür. Bebekler birden fazla hastalığa aynı anda sahip olabileceği gözden kaçmamalıdır.



Şekil 4.5. Bebeklerin hastalık dağılımları

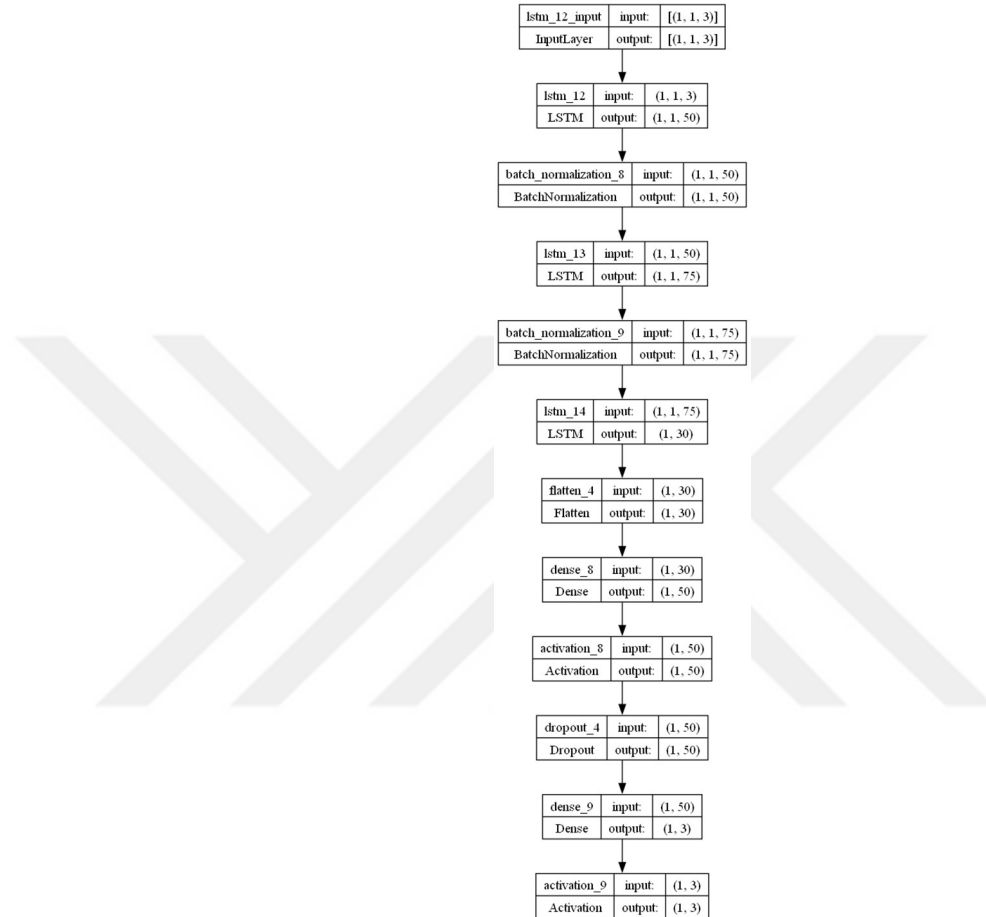
Tablo 4.2’de çalışmaya dahil edilen bebeklerin laboratuvar bulguları elde edildiği süre içerisinde sahip oldukları hastalıklar ve tüm bebekler için toplam hastalık sayıları gösterilmiştir.

Tablo 4.2. Veri elde edilen bebeklerin hastalıkları ve toplam sayıları

| Hastalıklar | Toplam Hastalık Etiketli Veriler |
|-------------|----------------------------------|
| RDS | 48 |
| NEC | 54 |
| Sepsis | 36 |
| Sağlıklı | 33 |
| Pnömotoraks | 6 |

4.2.1.1. LSTM Model Mimarisi

Bu çalışmada oluşturulan LSTM derin öğrenme modeli 3 LSTM ağı yapısından ve tam bağlantılı sinir hücresi yapısına bağlanmaktadır. Şekil 4.6’da ağıın model yapısı görülmektedir.



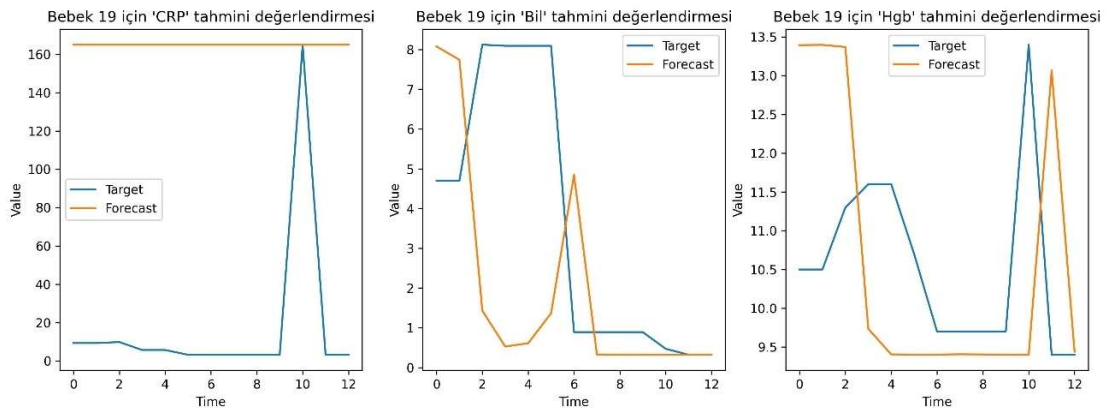
Şekil 4.6. LSTM model yapısı parametreleri

Modelin girişi CRP, hemoglobin ve bilirubin değerlerini alacaktır. Bu yüzden model girişi (1,1,3) olarak ayarlanmıştır. İlk LSTM modülü 50, ikinci modül 75 ve üçüncü modül 30 hücre içermektedir. Her ağ geçişinde “Yığın Normalleştirme” uygulanmıştır. Ağ çıktısını bir regresyon modeli gibi nümerik sayı olarak elde edebilmek için ağ çıkışına tam bağlantılı katmanlar eklenmiştir. Çıkış aktivasyon fonksiyonu olarak tanh aktivasyon fonksiyonu belirlenmiştir.


LSTM ağ mimarisi kullanılarak oluşturulan modelin eğitimi öncesinde, her bebeğe ait CRP, hemoglobin ve bilirubin kan parametreleri, her bir veri noktası için bir adım geri kaydırılmıştır. Bu işlemle her t anındaki veri, t_{+1} anındaki hedef değer olarak yapılandırılmış ve eğitim süreci denetimli öğrenme şeklinde düzenlenmiştir. LSTM

modeli, her bir bebeğin zaman serisi verisi için ayrı ayrı eğitilmiştir. Bebekler arasında geçiş yapılırken modelin hafızası sıfırlanmıştır.

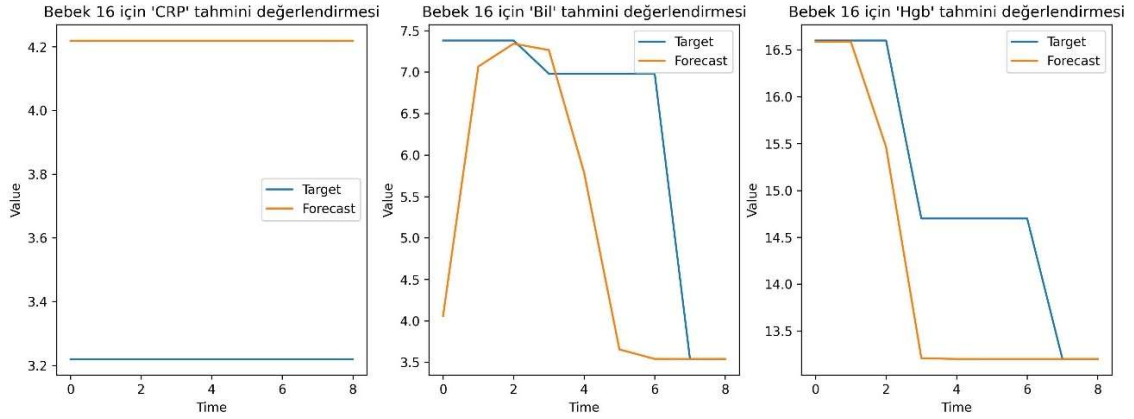
Model, her bir bebeğin zaman serisi verisi üzerinde 1000 epoch boyunca eğitilmiştir. Optimizasyon yöntemi olarak "Adam" algoritması tercih edilmiştir. Modelin geliştirilmesi ve veri ön işleme aşamaları Python 3.11.4 kullanılarak gerçekleştirilmiş, TensorFlow, Keras ve scikit-learn kütüphanelerinden yararlanılmıştır. Eğitim ve veri ön işleme işlemleri, 32 GB RAM'e sahip bir dizüstü bilgisayarda NVIDIA GeForce RTX 3050Ti grafik kartı ile gerçekleştirilmiştir. Model çıktıları test için ayrılmış veriler üzerinden Şekil 4.7'de görülmektedir.



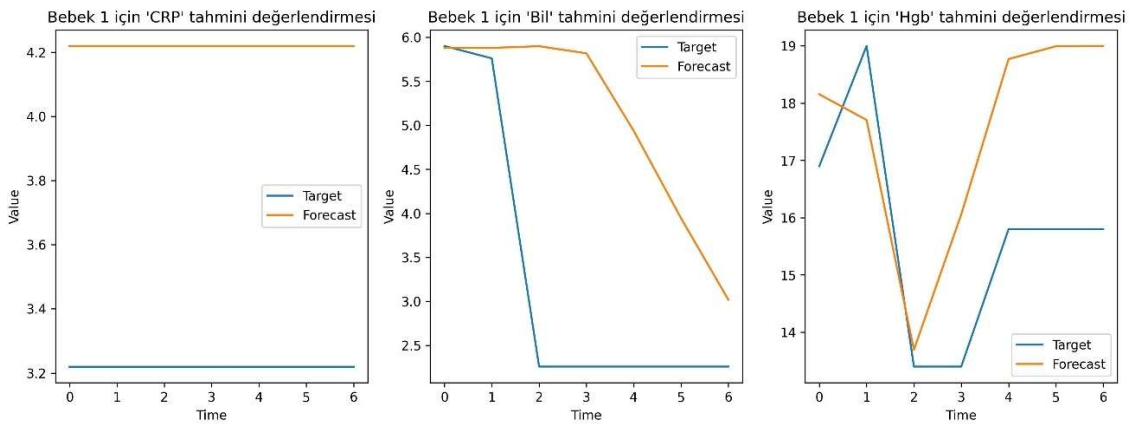
Şekil 4.7. (a) Tahmin 1



Şekil 4.7. (b) Tahmin 2



Şekil 4.7. (c) Tahmin 3



Şekil 4.7. (d) Tahmin 4

Tablo 4.3. LSTM model doğruluk çıktısı değerlendirme tablosu

| Metrik | CRP | Bilirubin | Hemoglobin |
|-----------------------|---------|-----------|------------|
| Ortalama Karesel Hata | 2274.90 | 14.22 | 7.37 |
| R-Kare (%) | 29.09 | 36.36 | 43.63 |

Tablo 4.3'de eğitimi gerçekleştirilen LSTM modelinin test verileri üzerinden gerçekleştirilen değerlendirme metrikleri görülmektedir. Performans değerlendirme tablosu dikkatli incelendiğinde modelin yüksek doğruluk değerlerine ulaşamadığı gözlemlenebilmektedir. Özellikle CRP parametresinin OKH değeri diğer performans değerlerine göre daha olumsuz bir sonuç göstermektedir.

4.2.2. XgBoost ile Zaman Seri Analizi Modeli

Bir önceki bölümde prematüre bebek laboratuvar bulguları geçmiş verilerine bakarak ileriye yönelik tahmin yapan zaman seri analizi yaklaşımıyla değerlendirilmiştir. Xgboost model yaklaşımında sadece laboratuvar bulguları değil bebeklerden elde edilen zaman etiketli medikal parametreler de özellik kümesi olarak çalışmaya dahil edilmiştir. Dahil edilen medikal belirteçler sırasıyla; Ateş, Nabız, Oksijen Satürasyonu ve Solunum Sayısıdır. XgBoost ile zaman seri analizi yaklaşımında veri seti üzerinde yeni ön işlemler gerçekleştirilmiştir.

4.2.2.1. Veri Seti Ön İşleme

Bu çalışma 47 yenidoğan prematüre bebekten alınan 300 adet veri ile gerçekleştirilmiştir. Her bir bebeğe ait veriler zaman etiketleri ile beraber (zaman sayısı x değerlendirilen özellikler x çıktı boyutu) olarak tensör formatında tutulmaktadır. Burada değerlendirilen özellik ve çıktı boyutları her bebek için sabit olsa da zaman sayısı bebeklerde aynı zamanlarda verilerin elde edilememesinden dolayı sabit bir değere sahip değildir. Xgboost model girişi sabit boyutta veri kümeleri ile işlem yapabildiği için veri seti üzerinde farklı ön işleme adımları gerçekleştirilmiştir. Aynı zamanda kısıtla olan veri sayıları bu sayede artırılmıştır. Veri artırma yöntemleri Tablo 4.4’de açıklanmıştır. Veri artırma yöntemleri sonucunda veri sayısı 573’e çıkarılmıştır. Ayrıca zaman etiketleri 7 olarak ayarlanmıştır. Zaman etiketli veri sayısı 7’nin altında kalan bebeklerde sıfır doldurma işlemi gerçekleştirilmiştir. Veri başına eksik zaman etiketleri 0 değerleri ile doldurulmuştur. Zaman etiketli veri sayısı 7 üzerinde olan bebekler için ilk veri noktasından başlayarak 7şerli ve bir kayma adımıyla tüm veriler pencereyerek parçalara ayrılarak alınmıştır. Test verileri veri artırma işlemlerine tabi tutulmamıştır. 70 adet zaman serisi verisi test verisi olarak ayrılmıştır.

Tablo 4.4. Veri Artırma Yöntemi Açıklama

| Parametre | Açıklama | Değer |
|-------------|---|-----------------------------|
| Twtime | Zaman penceresi süresi. Zaman serisi analizlerinde kullanılan zaman aralığını belirler. | 3 (zaman aralığı) |
| C_size | Parça (chunk) boyutu. Verinin küçük parçalara bölünmesinde kullanılan boyutu belirler. | 7 (parça boyutu) |
| Q_level | Kuantizasyon seviyeleri. Veriyi kaç seviyeye böleceğinizi belirler; daha yüksek değerler daha hassas kuantizasyon sağlar. | 10 (kuantizasyon seviyesi) |
| N_scales | Gürültü ölçeği. Veriye eklenecek rastgele gürültünün büyüklüğünü belirler; modelin genelleştirme kabiliyetini artırmak için kullanılır. | 0.01 (gürültü seviyesi) |
| P_size | Yama (patch) boyutu. Veri içinde işlem yapılacak alt birimlerin boyutunu belirler. | 2 (yama boyutu) |
| Cov_windows | Kovaryans penceresi tipi. Kovaryans analizinde kullanılan pencere fonksiyonunu belirler; örneğin, "flattop" kenarlarda minimum etki sağlar. | "flattop" (pencere tipi) |
| Cov_size | Kovaryans penceresi boyutu. Kovaryans analizinde kullanılan pencerenin boyutunu belirler; daha büyük değerler daha yumuşak sonuçlar verir. | 2 (pencere boyutu) |

Çalışmaya dahil edilen 47 bebeğin zaman içerisinde sahip oldukları hastalıkların toplam değerleri Tablo 4.5’de görülmektedir.

Tablo 4.5. Veri elde edilen bebeklerin hastalıkları ve toplam sayıları

| Hastalıklar | Toplam Hastalık Etiketli Veriler |
|-------------|----------------------------------|
| RDS | 124 |
| NEC | 78 |
| Sepsis | 42 |
| Sağlıklı | 73 |
| Pnömotoraks | 17 |
| İKK | 44 |
| Diafragma | 17 |

4.2.2.2. Xgboost Model Yapısı

Xgboost modeli karar ağaçları temelli bir makine öğrenmesi modelidir. Xgboost modellerinde parametre ayarı yapılarak öğrenme oranı, maksimum derinlik, alt veri kümesi değerleri gibi değerler kontrol edilerek en iyi parametreler ile eğitim yapılması sağlanabilmektedir. Bu çalışmada Xgboost modeli için değiştirilebilir parametre ayarı parametre ızgarası oluşturularak gerçekleştirilmiştir. Parametre ızgarasına eklenen değişkenler ve değer aralıkları aşağıda görülen Tablo 4.6'daki gibi ayarlanmıştır.

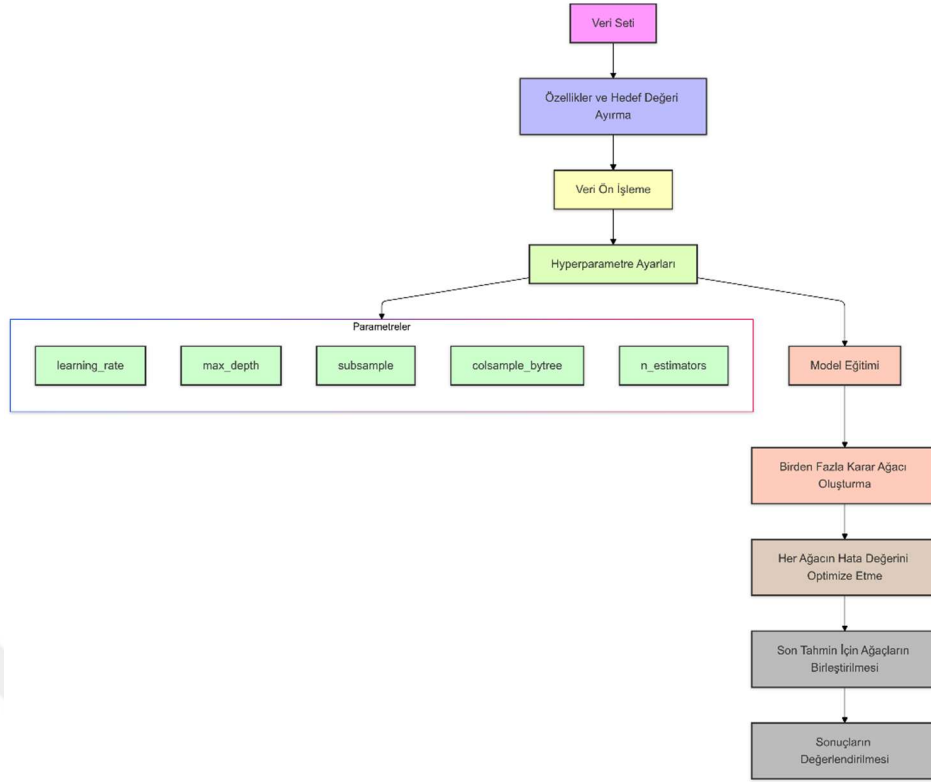
Tablo 4.6. Xgboost parametre ızgarası değişkenleri ve tanımlanan değer aralıkları

| Parametre | Açıklama | Değerler |
|-------------------------|--|------------------|
| Learning_rate | Modelin her iterasyonda öğrenme hızını kontrol eder. | [0.01, 0.1, 0.2] |
| Max_depth | Ağaçların maksimum derinliği. Daha derin ağaçlar daha karmaşık modeller oluşturur. | [3, 5, 7] |
| Sub_samples | Her iterasyonda kullanılan örneklerin oranı. | [0.6, 0.8, 1.0] |
| Colsample_bytree | Her ağacın büyümesinde kullanılan özelliklerin oranı. | [0.6, 0.8, 1.0] |
| n_estimators | Modelde oluşturulan toplam ağaç sayısı. | [100, 200, 300] |

Xgboost CRP, Hemoglobin ve Bilirubin değerlerini ayrı ayrı tahmin ettirecek şekilde 3 ayrı model olarak ayrılmıştır. Modellerin eğitim şablonları aşağıda Şekil 4.8'de görülmektedir. Her model eğitiminden önce değişken parametre ızgara araması yapılarak tespit edilmiştir. Tablo 4.7'de CRP, bilirubin ve hemoglobin için tespit edilen en iyi parametrelere ait tablo görülmektedir.

Tablo 4.7. 3 ayrı model için en iyi parametre değerleri

| Hiper Parametreler | CRP | Bilirubin | Hemoglobin |
|-------------------------|------|-----------|------------|
| learning_rate | 0.01 | 0.01 | 0.01 |
| colsample_bytree | 1 | 1 | 0.6 |
| max_depth | 3 | 7 | 7 |
| n_estimators | 300 | 300 | 300 |
| subsample | 0.6 | 0.6 | 0.6 |



Şekil 4.8. Xgboost modelleri eğitim ve değişken parametre ayarları akış diyagramı

3 ayrı model için eğitim ve validasyon işlemleri gerçekleştirilmiştir. Xgboost modelleri K-Kat Çapraz Doğrulama ile eğitilmiştir. K değeri olarak 5 seçilmiştir. Tablo 4.8’de eğitilen modellerin değerlendirme çıktıları gösterilmiştir.

Tablo 4.8. Modeller için değerlendirme metriği çıktıları

| Değerlendirme Metrikleri | CRP-Model | Bil-Model | Hb-Model |
|------------------------------------|-----------|-----------|----------|
| Ortalama Karesel Hata (Eğitim) | 2213.9848 | 3.3233 | 22.1907 |
| Ortalama Karesel Hata (Validasyon) | 2666.0596 | 9.7588 | 16.7993 |

4.2.3. LSTM ve Dikkat Mekanizması Ağları ile Zaman Seri Analizi

Bir önceki bölümde Xgboost yöntemi uygulanan zaman seri modellerinde girdi değerleri olarak medikal parametrelerin özellik kümesine dahil edildiği belirtilmiştir. LSTM ve Çok-Başlı Dikkat (ÇBD) zaman seri analizi yaklaşımında medikal parametrelere ek olarak bebeklerin doğum gün ve kilo bilgileri, hastanede kalma süreleri ve mevcut teşhisi konmuş hangi hastalıklara sahip olduğuna ait bilgiler de girdi parametresi olarak veri setine eklenmiştir. LSTM-ÇBD modelinde veri artırma yöntemlerinde değişikliğe gidilmiştir.

4.2.3.1. Veri Seti Ön İşleme

Bu çalışmada 47 adet yenidoğan prematüreden elde edilen verilerden oluşturulan bir veri seti kullanılmıştır. Girdi özellik kümesine eklenen yeni parametreler ile birlikte her bir zaman serisi girdi yapısı şu formatta görülmektedir; (n x zaman adımı x girdi özellikleri). Girdi özelliklerine medikal parametrelere ek olarak bebeklerin doğum ağırlığı, doğum günü, yaşı (gün) ve bebeklerin bu parametreler alınırken kaydedilen hastalıkları (sağlıklı, rds, nec, ikk, sepsis, diafragma) bilgileri eklenmiştir. Hastalık dağılımları Tablo 4.5’de görülmektedir. Veri tahmini için zaman adımı 3 olarak belirlenmiştir. 47 bebeğe ait kaydedilen zaman etiketli verilerde bazı bebeklerde 3 zaman adımından daha fazla günde veri kaydedildiği gözlenmiştir. Belirlenen 3 zaman adımında verileri oluşturmak için zaman kaydırma yöntemi uygulanmıştır. Kaydırma adımı 1 olarak seçilmiştir. Bu sayede 47 bebekten elde edilecek zaman etiketli veri sayısı 146’ya çıkarılmıştır. Çalışmada ileriye yönelik tahmin edilmeye çalışılan değerler CRP, Bilirubin ve Hemogloblin değerleridir. Burada bir bebeğe ait veriler $\{x_0, x_1, x_2 \dots x_T\}$ olarak kabul edilirse T toplam veri sayısı olacaktır. Giriş değerleri her i değeri için aşağıdaki denklikte görüldüğü şekilde hesaplanmaktadır.

$$X_i = \{x_{i+1}, x_{i+2}, x_{i+3}\} \in \mathbb{R}^{3 \times 14} \quad (4.1)$$

Her i değeri için hedef CRP, Bilirubin ve Hemogloblin değerleri aşağıdaki şekilde hesaplanır.

$$Y_i = \begin{cases} y_{i+4} \in \mathbb{R}^3, & \text{eğer } i + 4 \leq T \\ y_{i+3} \in \mathbb{R}^3, & \text{eğer } i + 3 > T \end{cases} \quad (4.2)$$

İleriye yönelik tahmin yapıldığı için eğer zaman ifadesi dörtten büyük veya eşitse zaman adımıdaki değer dördüncü değer hedef değer olarak alınır. Dörtten küçükse üçüncü değer hedef değeri olarak alınmaktadır.

Veri artırma yöntemi olarak gürültü ekleme ve zaman saptırma, büyüklük kaydırma ve rastgele örnekleme yöntemleri kullanılmıştır. Tablo 4.9’da uygulanan veri artırma yöntemleri detaylı olarak açıklanmıştır.

Tablo 4.9. Uygulanan veri artırma yöntemleri

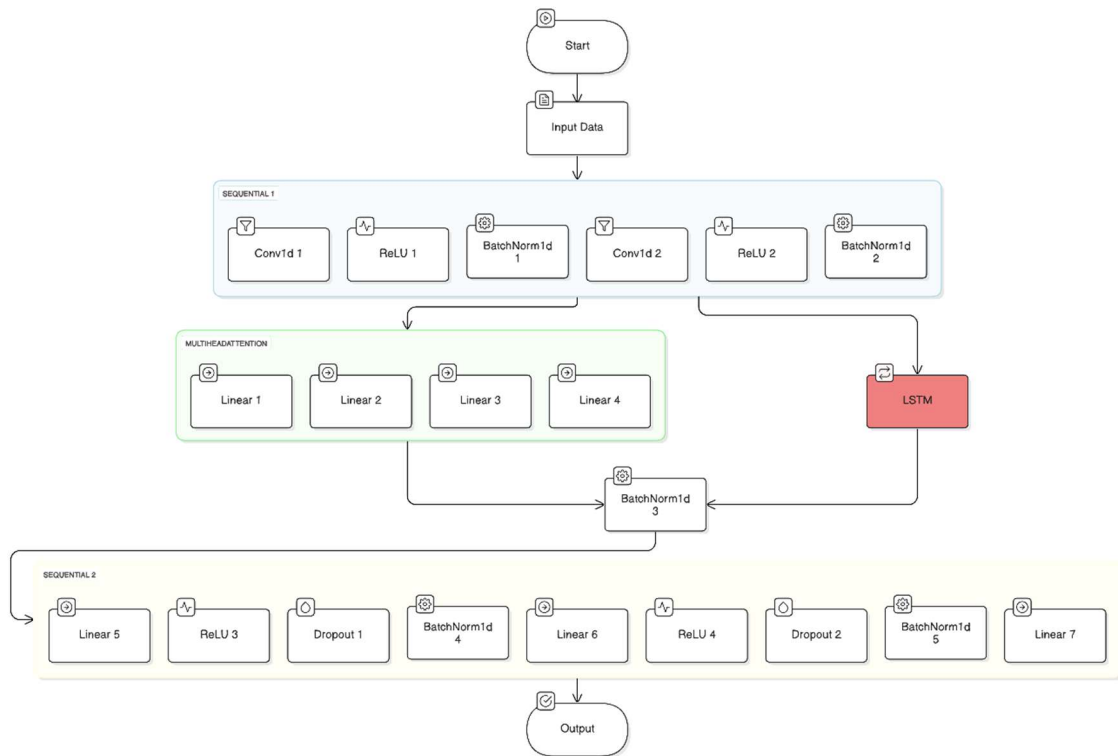
| Yöntem | Açıklama |
|--------------------|--|
| Gürültü Ekleme | Her bir orijinal veri örneğine ek olarak “ <i>n_örnek</i> ” adet gürültülü kopya eklenir. Burada ortalaması 0, standart sapması 0.01 olan normal dağılımdan rastgele değerler eklenerek veride çeşitlilik yaratılır. |
| Zaman Saptırma | Zaman ekseninde, her zaman adımını -0.5 ile $+0.5$ aralığında rastgele kaydırır. Bu sayede zaman boyutundaki varyasyon artırılarak modelin daha genelleştirilmiş bir şekilde öğrenmesi hedeflenir. |
| Büyüklük Kaydırma | Verinin genlik değerlerini, her özelliğe farklı bir ölçek faktörü (0.9 ile 1.1 arasında) çarparak yeniden düzenler. Böylece her bir özelliğin büyüklüğünde hafif rastgele değişiklik sağlanır. |
| Rastgele Örnekleme | Veri penceresinde ($pencere_boyutu = len(X[i])$) rastgele bir başlangıç noktası belirleyerek veriyi kırpar. Böylece orijinal dizinin farklı alt segmentleri ile ek örnekler üretilir. |

Veri artırma adımları 10 kez tekrar edilmiş ve 146 olan veri sayısı kademeli olarak 1752’ye çıkarılmıştır. Veri artırılmadan önce 39 adet veri test verisi olarak ayrılmıştır. Test olarak ayrılan veriler eğitim işlemlerine dahil edilmemiştir.

4.2.3.2. LSTM-ÇBD Model Mimarisi ve Model Eğitimi

Bu çalışmada oluşturulan derin öğrenme modeli sıralı olarak çalışan az parametrelili bir LSTM ve dikkat mekanizması yapısındadır. Model eğitiminde veriler (yığın boyutu, zaman damgası, özellikler) şeklinde girdi olarak hazırlanmıştır. Girdi verileri ilk olarak konvolüsyonel tabanlı bir özellik çıkarımı bloğuna sokulmaktadır. Bir boyutlu bir konvolüsyondan geçen girdiler 14 özellik boyutu 64 olarak artırılır. Bu sayede girdi özellikleri daha düşük seviyede özelliklere dönüştürülür. Sırasıyla gelen aktivasyon

fonksiyonu ve yığın normalleştirme katmanlarından sonra tekrar $64 \rightarrow 64$ konvolüsyonel işleme sokularak özellik seviyelerinden daha yüksek seviyede öğrenilmesi sağlanmaktadır. Özellik çıkarımından sonra zaman adımlarına daha fazla ağırlık vermek amacıyla ÇBD mekanizmasına gönderilmektedir. “Head” değeri 4 ve “head_size” 32 olarak ayarlanmıştır. ÇBD bölümüne paralel olarak hem geçmiş hem gelecek zaman adımları arasında anlamsal ilişkiyi daha iyi anlamak için LSTM bloğu eklenmiştir. LSTM ve ÇBD blok çıktıları birleştirilerek yığın normalleştirme katmanına sokulmaktadır. Çıkış verisi için sırasıyla düzleştirilerek tam bağlı katmana eklenmektedir. Şekil 4.9’da model mimarisi diyagramı görülmektedir.




Şekil 4.9. LSTM-ÇBD Model Mimarisi

Model 1000 epoch boyunca eğitilmiştir. Yığın boyutu 16 olarak seçilmiştir. Optimizasyon yöntemi olarak AdamW (Adam with Weight Decay) optimizasyon yöntemi seçilmiştir. Öğrenme oranı başlangıçta 0.001 seçilmiş ve ağırlık bozumu 0.01 belirlenmiştir. AdamW, öğrenme sürecinde her adımda momentuma dayalı güncellemeler yaparken ağırlıkların büyümesini engellediği için tercih edilmiştir. Öğrenme oranı planlayıcısı eğitim aşamasına eklenmiştir. Öğrenme oranı dinamik olarak ayarlanmakta olup, “Cosine Annealing Warm Restarts” yöntemi uygulanmıştır. Modelin gradyan patlamasından korunması için gradyanlar 1.0 ile sınırlandırılmıştır. Oluşturulan model mimarisi 272,963 parametreye sahiptir. Bu oldukça hafif bir model olduğunu


göstermektedir. Model eğitimi sonuçları test veri seti üzerinden Tablo 4.10'da görülmektedir. Performans değerleri incelendiğinde modelin hafif bir yapıya sahip olmasına rağmen performans metriklerinin yüksek doğrulukta olduğu görülmektedir. Özellikle CRP değerleri %91.78 ile yüksek R-Kare doğruluğu gösterdiği görülmektedir. Şekil4.10'da model çıktıları örnek test verileri üzerinden görülmektedir.

Tablo 4.10. LSTM-ÇBD modeli doğruluk çıktıları değerlendirme tablosu


| Metrik | CRP | Bilirubin | Hemoglobin |
|---------------------------|----------|-----------|------------|
| Ortalama Karesel Hata | 234.9969 | 7.1309 | 2.6664 |
| R-Kare (%) | 91.78 | 66.76 | 77.62 |
| Kök Ortalama Karesel Hata | 58.5951 | 5.5971 | 2.5321 |



Şekil 4.10. (a) Tahmin 1



Şekil 4.10. (b) Tahmin 2



Şekil 4.10. (c) Tahmin 3

4.3. Zaman Seri Analizi Yöntemleri Çıktılarının Karşılaştırması

XGBoost, LSTM ve LSTM-ÇBD modelleri arasında yapılan değerlendirmelerde, OKH değerleri tüm model için de karşılaştırılabilir şekilde hesaplanmıştır. CRP tahmininde LSTM-ÇBD modeli 234.9969 OKH ile en düşük hata oranına sahiptir, LSTM modeli için bu değer 2274,90 ve XGBoost için 2666.0596 olarak hesaplanmıştır. Bu sonuçlar, XGBoost ve LSTM modellerinin CRP tahmininde benzer ve kötü bir performans sergilediğini gösterirken LSTM-ÇBD modeli iyi performans göstermiştir. Bilirubin tahmininde LSTM-ÇBD, 7.1309 OKH ile en düşük hata metriğini sunarken, LSTM modeli 14.22 OKH ile en yüksek hata oranına sahiptir. Hemoglobin tahmininde ise LSTM-ÇBD test sırasında elde ettiği OKH değeri 2.6664 iken, LSTM modeli için bu değer 7.37 ve XGBoost için 16.7993 olarak hesaplanmıştır. Bu durum, tüm parametrelerde olduğu gibi hemoglobin tahmininde de LSTM-ÇBD modelinin diğer modellerden daha başarılı olduğunu ortaya koymaktadır.


LSTM-ÇBD modelinin R-kare skorları incelendiğinde, CRP, Bilirubin ve Hemoglobin tahminlerinde sırasıyla %91.78, %66.76 ve %77.62 değerlerine ulaşmıştır. Bu sonuçlar, LSTM-ÇBD modelinin CRP tahminlerinde özellikle güçlü olduğunu Hemoglobin değerlerinin tahmininde yüksek performans gösterdiğini ve Bilirubin tahmininde kabul edilebilir doğruluk değerlerine ulaştığı gözlenmiştir.

Genel olarak, LSTM ve XGBoost modelleri CRP tahmininde ciddi zorluklar yaşandığı ve model performanslarının düşük kaldığı gözlenirse de LSTM-ÇBD model yaklaşımı CRP tahminlerini ciddi oranda iyileştirmiştir. Bilirubin ve hemoglobin performans değerleri LSTM-ÇBD modelinin diğer iki model sonuçlarını geliştirecek şekilde daha yüksek R-Kare değeri sağladığı ve daha düşük OKS değeri yakaladığı kaydedilmiştir. LSTM-ÇBD modeli diğer iki modelden de daha üstün sonuçlar elde etmiştir. Bu bulgular, dikkat yaklaşımının zaman seri analizi problemimize daha iyi uyum sağladığını göstermektedir.

4.4. Hiperspektral Verilerde Zaman Seri Analizi Verilerinin Elde Edilmesi

Yenidoğan prematüre bebeklere ait hiperspektral veriler TÜBİTAK – 1001-Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı (Proje No: 122E021) kapsamında Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesindeki yenidoğanlardan elde edilmiştir. Proje araştırması, Etik Kurul Onayı (2022/125) ile elde edilmiştir. Etik kurulu raporu EK-1’de verilmiştir.


Yenidoğan prematüre bebeklerin düzenli aralıklarla hiperspektral verileri zaman damgaları atanarak kaydedilmiştir. Çekim süreci boyunca 47 bebekten 526 adet hiperspektral veri elde edilmiştir. Hiperspektral veriler ile birlikte bebeğin çekim yapılan tarihte sahip olduğu hastalıklar da kaydedilmiştir. Bebeklerin hastalık teşhisi bilgileri ilgili doktorları ve sağlık çalışanları tarafından kaydedilmiştir. Hiperspektral veri görüntülemeye noktasal bir spektrometre olan Broadcom Qmini VIS/NIR – Miniature USB Spectrometer (AFBR-S20M2VN) spektrometresi kullanılmıştır. Bu spektrometre ile 440-1110nm dalga boyu aralığında veri kaydedilebilmektedir. Her bir bebekten bir çekimde 100 adet spektral örnek alınıp kaydedilmiştir. Şekil 4.11’de örnek bir hiperspektral veri görülmektedir.



Şekil 4.11. Sağlıklı bir bebeğe ait hiperspektral veri

Spektrometre kaynaklı olarak elde edilen dalga boyu yansıma verilerinde 500nm altı ve 1000nm üstü dalga boylarında yüksek gürültü olduğu görülmektedir. Bu yüzden tüm veriler 500-1000nm dalga boyu aralığında kırılmıştır. Aynı zamanda sinyaller üzerindeki gürültülerin giderilmesi için savitzky-golay yumuşatma filtresi uygulanmıştır.

Şekil 4.12’de 500-1100nm aralığında kırılmış ve yumuşatılmış bir hiperspektral veri görülmektedir.



Şekil 4.12. 500-1000nm aralığında kırılmış ve yumuşatılmış sinyal

4.5. Hiperspektral Veriler ile İleriye Yönelik Hastalık Tahmini Modelleri

Yukarıda başlıklarda bebeklere ait hiperspektral verilerin elde edilmesi süreci detaylı olarak anlatılmıştır. Her bir çekimde 100 ayrı noktadan spektral veriler kaydedilmiştir. Bu 100 hiperspektral veriler 10x10 boyutuna getirilerek hiperküpler halinde kaydedilmiştir. Spektral aralık 500-1000nm aralığında kırıldığı için 1538 adet dalga boyundan yansıma değeri kaydedilmiştir ve bu sayede kaydedilen hiperküpler 10x10x1538 boyutunda oluşmuştur. Her bir bebek en az 3 zaman damgasında veriye sahiptir. Bu yüzden bebeklere ait hiperspektral veriler ardışık sırada ve kayma değeri bir olacak şekilde 3 pencere boyutunda parçalara ayrılmıştır. Bu işlem sonucunda 560 veriye sahip veri seti oluşturulmuştur. Bu eğitim verilerinin 93 tanesi test için ayrılmıştır diğer 467 veri eğitim için ayrılmıştır. Model giriş tensörleri zaman damgalı hiperküplerden oluşurken hedef değerleri bebeklerin hastalık etiketleri olarak atanmıştır. Her üç zaman adımı sonrası bebeklerin hastalık teşhisleri (veya sağlıklı durumu) hedef değer olarak kaydedilmiştir. Bebekler hedef değer olarak kaydedilen dördüncü zaman adımında birden fazla hastalığa sahip olabilmektedir. Bu yüzden hedef değerleri “One-Hot Encoder” yöntemi ile binary olarak kodlanmıştır. Verileri kaydedilen bebeklerin hastalıklarına ait dağılım Tablo 4.11’de görülmektedir.

Tablo 4.11. Hiperspektral verisi alınan bebeklerin hastalık dağılımları

| Hastalıklar | Toplam Hastalık Etiketli Veriler |
|-------------|----------------------------------|
| NEC | 67 |
| Sağlıklı | 222 |
| RDS | 72 |
| Sepsis | 72 |
| IKK | 44 |
| Diyafragma | 31 |
| Pnömotoraks | 38 |

Diyafragma ve pnömotoraks hastalığına sahip veriler diğer hastalık değerlerine göre dağılımın altında kalmıştır. Bu hastalığa ait veriler değerlendirmeden çıkarılmıştır. Sağlıklı veriler ile diğer hastalık verilerinin veri setinde denge problemi yaratmaması için veri artırma yöntemlerine başvurulmuş ve hastalık dağılımını normalize edecek şekilde ayarlanmıştır. Gaussian gürültü ekleme, spektral eğrinin yansıma değerleri yönünde yukarı aşağı kaydırma ve $10 \times 10 \times 1538$ olarak oluşturulmuş hiperküplerin uzaysal düzlemde rastgele döndürülmesi işlemleri veri artırma yöntemleri olarak uygulanmıştır. Tablo 4.12’de veri artırma yöntemleri ve açıklamaları yer almaktadır.

Tablo 4.12. Veri artırma yöntemleri ve açıklamaları

| Yöntem | Açıklama | Amaç |
|-------------------|--|--|
| Gaussian Gürültü | Hiperspektral bantlara düşük seviyede normal dağılımlı gürültü eklenir | Gürültüye dayanıklı model eğitimi |
| Yoğunluk Kaydırma | Spektral eğrinin tamamı yukarı/aşağı kaydırılır | Sensör varyasyonlarını ve aydınlatma değişimini simüle etmek |
| Uzaysal Döndürme | Uzaysal düzlemde yamalar rastgele döndürülür | Uzamsal yapı varyasyonu kazandırmak |

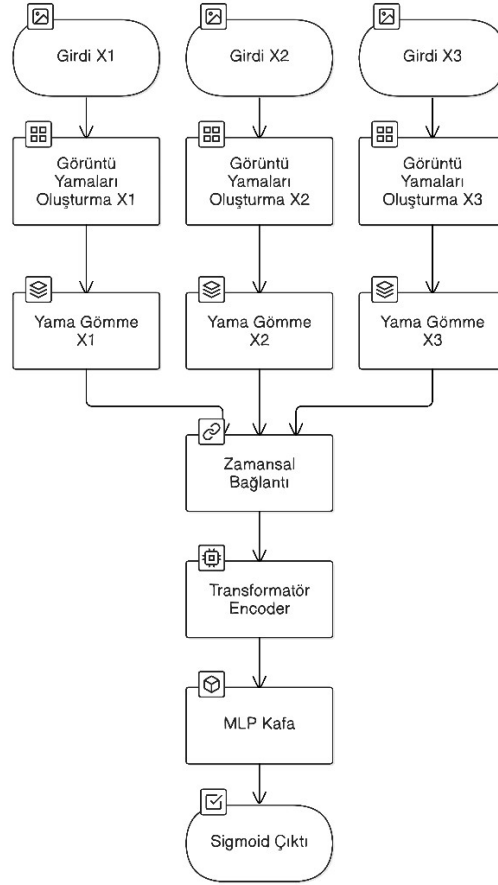
Eğitim verilerinde hedef çıktılar olan hastalıkların veri dağılımını dengelemek için her bir veriye en fazla 3 kez olacak şekilde veri artırma uygulanmıştır. Veri artırma işlemi sonucunda veri sayısı 1239’a yükseltilmiştir. Tablo 4.13’de görüldüğü gibi daha dengeli etiketli veriye sahip veri seti elde edilmiştir.

Tablo 4.13. Veri artırma sonrası etiketli veri dağılımı

| Hastalıklar | Toplam Hastalık Etiketli Veriler |
|-------------|----------------------------------|
| NEC | 264 |
| Sağlıklı | 429 |
| RDS | 288 |
| Sepsis | 284 |
| IKK | 168 |

4.5.1. Görü Dönüştürücü ile TBA Uygulanmamış Hiperspektral Verilerde Hastalık Tahmini

Görü Dönüştürücüler görüntülerin yamalara bölünüp gömme vektörleri haline getirilerek transformatör modellerde işlenebildiğini gösteren ağlardır. Bu çalışmada her biri 10x10x1538 boyutundaki hiperspektral veri bir yama olarak kodlanmıştır. Zaman damgası ardışık gelen 3 adet veriye ait her yama görü dönüştürücünün yama gömme işlemi ile düzleştirilmiştir. Pozisyonel gömme ifadesinde görüntünün sırasını zaman adımları temsil etmektedir. Bu sayede bu çalışmada hiperspektral veriler ile görü dönüştürücü modelin zaman seri analizi modeli haline getirilmesi sağlanmıştır. Oluşturulan model yapısı Şekil 4.13'de görülmektedir.




Şekil 4.13. Geliştirilen Görü Dönüştürücü model akış diyagramı

Her bir hiperspektral veri görüntü yamaları haline getirildikten sonra yama gömme işleminde vektörize hale getirilmektedir. Bu gömme işleminde gömme büyüklüğü 128 olarak belirlenmiştir. Bu gömme vektörleri transformatör kodlayıcı ağı modellerinin doğal dil işleme alanında kelimeleri tokenize ettikten sonra yaptığı gömme işleminin aynısıdır. Görü Dönüştürücülerde yamalara bölünen görüntülerde her bir yama görüntüsü pozisyonel olarak da kodlanır. Bu sayede yamalar içerisinde elde edilen özelliklerin orijinal görüntüde hangi konumda olduğu veya hangi komşu yamalar ile etkileşimde olduğu lokalize edilebilmektedir. Bu çalışmada gerçekleştirilen görü dönüştürücü ağda her bir yama görüntüsü bir hiperküp olduğu için pozisyonel bilgi vektörü zaman etiketlerini temsil etmektedir. Bu sayede bu transformatör ağ bir zaman seri modeli haline getirilmiştir. Transformatör encoder birimi 8 dikkat başı ve baş için 16 ağ birimi oluşturulmuştur. Encoder birimi çıkışı “Çok Katmanlı Algılayıcı” girişine bağlanarak model sınıflandırma görevine hazır hale getirilmiştir. Model K-Katlı Çapraz doğrulama yöntemi ile eğitilmiştir. K değeri 5 olarak seçilmiştir. Her bir çapraz doğrulamada epoch sayısı 200 ve paket boyutu 4 olarak belirlenmiştir. Optimizasyon

yöntemi olarak Adam optimizasyon algoritması kullanılmıştır. Öğrenme oranı başlangıçta 0.001 olarak seçilmiş ve öğrenme oranı planlayıcısı zamanla azalacak şekilde tanımlanmıştır. Tablo 4.14’de model ve eğitim parametreleri detaylı olarak görülmektedir. Şekil 4.14’de çapraz doğrulama son aşamadaki eğitim kaybı ve doğrulama metrikleri görülmektedir.

Tablo 4.14. Model ve eğitim parametreleri

| Parametre | Değer |
|------------------------------|----------------------------|
| Epoch | 200 |
| K-Katlı Çapraz Doğrulama (K) | 5 |
| Paket Boyutu | 4 |
| Başlangıç Öğrenme Oranı | 0.001 |
| Ağırlık Azalma Oranı | 1e-4 |
| Optimizasyon Yöntemi | Adam |
| Zamanlayıcı | Cosine Annealing |
| Kayıp Fonksiyonu | Binary Cross Entropy Kaybı |
| Dikkat Başlığı | 8 |
| Başlık Boyutu | 16 |
| Gömme Büyüklüğü | 128 |
| Aktivasyon Fonksiyonu | GELU |
| Çıktı Aktivasyonu | Sigmoid |
| GFlops | 0.2183 |
| Parametre Sayısı | 22.489.862 |



Şekil 4.14. K-Katlı Çapraz Doğrulama son aşama eğitim kaybı ve doğrulama metriği sonuçları

Model eğitimi gerçekleştirildikten sonra ayrılan test seti üzerinden yapılan model değerlendirmesi sonuçları Tablo 4.15’de görülmektedir.

Tablo 4.15. Hiperspektral Görü Dönüştürücü (HSViT) eğitim değerlendirme çıktıları

| | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|-------|-----------------|-----------------|-------------------|----------------|
| HSViT | 0.9742 | 0.8931 | 0.9878 | 0.9362 |

4.5.2. Görü Dönüştürücü ile TBA Uygulanmış Hiperspektral Verilerde Hastalık

Tahmini

Yukarıdaki Hiperspektral Görü Dönüştürücü yaklaşımında 500-1000nm aralığındaki tüm dalga boyları hiperküp de derinlik olarak temsil edilmektedir. Tüm dalga boylarının hiperküpe dahil edilmesiyle çok yüksek boyutlu veri kümesi oluşmuştur. Bu yüksek boyutlu veri kümesi ile yapılan model eğitimi hesaplama yükünü artırmaktadır. Bu sorunu minimize etmek ve model performansını artırmak amacıyla farklı komponent seviyelerinde TBA uygulanarak veri boyutu düşürülmüştür. Uygulanan komponent seviyeleri sırası ile 5, 50 ve 100 olarak belirlenmiştir. Tablo 4.14’de görülen model ve eğitim parametreleri korunarak sırasıyla TBA uygulanan veri setleri ile eğitimler gerçekleştirilmiştir. Tablo 4.16’da TBA komponent seviyesi sırasıyla 5, 50 ve 100 olan modellerin test seti üzerinden yapılan değerlendirme sonuçları görülmektedir.

Tablo 4.16. TBA Uygulanan Hiperspektral Görü Dönüştürücü (HSViT) modelleri eğitim değerlendirme çıktıları

| | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|--------------|-----------------|-----------------|-------------------|----------------|
| HSViT_TBA5 | 0.8839 | 0.6681 | 0.6741 | 0.6617 |
| HSViT_TBA50 | 0.9892 | 0.9648 | 0.9950 | 0.9795 |
| HSViT_TBA100 | 0.9892 | 0.9457 | 0.9875 | 0.9639 |

Değerlendirme sonuçları incelendiğinde en yüksek doğruluk değerlerini komponent sayısı 50 olarak belirlenmiş HSViT_TBA50 modeli göstermiştir.

4.6. Hiperspektral Verilerde Hastalık Tahmini Modelleri Karşılaştırma

Bu çalışmada hiperspektral görüntüleme ile elde edilen yenidoğan prematüre bebeklerin zaman etiketli hiperspektral verileri ile ileriye yönelik hastalık tahmini yapan görü dönüştürücü tabanlı yapay zeka modelleri geliştirilmiştir. Eğitilen tüm model mimarileri aynı ve Şekil 4.13’de görülmektedir. Eğitilen 4 ayrı modelde HSViT modeli için ham hiperspektral hiperküpler kullanılırken, HSViT_TBA5, HSViT_TBA50, HSViT_TBA100 modelleri TBA sonrası sırasıyla 5, 50, 100 bileşene indirgenmiş veriler ile eğitilmiştir. Eğitim sonuçları karşılaştırıldığında HSViT_TBA50 modeli tüm değerlendirme parametrelerinde en yüksek genel performans değerini göstermiştir. Bu

durum, hiperspektral verinin aşırı boyutluluğunun azaltılmasının modeli aşırı öğrenmeden koruyarak daha genellenebilir sonuçlar ürettiğini kanıtlamaktadır. Model sonuçları incelendiğinde en düşük performansı HSViT_TBA4 modelinin gösterdiği görülmektedir. Bu durum, sadece 5 bileşene indirgenen verinin modelde yeterli temsil gücüne ulaşamadığını ve kritik spektral bilgilerin kaybolmasına yol açtığını göstermiştir.



5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu tez çalışmasında yenidoğan prematürelere ön teşhis ve vaka yönetim sistemleri için dijital ikiz yaklaşımları ile çözümler önerilmiştir. Vaka yönetimi için bebeklerin düzenli olarak takip edilen medikal parametreleri ve kan tahlili sonuçları olan laboratuvar bulguları ve bebeklerden elde edilen hiperspektral görüntüleme verileri üzerine çalışılmıştır. Laboratuvar bulguları tahmininde zaman seri analizi yöntemlerinden faydalanarak CRP, bilirubin ve hemoglobin değerlerini ileriye yönelik tahmin eden ve tahmin değerlerini bebeğin geçmiş laboratuvar bulguları ve medikal parametrelerinden öğrenen modeller geliştirilmiştir. Zaman seri analizi yöntemleri olarak LSTM temelli derin öğrenme yaklaşımı, Xgboost makine öğrenmesi algoritması ve paralel LSTM ve ÇBD mekanizması model mimarilerinden faydalanılmıştır. Hiperspektral görüntüleme verileri ile bebeklerin geçmiş hiperspektral çekimlerine bakarak ileriye yönelik hastalık tahmini yapan yapay zeka modelleri geliştirilmiştir. Zaman etiketli hiperspektral veriler için özelleştirilmiş görü dönüştürücü tabanlı modeller geliştirilmiştir. Geliştirilen yapay zeka modelleri ile desteklenen prematüre bebeklerin dijital ikizleri bebeklerin farklı teşhis veya tıbbi müdahalelere karşı vücudunun vereceği tepkilerin simüle edilebilmesini ve izlenebilmesini desteklemektedir. Bu kapsamda yenidoğan prematürelere dijital ikiz yaklaşımı ile vaka yönetimi yaklaşımı literatürde ilk olarak görülmektedir.

Veri toplama süreci boyunca toplam 47 bebekten 300 adet laboratuvar bulgusu ve 560 hiperspektral veri zaman etiketli olarak elde edilmiştir. Bebeklerin verileri tutulurken aynı zamanda ilgili doktorları ve sağlık personeli ile görüşerek mevcut hastalıkları da kaydedilmiştir. Takip edilen bebekler İKK, Sepsis, pnömotoraks, RDS, NEC ve sağlıklı olmak üzere bir veya birden çok hastalık durumunu taşıması göz önünde bulundurularak not edilmiştir. İlk olarak 22 bebek üzerinde çalışılan LSTM tabanlı zaman seri analizi modeli geliştirilmiştir. Bebeklerin veri dağılımları dengesiz olduğu için en az 5 en fazla 15 zaman verisi içeren bebekler çalışmaya dahil edilmiştir. Bu filtreleme ile kalan 17 bebeğin her zaman serisi LSTM modelinde eğitilmiştir. Bunun sonucunda LSTM model mimarisi OKH ve R-kare skoru ile değerlendirilmiştir. CRP değeri 2274.90 OKH ve %29.09 R-kare skoru ile en düşük performansı göstermiştir. Bilirubin 14.22 OKH ve %36.36 R-kare ve hemoglobinin 7.37 OKH ve %43.63 R-kare skoru elde etmiştir. Hemoglobin değeri en yüksek temsil gücüne erişirken model CRP değerini temsil

etmekte zorlanmıştır. Xgboost yaklaşımında CRP, hemoglobin ve bilirubin için 3 ayrı model eğitilmiştir. Model eğitiminde sadece bu laboratuvar bulgularının geçmiş değerleri değil ateş, nabız, oksijen saturasyonu ve solunum sayısı medikal parametreleri de özellik olarak eklenmiştir. Model hiper parametreleri parametre ızgarası ile seçilmiş ve K-kat çapraz doğrulama ile eğitim işlemi yapılmıştır. 47 bebeğe ait veriler veri artırma yöntemlerine tabi tutularak 573'e çıkarılmış ve zaman adımı sayısı 7 olarak ayarlanmıştır. Model eğitimi sonucunda CRP değeri 2666.0596 OKH ile LSTM'de olduğu gibi en düşük performansı göstermiştir. Bilirubin 9.7588 OKH ve hemoglobin 16.7993 OKH değerlerini almıştır. Bilirubin için model doğruluğu LSTM'e kıyasla daha iyi sonuç elde ederken hemoglobinde LSTM daha iyi sonuç almıştır. CRP iki modelde de temsil gücüne erişememiştir. LSTM-ÇBD modelinde 47 bebekten elde edilen 146 zaman etiketli veri ile eğitim gerçekleştirilmiştir. Model performansı OKH ve R-Kare skoru ile değerlendirildiğinde; CRP tahmininde OKH 234.9969 ve R-Kare skoru %91.78, bilirubin için OKH 7.1309 ve R-Kare skoru %66.76 ve hemoglobin için OKH 2.6664 ve R-Kare skoru %77.62 olarak kaydedilmiştir.

Elde edilen çıktılar incelendiğinde tüm çıktı parametreleri için en yüksek doğruluk ve en düşük hata değerlerini LSTM-ÇBD modelinin gösterdiği görülmektedir. CRP için R-Kare skorunun daha yüksek olmasına rağmen OKH değerinin diğer değerlere göre fazla hata değerine sahip olmasının sebebi CRP değerlerinin daha yüksek ortalamada veriye sahip olmasıdır. Bu sayede CRP değerlerindeki hata payları daha yüksek oranda cezalandırılmaktadır. Modellerin yüksek doğruluk değerlerine çıkmasına rağmen daha yoğun veri elde edilmesi ve veri sıklığının artırılması ile modellerin daha iyi temsil gücüne erişeceği düşünülmektedir.

Hiperspektral görüntüleme ile elde edilen zaman etiketli hiperküpler ile görü dönüştürücü tabanlı modeller eğitilmiştir. Veri seti yaklaşımı olarak ham veriler ile (HSViT) ve TBA uygulanarak sırasıyla 5, 50 ve 100 bileşene indirgenen veri setleri ile (HSViT_TBA5, HSViT_TBA50, HSViT_TBA100) eğitim yapılan modeller geliştirilmiştir. Bu modellerde HSViT_TBA5 modeli %88.39 doğruluk değerine erişmesine rağmen kesinlik %66.81, duyarlılık %67.41 ve F1-Skor %66.17 ile en düşük performansı gösteren model olmuştur. HSViT_TBA50 modeli ise %98.92 doğruluk, kesinlik %96.48, duyarlılık %99.50 ve F1-Skor %97.95 ile her değerlendirme kriterinde en yüksek doğruluk seviyesine ulaşmıştır. Görü Dönüştürücü modellerinin görüntü yamalama işleminin zaman seri analizi yaklaşımlarında zaman etiketli veriler olarak kullanılması yeni bir yaklaşım olarak kaydedilmiştir.

5.2 Öneriler

Bu tez çalışmasında elde edilen parametreler YYBÜ'nde kalan prematüre ve çoğunluğu hasta olan bebeklerden elde edilmiştir. Çalışma sürecinde sağlıklı bebek takibi gerçekleştirilemediği için zayıf solunum sıkıntısı çeken bebekler sağlıklı olarak kabul edilmiştir. Bunun için çalışmanın kapsamının genişletilip yenidoğan prematürelerin yanı sıra normal süreçte doğan sağlıklı bebeklerden elde edilecek verilerin de eklenmesi gerektiği düşünülmektedir. Bu sayede çalışmanın veri çeşitliliği ve kontrol grubunun sağlamlığı artırılacaktır.

Kan tahlilleri prematüre bebeklerin zayıf fiziksel yapısı, kansızlık sorunları ve acite olmaları sebebi ile zorunlu olunmadıkça yapılmamaktadır. Bu sebeple projede elde edilen laboratuvar bulguları bazı bebeklerde sıklıkla zaman içinde kendini tekrar eden aynı değerleri almaktadır. Bu nedenle, çalışmanın veri toplama süreci uzatılarak laboratuvar bulgularının yeni elde edildiği süreçlere gelecek şekilde zaman adımlarının ayarlanması ve birbirini tekrar eden veri gruplarından kaçınılmasını sağlanması önerilmektedir.

Gelecek dönem çalışmalarında noktasal spektrometre ile elde edilen hiperspektral veriler yerine satır tarama spektrometreleri ile elde edilecek görüntüler ile çalışılması hedeflenmektedir. Bu sayede geliştirilecek modellerin sadece spektral bantlar arası elde edilen yoğunluk değerleri üzerinden değil hiperspektral görüntü üzerindeki uzamsal ilişkileri de çıkarılması sağlanarak hastalığın olduğu bölgelerin sıcaklık haritaları ile lokalize edilebilmesi amaçlanacaktır.

KAYNAKLAR

- Bhutani, V.K., Wong, R.J., 2013, Bilirubin Neurotoxicity in Preterm Infants: Risk and Prevention, *Journal of Clinical Neonatology*, 2(2), 61-69.
- Bettine, G.W., Jagt, M.B.H., Wouter, H., Frans, N.V., 2022, A review study of fetal circulatory models to develop a digital twin of a fetus in a perinatal life support system, *Frontiers in Pediatrics*, 10.
- Björnsson, B., Borrebaeck, C., Elander, N., Gasslander, T., Danuta, R.G., Mika, G., Jörnsten, R., Lee, E.J., Li, X., Lilja, S., Martínez-Enguita, D., Matussek, A., Sandström, P., Schäfer, S., Stenmarker, M., Sun, X.F., Sysoev, O., Zhang, H., Benson, M., 2019, Digital twins to personalize medicine, *Genome Medicine*, 12(4).
- Borowski, P.F., 2021, Digitization, Digital Twins, Blockchain, and Industry 4.0 as Elements of Management Process in Enterprises in the Energy Sector, *Energies*, 14(7).
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., 2015, Time Series Analysis: Forecasting and Control, Wiley, Germany.
- Chiesa, C., Natale, F., Pascone, R., Osborn, J.F., Pacifico, L., Bonci, E., De Curtis, M., 2011, C-reactive protein and procalcitonin: Reference intervals for preterm and term newborns during the early neonatal period, *Clinica Chimica Acta*, 412(11), 1053-1059.
- Cihan, M., Ceylan, M., Soylu, H., Konak, M., 2022, Fast Evaluation of Unhealthy and Healthy Neonates Using Hyperspectral Features on 700-850 Nm Wavelengths, ROI Extraction, and 3D-CNN, *IRBM*, 43(5), 362-371.
- Cottriss, D., 2024, *How AI is Supercharging Digital Twins* [online], Nasdaq, <https://www.nasdaq.com/articles/how-ai-is-supercharging-digital-twins> [Ziyaret Tarihi: 14 Aralık 2024].
- Dosovitskiy, A., et al., 2021, An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, ICLR.
- Dubey, A.K., Kumar, A., García-Díaz, V., Sharma, A.K., Kanhaiya, K., 2021, Study and analysis of SARIMA and LSTM in forecasting time series data, *Sustainable Energy Technologies and Assessments*, 47, 101474.
- Edelman, G. J., Gaston, E., van Leeuwen, T. G., Cullen, P. J., Aalders, M. C. G., 2012, Hyperspectral imaging for non-contact analysis of forensic traces, *Forensic Science International*, 223(1-3), 28-39.
- Elayan, H., Aloqaily, M., Guizani, M., 2021, Digital Twin for Intelligent Context-Aware IoT Healthcare Systems, *IEEE Internet of Things Journal*, 8(23), 16749-16757.

- European Commission, 2024, European Virtual Human Twins Initiative [online], <https://digital-strategy.ec.europa.eu/en/policies/virtual-human-twins> [Ziyaret Tarihi: 12 Aralık 2024].
- Fairchild, K., Schelonka, R., Kaufman, D., et al., 2013, Septicemia mortality reduction in neonates in a heart rate characteristics monitoring trial, *Pediatric Research*, 74, 570-575.
- Grieves, M., Vickers, J., 2016, Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems, *Transdisciplinary Perspectives on Complex Systems*, 85-113.
- Halicek, M., Little, J. V., Wang, X., Chen, A. Y., Fei, B., 2019, Optical biopsy of head and neck cancer using hyperspectral imaging and convolutional neural networks, *Journal of Biomedical Optics*, 24(3), 036007.
- Hochreiter, S., Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation*, 9(8), 1735-1780.
- İmamoğlu, E.Y., 2019, Yenidoğanda Ateş ve Hipotermiye Yaklaşım, *Klinik Tıp Pediatri Dergisi*, 11(4), 200-204.
- Johnson, P.A., Schmölzer, G.M., 2020, Heart Rate Assessment during Neonatal Resuscitation, *Healthcare*, 8(1), 43.
- Jolliffe, I. T., 2002, *Principal Component Analysis* (2nd ed.), Springer.
- Kumar, N., Akangire, G., Sullivan, B., Fairchild, K., Sampath, V., 2020, Continuous vital sign analysis for predicting and preventing neonatal diseases in the twenty-first century: big data to the forefront, *Pediatric Research*, 87, 210-220.
- Laura, C.Q., Deedee, K., Maria, W.K., Laurien, O., Niek, A., Jacqueline, S.B., Eduardus, C.J.E., Peter, A., Carola, P., 2021, Prediction of Late-Onset Sepsis in Preterm Infants Using Monitoring Signals and Machine Learning, *Critical Care Explorations*, 3(1), e0302.
- Li, A., Mullin, S., Elkin, P.L., 2024, Improving Prediction of Survival for Extremely Premature Infants Born at 23 to 29 Weeks Gestational Age in the Neonatal Intensive Care Unit: Development and Evaluation of Machine Learning Models, *JMIR Med Inform*, 12, e42271.
- Lim, B., Zohrem, S., 2021, Time-series forecasting with deep learning: a survey, *Royal Society*, 379(2194).
- Lv, Z., Xie, S., 2022, Artificial intelligence in the digital twins: State of the art, challenges, and future research topics, *Digital Twin*, 2, 1-12.
- Makridakis, S., Hibon, M., 1997, ARMA Models and the Box-Jenkins Methodology, *Journal of Forecasting*, 16, 147-163.

- Manja, V., Mathew, B., Carrion, V., [Lakshminrusimha, S.](#), 2015, Critical congenital heart disease screening by pulse oximetry in a neonatal intensive care unit, *J Perinatol*, 35, 67-71.
- Minerva, R., Lee, G.M., Crespi, N., 2020, Digital Twin in the IoT Context: A Survey on Technical Features, Scenarios, and Architectural Models, *Proceedings of the IEEE*, 108(10), 1785-1824.
- Ohuma, E.O., Moller, A.B., Bradley, E., Chakwera, S., Hussain-Alkhateeb, L., Lewin, A., Okwaraji, Y.B., Mahanani, W.R., Johansson, E.W., Lavin, T., Fernandez, D.E., Domínguez, G.G., de Costa, A., Cresswell, J.A., Krasevec, J., Lawn, J.E., Blencowe, H., Requejo, J., Moran, A.C., 2023, National, regional, and global estimates of preterm birth in 2020, with trends from 2010: a systematic analysis, *Lancet*, 1261-1271.
- Ornek, A.H., Ceylan, M., Ervural, S., 2019, Health status detection of neonates using infrared thermography and deep convolutional neural networks, *Infrared Physics & Technology*, 103, 103044.
- Pramana, I.A., Latzin, P., Schlapbach, L.J., Hafen, G., Kuehni, C.E., Nelle, M., Riedel, T., Frey, U., 2011, Respiratory symptoms in preterm infants: burden of disease in the first year of life, *Eur J Med Res*, 16, 223.
- Piasecik, R., Vickers, J., Lowry, D., Scotti, S., Stewart, J., Calomino, A., 2010, Technology area 12: Materials, structures, mechanical systems, and manufacturing road map, *NASA Office of Chief Technologist*.
- Sale, S.M., 2010, "Neonatal apnoea", *Best Practice & Research Clinical Anaesthesiology*, 24(3), pp. 323-336
- Savitzky, A., Golay, M. J. E., 1964, Smoothing and Differentiation of Data by Simplified Least Squares Procedures, *Analytical Chemistry*, 36(8), 1627-1639.
- Scheuermann, C., Binderberger, T., Frankenberg, N.V., Werner, A., 2020, Digital twin: a machine learning approach to predict individual stress levels in extreme environments, UbiComp-ISWC '20, *Virtual Event*, Mexico, 657-664.
- Shahat, E., Hyun, C.T., Yeom, C., 2021, City Digital Twin Potentials: A Review and Research Agenda, *Sustainability*, 13(6), 3386.
- Siami-Namini, S., Tavakoli, N., Siami Namin, A., 2018, A Comparison of ARIMA and LSTM in Forecasting Time Series, 17th IEEE International Conference on Machine Learning and Applications (ICMLA), Orlando, FL, USA, 1394-1401.
- Sizemore, N., Oliphant, K., Zheng, R., Martin, C., Claud, E., Chattopadhyay, I., 2024, A Digital Twin of the Infant Microbiome to Predict Neurodevelopmental Deficits, *Research Square*.

- Sun, T., He, X., Li, Z., 2023, Digital twin in healthcare: Recent updates and challenges, *Digital Health*, 9, 2055-2076.
- Sun, Y., Wang, W., Long, X., Meftah, M., Tan, T., Shan, C., Aarts, R.M., de With, P.H.N., 2019, Respiration Monitoring for Premature Neonates in NICU, *Applied Sciences*, 9(23), 5246.
- Tuhaise, V.V., Tah, J.H.M., Abanda, F.H., 2023, Technologies for digital twin applications in construction, *Automation in Construction*, 152, 104931.
- Uri, J., 2020, 50 Years Ago: "Houston, We've Had a Problem" [online], NASA, <https://www.nasa.gov/history/50-years-ago-houston-weve-had-a-problem/> [Ziyaret Tarihi: 12 Aralık 2024].
- Varal, İ.G., 2020, Prematüre Bebeklerde Hemogloblin Düzeyi ile Bronkopulmoner Displazi İlişkisi, *The Journal of Current Pediatrics*, 18(1), 15-28.
- Vasefi, F., MacKinnon, N., Farkas, D. L., 2016, Hyperspectral and Multispectral Imaging in Dermatology, *Imaging in Dermatology*, 16, 187-201.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., Polosukhin, I., 2017, Attention is all you need, *Advances in Neural Information Processing Systems (NeurIPS)*, 5998–6008.
- Villa, A., Benediktsson, J. A., Chanussot, J., Jutten, C., 2011, Hyperspectral Image Classification With Independent Component Discriminant Analysis, *IEEE Transactions on Geoscience and Remote Sensing*, 49(12), 4865-4876.
- Warburton, A., Monga, R., Sampath, V., et al., 2019, Continuous pulse oximetry and respiratory rate trends predict short-term respiratory and growth outcomes in premature infants, *Pediatric Research*, 85, 494-501.
- Watchko, J.F., 2016, Bilirubin-Induced Neurotoxicity in the Preterm Neonate, *Clinics in Perinatology*, 43(2), 297-311.
- WHO, UNICEF, 2023, Born too soon: decade of action on preterm birth, Geneva: *World Health Organization*.
- Yanyu, L., Prakesh, S.S., Xiang, Y.Y., Ruth, W., Bruno, P., Akhil, D., Michael, D., Shoo, L.K., 2015, Association Between Admission Temperature and Mortality and Major Morbidity in Preterm Infants Born at Fewer Than 33 Weeks' Gestation, *JAMA Pediatrics*, 169(4).
- Yochpaz, S., Friedman, N., Zirkin, S., Blumovich, A., Mandel, D., Marom, R., 2022, C-reactive protein in early-onset neonatal sepsis—a cutoff point for CRP value as a predictor of early-onset neonatal sepsis in term and late preterm infants early after birth, *The Journal of Maternal-Fetal & Neonatal Medicine*, 35(23), 4552-4557.

- Yurkevich, E.V., Stepanovskaya, I.A., 2021, Controlling the security of the airport airspace using the digital twin, *Journal of Physics: Conference Series*, 1864(1), 012128.
- Zhang, J., Cui, H., Yang, A.L., Gu, F., Shi, C., Zhang, W., Niu, S., 2023, An intelligent digital twin system for paper manufacturing in the paper industry, *Expert Systems with Applications*, 230, 120614.
- Zhang, Y., Lu, S., Wu, Y., Hu, W., Yuan, Z., 2022, The Prediction of Preterm Birth Using Time-Series Technology-Based Machine Learning: Retrospective Cohort Study, *MIR Med Inform*, 10(6), e33835.
- Zhang, Y., Qiang, H., Wang, X., Xiao, F., Ji, Z., Li, X., Ma, L., Cong, Y., 2022, Digital Twin and Its Application in Storage and Maintenance of Solid Rocket Motor, *Forest Chemicals Review*, 671-690.



EKLER

EK-1 Prematüre Bebeklerde Vaka Önleme ve Yönetimi İçin Toplanan Medikal Parametreler Ve Laboratuvar Bulgularının Elde Edilmesi İçin Etik Kurul Kararı



T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

YEREL ETİK KURULU KARARLARI

Toplantı Sayısı: 2022/05

Toplantı Tarihi :01.03.2022

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

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

Yardımcı Araştırmacılar: Hanifi SOYLU, Murat KONAK.

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