

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**MEKANİK DOLAŞIM DESTEK SİSTEMİ HASTALARININ DRİVELİNE
YARALARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMİ İLE
ENFEKSİYON AÇISINDAN İNCELENMESİ**

Kemal KANDEMİR

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

TEMMUZ 2021

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**MEKANİK DOLAŞIM DESTEK SİSTEMİ HASTALARININ DRİVELİNE
YARALARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMİ İLE
ENFEKSİYON AÇISINDAN İNCELENMESİ**

Kemal KANDEMİR

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

TEMMUZ 2021

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MEKANİK DOLAŞIM DESTEK SİSTEMİ HASTALARININ DRİVELİNE
YARALARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMİ İLE
ENFEKSİYON AÇISINDAN İNCELENMESİ**

Kemal KANDEMİR
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 02/07/2021 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Dr. Öğr. Üyesi Hamza Feza CARLAK (Danışman)

Doç. Dr. Evren EKMEKÇİ

Dr. Öğr. Üyesi Salih ÖZÇOBANOĞLU

ÖZET

MEKANİK DOLAŞIM DESTEK SİSTEMİ HASTALARININ DRİVELİNE YARALARININ GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMİ İLE ENFEKSİYON AÇISINDAN İNCELENMESİ

Kemal KANDEMİR

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Hamza Feza CARLAK

Temmuz 2021; 48 sayfa

Tez çalışmasında, kalp yetersizliği yaşayan hastalara tedavi olarak uygulanan mekanik dolaşım destek sisteminin implantasyonu sonrasında oluşabilecek driveline yaralarının görüntü işleme ve derin öğrenme yöntemleri ile enfeksiyon durumunun incelenmesi üzerine çalışılmıştır. Sol ventrikül destek cihazları (LVAD) implantasyonu nedeniyle meydana gelen driveline enfeksiyonu hastalarda üçüncü en yaygın ölüm nedenidir. Driveline enfeksiyonu cilt dokusunda ödem, sıcaklık, pürülan akıntı gibi semptomların ortaya çıkmasıdır. Bu semptomlar cilt dokusunda lezyonlara neden olur. Bu çalışmada, kalp yetersizliğine bağlı LVAD implantasyonu sonrası oluşabilecek aktarma organları enfeksiyonunu tespit etmek için görüntü işleme teknikleri ve derin öğrenme yöntemleri kullanılmıştır.

Çalışma kapsamında kalp yetersizliğine bağlı olarak mekanik dolaşım destek sistemi implantasyonu uygulanan hastalardan alınan görüntüler ile enfeksiyon durumu hakkında inceleme yapılmıştır. Bu tespitler için öncelikle driveline'in vücuttan çıkış bölgesi tespit edilmiştir. Driveline vücut çıkış bölgesi tespitinde, cilt dokusu üzerinde bölütleme işlemi yapılmıştır. Bu tespit işlemi için bölütleme işlemi olarak K-Ortalamalar algoritması tercih edilmiştir. Bölütleme işlemi sonrasında elde edilen driveline vücut çıkış bölgesi, öznitelik çıkarma işlemi ve derin öğrenme için girdi olarak kullanılmıştır. Öznitelik çıkarma kısmında üç farklı yöntem kullanılmıştır. Bu yöntemler: ayırık dalgacık dönüşümü, Shannon Entropisi ve gri seviyeli eş-oluşum matrisleridir. Bu yöntemlere bağlı olarak bazı çıkarımlarda bulunulmuştur. Öznitelik çıkarmaya ek olarak derin öğrenme yöntemi kullanılmıştır. Derin öğrenmede evrişimli sinir ağı mimarisi tercih edilmiştir. Evrişimli sinir ağı mimarisine bağlı olarak model geliştirilmiştir. Bu model ile görüntünün enfeksiyon durumu hakkında tahminde bulunulmuştur. Mevcut veri yapısı ve miktarına bağlı olarak geliştirilen modelin başarı oranı %90 olarak hesaplanmıştır.

ANAHTAR KELİMELER: derin öğrenme, driveline enfeksiyon tespiti, evrişimli sinir ağı, görüntü işleme, tıbbi teşhis

JÜRİ: Dr. Öğr. Üyesi Hamza Feza CARLAK

Doç. Dr. Evren EKMEKÇİ

Dr. Öğr. Üyesi Salih ÖZÇOBANOĞLU

ABSTRACT

ASSESSMENT OF INFECTION LEVELS IN MECHANICAL CIRCULATORY ASSIST DEVICE IMPLANTED PATIENTS UTILIZING IMAGE PROCESSING AND DEEP LEARNING METHODS

Kemal KANDEMİR

MSc Thesis in Department of Electric and Electronic Engineering

Supervisor: Assist. Prof. Dr. Hamza Feza CARLAK

July 2021; 48 pages

In this study, infection levels of possible driveline complications due to the implantation of mechanical circulatory assist devices were investigated with image processing and deep learning methods. Driveline infection due to the left ventricular assist devices (LVAD) implantation is the third most common cause of death in patients. Driveline infection is the manifestation of symptoms such as edema, warmth, purulent discharge in the skin tissue. These symptoms cause lesions in the skin tissue. In this study, image processing techniques and deep learning methods were used to detect driveline infection that may occur after implantation of LVAD due to the heart failure.

Within the scope of the study, infection status was examined with images taken from patients who underwent mechanical circulatory support system implantation due to the heart failure. For these determinations, first of all, the exit region of the driveline from the body tissue was detected. In the detection of the body exit region of the driveline cable, segmentation was performed on the skin tissue. The K-means algorithm was chosen for the segmentation process. Region of the detected driveline exit-line was used as an input for the feature extraction and deep learning operations. Three different methods which are wavelet transform, Shannon entropy and gray level co-occurrence matrix were utilized in the feature extraction stage. The inferences have been made depending on these methods. A deep learning method was used in addition to the feature extraction method. Convolutional neural network architecture was developed and used for deep learning to predict the infection level of the patients. The success rate of the model, which was developed depending on the existing data structure and amount, was calculated as 90%.

KEYWORDS: convolutional neural network, deep learning, driveline infection, image processing, medical diagnosis

COMMITTEE: Assist. Prof. Dr. Hamza Feza CARLAK

Assoc. Prof. Dr. Evren EKMEKÇİ

Assist. Prof. Dr. Salih ÖZÇOBANOĞLU

ÖNSÖZ

Kalp yetersizliğine bağlı olarak sol ventriküler destek cihazı kullanan hastaların hastaneden taburcu olduktan sonra driveline enfeksiyon durumlarını takip edebileceği ve sağlık çalışanlarımıza yardımcı olacak bir çalışmanın içinde bulunmanın heyecanıyla bu çalışmada gözlemlediklerimin bir kısmını tezimde yayınlamayı uygun buldum.

Bu çalışmada her türlü yardımlarını esirgemeyen ve projenin hayata geçmesini sağlayan danışman hocam Dr. Öğr. Üyesi Hamza Feza CARLAK'a teşekkür ederim. Çalışmam boyunca hastalara ve verilere ulaşmamı sağlayan ayrıca tıbbi anlamda verileri yorumlamama yardımcı olan ve desteklerini esirgemeyen Dr. Öğr. Üyesi Salih ÖZÇOBANOĞLU hocama ve ekibine teşekkür ederim.

Çalışma süresince fikir alışverişinde bulunduğum ve fikirleriyle görüşlerime, çalışmalarına katkıda bulunan arkadaşım Çağdaş TOPÇU'ya ve eğitim hayatım boyunca bana desteklerini esirgemeyen annem Yasemin KANDEMİR, babam Recai KANDEMİR ve ablam Tuğba KONAR'a minnet ve şükranlarımı sunuyorum.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
2. KAYNAK TARAMASI.....	3
2.1. Ventriküler Destek Cihazı	3
2.2. Sol Ventriküler Destek Cihazına Bağlı Enfeksiyon	4
2.3. Driveline Enfeksiyon Tespiti ve Bölütlemesi Üzerine Yapılan Çalışmalar.....	6
3. MATERYAL VE METOT	7
3.1. Önışleme Aşaması.....	7
3.1.1. Gaussian filtresi	7
3.1.2. Yerel olmayan yöntemlerle gürültü arındırma	7
3.1.3. Ortalama kaydırma filtresi.....	7
3.2. Görüntü Bölütleme	8
3.2.1. K-Ortalamlar algoritması	8
3.3. Öznitelik Çıkarma	9
3.3.1. Ayrık dalgacık dönüşümü.....	9
3.3.1.1. Ayrık dalgacık dönüşümü	9
3.3.1.2. 2 Boyutlu dalgacık dönüşümü	9
3.3.2. Shannon entropi	11
3.3.3. Gri seviyeli eş-oluşum matrisleri.....	11
3.4. Derin Öğrenme	12
3.4.1. Evrişimli sinir ağları	14
3.4.2. Evrişimli sinir ağı katman yapısı	14
3.4.2.1. Evrişim katmanı	14

3.4.2.2. Havuzlama katmanı	16
3.4.2.3. Tam bağı katman	16
3.4.2.4. Aktivasyon katmanı	17
3.4.2.5. Yığın normalizasyonu katmanı	18
3.4.2.6. Düzüm seyreltme katmanı	18
3.4.3. Veri artırma.....	19
3.4.4. Derin öğrenme hiperparametreleri.....	20
3.4.4.1. Öğrenme oranı	20
3.4.4.2. Momentum.....	20
3.4.4.3. Optimizasyon Yöntemleri.....	21
3.4.5. Derin öğrenme performans ölçümü.....	22
3.5. Driveline Enfeksiyon Tespitinde Görüntü İşleme ve Derin Öğrenme Yönteminin Uygulanması.....	23
4. BULGULAR VE TARTIŞMA	28
5. SONUÇLAR	42
6. KAYNAKLAR	44
7. EKLER.....	48
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Mekanik Dolaşım Destek Sistemi Hastalarının Driveline Yaralarının Görüntü İşleme ve Derin Öğrenme Yöntemi ile Enfeksiyon Açısından İncelenmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

02/07/2021
Kemal KANDEMİR



SİMGELER VE KISALTMALAR

Simgeler

θ	: Açısal Bilgi
d	: Mesafe
σ	: Standart Sapma

Kısaltmalar

AdaGrad	: Adaptif Gradyan Algoritması
Adam	: Adaptif Moment Tahmini
BiVAD	: Sağ ve Sol Ventriküler Destek Cihazı
CNN	: Evrişimli Sinir Ağları
DBN	: Derin İnanç Ağı
GLCM	: Gri Seviyeli Eş-Oluşum Matrisi
GPU	: Grafik İşlemci Birimi
HAPPY	: Heart Failure Prevalence and Predictors in Turkey
LTSM	: Uzun Kısa Süreli Hafıza
LVAD	: Sol Ventriküler Destek Cihazı
RBM	: Sınırlı Boltzman Makineleri
RMSprop	: Kök Ortalama Kare Yayılımı
RNN	: Tekrarlayan Sinir Ağları
ROI	: İlgi Bölgesi
RVAD	: Sağ Ventriküler Destek Cihazı
SGD	: Stokastik Gradyan İnişi
VAD	: Ventriküler Destek Cihazı

Tezde ondalık yazımlar mevcuttur ve ondalık yazımlar nokta ayırıcı ile kullanılmıştır. (Örn. “07.35”)

ŞEKİLLER DİZİNİ

Şekil 2.1. HeartWare ve Heartmate II cihaz bağlantıları (Peberdy vd., 2017)	4
Şekil 3.1. Çoklu çözünürlüklü dalgacık ayrıştırma işlemi	9
Şekil 3.2. İki boyutlu ayırık dalgacık dönüşümü kullanılarak görüntü analizi: birinci seviyede ayrışma (a), ikinci seviyede ayrışma (b)	10
Şekil 3.3. Gri seviye eş oluşum matrisi çıkarılması sırasındaki mesafe ve açı bilgisinin uygulanması	12
Şekil 3.4. Yapay sinir ağları, makine öğrenmesi ve derin öğrenme diyagramları	13
Şekil 3.5. LeNet-5 modelinin katmanları (Lecun vd., 1998)	14
Şekil 3.6. Evrişim işleminin matris uygulaması (Sameep Tandon, t.y.)	15
Şekil 3.7. RGB görüntü için evrişim işlemi	15
Şekil 3.8. Maksimum havuzlama, ortalama havuzlama, minimum havuzlama teknikleri	16
Şekil 3.9. Tam bağlı katmanda düzleştirme işlemi	17
Şekil 3.9. ReLU, sigmoid, tanh ve softmax fonksiyonlarının [-4,4] aralığındaki gösterimi	18
Şekil 3.10. Düğüm Seyreltme a.) standart yapay sinir ağı b.) düğüm seyreltme uygulanmış yapay sinir ağı (Z.-S. Wang vd., 2020)	19
Şekil 3.11. Veri artırma yönteminin uygulaması sonucu elde edilen veriler	19
Şekil 3.12. Farklı öğrenme oranları uygulanan temsili modelin (a) kayıp fonksiyon dağılımları (b) doğruluk fonksiyon dağılımları (Deijn, 2018)	20
Şekil 3.13. Stokastik Gradyan İnişi (a) momentum değeri olmadan (b) momentum yöntemi kullanılarak (Raghuwanshi ve Pateriya, 2021)	21
Şekil 3.14. Driveline bölgesinden görüntü elde edilmesi	23
Şekil 3.15. Ham görüntü üzerine önışleme uygulanmış görüntüler Ham driveline bölgesi görüntüsü (a) Önışleme uygulanmış görüntü (b)	24
Şekil 3.16. Cilt dokusu driveline bölütleme çıktıları Ham görüntü (a) Önışleme uygulanmış görüntü (b) Driveline bölütleme uygulanmış görüntü (c) Cilt bölütleme uygulanmış görüntü (d)	24
Şekil 3.17. Vücut Rengi, Kablo Rengi çıkarılması	25
Şekil 3.18. Driveline'nın vücuda giriş bölgesinin tespiti	25
Şekil 3.19. Tasarlanan sistemin akış şeması	26
Şekil 3.20. Derin öğrenme modeli katman yapısı	27
Şekil 4.1 Enfeksiyonsuz(sol figürler) ve enfeksiyonlu (sağ figürler) verilerin homojenlik, enerji, kontrast ve korelasyon dağılımları	28
Şekil 4.3. Derin öğrenme modeline SGD optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları	29

Şekil 4.4. Derin öğrenme modeline Adam optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları.....	30
Şekil 4.5 Derin öğrenme modeline RMSprop optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları.....	30
Şekil 4.6. Derin öğrenme modeline AdaGrad optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları.....	31
Şekil 4.7. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	32
Şekil 4.8. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.5 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	32
Şekil 4.9. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.9 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	33
Şekil 4.10. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.99 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	33
Şekil 4.11. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 1 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	34
Şekil 4.13. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.01 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	35
Şekil 4.14. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.001 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	36
Şekil 4.15. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.0001 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	36
Şekil 4.16. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.00001 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	37
Şekil 4.17. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.000001 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	38
Şekil 4.18. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.0000001 seçilmesi sonucu doğruluk ve kayıp dağılımları.....	38
Şekil 4.19. SGD optimizasyon yönteminin hiperparametre olarak öğrenme oranının 0.0001 ve momentum değerinin 0.9 seçilmesi sonucu doğruluk ve kayıp dağılımları	39
Şekil 4.20. Eğitilen modele test verilerinin gerçek ve tahmini değerlerinin dağılımı	40
Şekil 4.21. Eğitilen modele test verilerin normalize hata matrisi	40

ÇİZELGELER DİZİNİ

Çizelge 2.1. Sol ventrikül destek cihazı olan hastalarda enfeksiyon insidansı.....	5
--	---



1. GİRİŞ

Kalp yetersizliği, giderek artan vaka sayısı ile Dünya’da önde gelen ve insan yaşamını tehdit eden önemli bir sağlık sorunudur. Dünya çapında en az 64,3 milyon kişinin kalp yetersizliği sorunu yaşadığı tahmin edilmektedir (Lippi ve Sanchis-Gomar, 2020). Amerikan Kalp Birliği (American Heart Association), tarafından gerçekleştirilen bir çalışmaya göre 2012’den 2030 yılına kadar olan süreçte, kalp yetersizliği sendromunda yaklaşık %46’lık bir artış beklemektedir. Buna bağlı olarak 2030 yılında ABD’de 18 ve üzeri yaş grubunda 8 milyondan fazla kişide kalp yetersizliği sendromu görülmesi tahmin edilmektedir. Türkiye’de ise kalp yetersizliği sendromunun saptanması amacıyla yapılan HAPPY (Heart Failure Prevalence and Predictors in Turkey) çalışması sonucunda, 2 milyonun üzerinde hastanın var olduğu görülmüştür (LaleTokgözoğlu, t.y.).

Kalp yetersizliğinin bu zamana kadar birçok tanımı yapılmıştır. İlk kez Sir Thomas Lewis tarafından 1933 yılında “Kalbin içeriğini yeterince boşaltmadığı bir durum” olarak tanımlanmıştır. 1950’de ise Paul Wood tarafından “Tatmin edici bir doldurma basıncına rağmen kalbin vücudun ihtiyaçları için yeterli dolaşımı sağlayamadığı bir durum” olarak tanımlanmıştır (Davis, 2000). Kalp yetersizliği, günümüzde ise ventrikülün doluş ve/veya ejeksiyon yetisini etkileyen yapısal veya işlevsel değişikliklerin neden olduğu karmaşık bir klinik sendromu olarak tanımlanmaktadır (Authors/Task Force Members vd., 2008).

Kalp yetersizliğinin tedavisi ilaç tedavisi, cerrahi operasyonlar ve kalp destek cihazları ile yapılabilir (Kemp ve Conte, 2012). İleri evre kalp yetersizliği sendromu yaşayan hastalarda kalp destek cihazları ile yaşam kalitesi arttırılabilmektedir. Kalp destek cihazları üç durumda kullanılmaktadır. Birinci durumda, kalp yetmezliği sendromu tedavisi için kalp nakli uygulanacak hastaların, donör bekleme sürecinde, hastanın yaşam süresini uzatmak için nakil gerçekleşene kadar geçici olarak kalp destek cihazlarının implantasyonu gerçekleşir. İkinci durum, hastanın sağlık durumunun kalp nakli için elverişli olmaması ve kalp nakli yerine kalp destek cihazlarının tercih edilmesi durumudur. Üçüncü durumda ise kalbe destek amaçlı, geçici olarak kalp destek cihazları kullanılmaktadır (Barg vd., 2017).

Tez çalışmasında kalp destek cihazı olarak sol ventriküler destek cihazı kullanan hastalar incelenmiştir. Sol ventriküler destek cihazı, kalp için mekanik bir pompa görevi görmektedir. Kalpteki ventrikülün boşaltılmasına yardımcı olur. Bu sayede kalbin iş yükünü azaltarak, kalbin çok daha etkin bir biçimde çalışmasını sağlar. Buna bağlı olarak hastayı yatağa bağımlı hale gelmekten kurtarmakta, günlük hayatına devam edebilmesine olanak sağlamaktadır. Sol ventriküler destek cihazı implantasyonu yapılan hastanın, bu işlem sonrasında hastanede bulunduğu ve hastaneden taburcu olduktan sonraki sürecinde durumunun takibinin yapılması gerekmektedir. Takip edilmesi gereken en önemli durumlardan biri ise driveline enfeksiyonu oluşup oluşmadığıdır. Kalp nakli bekleyen, bu süreçte sol ventriküler destek cihazı kullanan hastalarda, driveline enfeksiyonu oluşabilir. Buna bağlı olarak enfeksiyon oluştuğundan dolayı nakil işlemi gerçekleştirilemeyebilir ve/veya nakil sırasından çıkarabilir. Diğer taraftan driveline enfeksiyonu sebebiyle hasta hayatını kaybedebilir. Bu yüzden enfeksiyonun erken tespit edilmiş olması, hastanın sağlığı açısından büyük önem arz etmektedir. Enfeksiyonunun erken tespit edilmesi sayesinde, uzmanların uygun bulduğu antibiyotik tedavisi gibi tedavilere erkenden

başlanabilir (Trachtenberg vd., 2015). Bu sayede hastanın sağlığına kavuşmasına katkı sağlanmış olur.

Tez çalışmasında sol ventriküler destek cihazının implantasyon sonrasında oluşabilecek driveline enfeksiyon tespiti üzerine yoğunlaşmıştır. Bu çalışma sayesinde erken enfeksiyon tespiti yapılabilmesi öngörülmüştür. Hasta takibinde alanındaki uzman doktorlara yardımcı ve destekleyici olabilmek hedeflenmiştir. Buna bağlı olarak, hastaların tedavi süreçlerine katkı sağlayabilmek ve yaşam sürelerinin uzatılabilmesi amaçlanmıştır. Bunlara ek olarak bu cihazların ve operasyonların devletlere olan giderlerinin azaltılabileceği öngörülmektedir (Leuck, 2015).

Önerilen fikir üzerine literatür araştırması yapıldığında yalnızca iki çalışma bulunmuştur. Bu yüzden çalışmanın literatüre katkısının önemli olacağı öngörülmektedir. İncelenen çalışmalardan birincisinde driveline enfeksiyonunun tespiti üzerine çalışılmıştır. Bu çalışmada enfeksiyon tespiti için derin öğrenme yöntemi önerilmiştir. Enfeksiyon tespiti yapılırken derin öğrenme evrişimli sinir ağı mimarisini tercih etmişlerdir. Evrişimli sinir ağında VGG-16 modeli yenilenmiştir ve çalışmalarında da bu model kullanılmıştır (Aras vd., 2018). İkinci çalışma olarak ise driveline enfeksiyonu tespitinden ziyade, derin öğrenme ile driveline bölütlemesi üzerine çalışılmıştır (Lüneburg vd., 2019). Bunlara ek olarak literatürdeki çalışma azlığından dolayı doku analizi üzerine yapılmış çalışmalar araştırılmıştır. Bu çalışmalarda cilt dokusu üzerindeki farklılıklar incelenmiştir. Ayrıca çalışmalarda vücut derisindeki cilt lekelerinin sınıflandırılması, cilt kanseri tahmini üzerine yapılmış olan öngörüler incelenmiştir. Bu yayınlardan elde edilen bilgiler tez çalışması sürecine katkı sağlamıştır.

Tez çalışmasında ise, literatürdeki çalışmalardan edinilen bilgiler ışığında görüntü işleme teknikleri ve derin öğrenme yöntemleri tercih edilmiştir. Çalışmada driveline bölütlemesi, driveline enfeksiyonunun vücuttan çıkış bölgesinin doku analizi ve derin öğrenme yöntemleri ile enfeksiyonlu verilerin tahmini üzerine çalışılmıştır. Çalışmanın birinci bölümünde genel olarak K-Ortalamlar algoritması kullanılarak driveline vücut bölütlemesi yapılmıştır. Bu bölütleme sonrasında driveline enfeksiyonunun vücuttan çıkış bölgesinin tespiti yapılmıştır. İkinci bölümde vücuttan çıkış bölgesinin doku analizi için üç ayrı yöntem kullanılmıştır. İlk olarak ayrık dalgacık dönüşümü, ikinci olarak Shannon entropi yöntemi ile incelenmesi, üçüncü olarak ise gri seviye eş oluşum matrisi (GLCM) incelenmiştir. GLCM'den elde edilen veri ile entropi, kontrast, homojenlik ve korelasyon öznitelikleri çıkarılmıştır. Görüntü işleme teknikleri kullanıp doku analizi yapılmış ve bu sayede driveline enfeksiyonunun tespiti sağlanmıştır. Ek olarak derin öğrenme yöntemi kullanılarak enfeksiyon tahmininde bulunulmuştur. Derin öğrenme sırasında evrişimli sinir ağı mimarisi tercih edilmiştir. Bu mimariye bağlı olarak model geliştirilmiştir. Bu modele bağlı olarak hastaların görüntüleri incelenip, driveline enfeksiyonunun durumu hakkında tahminde bulunulmaktadır. Mevcut veriler ile geliştirilen derin öğrenme modelin başarı oranı %90 olarak hesaplanmıştır.

2. KAYNAK TARAMASI

2.1. Ventriküler Destek Cihazı

Ventriküler destek cihazları, kalp yetersizliği yaşayan hastaların cerrahi operasyonla implantasyonunun gerçekleştirilerek, tedavisine yardımcı olan mekanik bir pompadır. Her geçen gün artan kalp yetersizliği hastalığına geçici ya da kalıcı çözüm sağlamaktadır. Kalp yetmezliği hastalığının öncelikli tedavisi kalp transplantasyonudur. Fakat yeterli donör bulunamadığından transplantasyon gerçekleşene kadar ventriküler destek cihazlar ile nakil bekleme süreci uzatılabilmektedir. Ayrıca sağlık sorunları nedeniyle transplantasyon işlemi gerçekleşemeyecek hastalar için transplantasyon işlemi yerine tedavi olarak VAD implantasyonu tercih edilmektedir. Bunların yanında tedavi yöntemi olarak geçici olarak implantasyon yapılmaktadır. Implantasyon sonrasında iyileşmeler görülmektedir (Barg vd., 2017).


Ventriküler destek cihazları, kalpteki ventrikülün işlevi olan mekanik pompa işlemine yardımcı olmaktadır. Bu sayede ventrikül üzerine düşen iş yükünü azaltmaktadır. Ayrıca mekanik pompa işlevine yardımcı olduğu için kan akışı artmaktadır.

En yaygın LVAD tipi, karnın üst kısmına yerleştirilen bir pompaya bağlı iki tüpe sahiptir. Sol ventriküle bir tüp yerleştirilir ve ventrikülden pompaya kan taşır. Pompa daha sonra kanı aorta taşır, ana arter sol ventrikülden ayrılır. Pompanın diğer hortumu karın duvarından yönlendirilir ve vücudun dışına yerleştirilen pompanın bataryasına ve kontrol sistemine bağlanır.

Ventriküler destek cihazların temelde iki tipi vardır. Bunlar, sol ventriküler destek cihazı (LVAD) ve sağ ventriküler destek cihazıdır (RVAD). Bu ikili birlikte kullanılıyorsa, cihaza biventriküler destek cihazı (BIVAD) olarak isimlendirilir. Ancak BIVAD, ayrı bir VAD tipi değildir. Çoğunlukla sol ventriküler destek cihazı (LVAD) kullanılmaktadır.

Sol ventriküler destek cihazları, temel olarak dört kısımdan oluşmaktadır. Bu kısımlar pompa, kontroller, batarya ve driveline (güç ve kontrol kabloları) dır. Pompa olarak adlandırdığımız kısımda, göğsün içine bir motor yerleştirilmiştir. Bu pompa ile kanı kalpten vücuda pompalar. Kontrolör olarak adlandırdığımız kısım, pompayı kontrol eden kısımdır. Bu kontrolörlere bağlı olarak mesaj, görüntüler ve cihazlar hakkında alarmlar verir. Batarya kısmı pompa içindir. Pompanın işlevini yerine getirebilmesi için bir güç kaynağına bağlı olması gerekir. Batarya güç kaynağı görevini görür. Driveline kısmı ise pompayı vücut dışına bağlayan bir kablodur. Deri içerisinden geçer ve önemli güç ve kontrol kablolarını taşır (Larose vd., 2010). Şekil 2.1’de HeartWare ve Heartmate II modellerin bölümleri ve cihaz bağlantıları gösterilmiştir.


En yaygın kullanılan sol ventriküler destek cihazları modelleri: HeartWare, Heartmate II ve Heartmate III ‘dir.



Şekil 2.1. HeartWare ve Heartmate II cihaz bağlantıları (Peberdy vd., 2017)

2.2. Sol Ventriküler Destek Cihazına Bağlı Enfeksiyon

LVAD bağlı enfeksiyon, kalp yetersizliği yaşayan hastaların LVAD implantasyon sonrasında en yaygın ölüm sebeplerinden 3. sıradadır (Schneegg vd., 2021). Bu yüzden enfeksiyonun etkisi yadsınamaz. Ayrıca LVAD implantasyonu sonrasındaki ilk 30 gün, enfeksiyonun en çok görüldüğü dönemdir. Enfeksiyon riski LVAD kullanıldığı süre boyunca devam etmektedir. LVAD enfeksiyonları genel olarak üç başlık altında toplanabilmektedir. Bunlar: VAD'a özgü enfeksiyonlar, VAD'la ilişkili enfeksiyonlar ve VAD'la ilişkili olmayan enfeksiyonlardır. Şekil 2.2'de. VAD'a özgü enfeksiyonlar, VAD'la ilişkili enfeksiyonlar ve VAD'la ilişkili olmayan enfeksiyonlar gösterilmiştir.



Şekil 2.2. Mekanik destek sistemi enfeksiyonları (Hannan vd., 2011)

LVAD implantasyonu sonucu oluşan enfeksiyon, yoğunlukla driveline bölgesinde olmaktadır. Driveline enfeksiyonları yüzeysel ve derin olarak sınıflandırılır. Her iki enfeksiyon, driveline çıkış bölgesini çevreleyen yumuşak dokuları kapsar. Derin enfeksiyonlar fasya ve kas tabakalarını da içerir. Driveline enfeksiyonlarına en fazla *Staphylococcus aureus*, *Pseudomonas aeruginosa*, *Escherichia coli*, *Coagulase negative-staphylococci*, *Enterococcus spp*, *Corynebacterium spp* ve *Candida spp* gibi mikroorganizmalar neden olmaktadır. Driveline enfeksiyonlarının klinik görünümü; cihazı çevreleyen deri altı dokularında ya da kutanöz çıkış yerinde eritem, ağrı, ödem, sıcaklık, pürülan akıntı gibi lokal enfeksiyon bulguları şeklindedir (Zinoviev vd., 2020).

Çizelge 2.1. Sol ventrikül destek cihazı olan hastalarda enfeksiyon insidansı (Pereda ve Conte, 2011)

Yazarlar	Yayın Yılı	Hasta Sayısı	Kullanılan Cihaz	Driveline Enfeksiyon (%)
(Martin vd., 2010)	2010	145	MateMate I HeartMate II Thoratec IVAD VentrAssist Abiomed MicroMed	37
(Holman vd., 2010)	2010	593	Sadece Pulsatil	21
(Aslam vd., 2010)	2010	300	HeartMate I HeartMate II Thoratec IVAD Jarvik2000	16
(Saito vd., 2010)	2010	106	Toyobo HeartMate I Novacor Jarvik2000 EvaHeart DuraHeart	34
(Pagani vd., 2009)	2009	281	HeartMate II	14
(Morshuis vd., 2009)	2009	68	DuraHeart	15
(Pae vd., 2007)	2007	23	LionHeart	Mevcut Değil
(Miller vd., 2007)	2007	133	HeartMate II	14
(Monkowski vd., 2007)	2007	60	HeartMate I Thoratec	48
(Holman vd., 2004)	2004	68	HeartMate I	28

Çizelge 2.1’de driveline enfeksiyonu üzerine yapılan çalışmalarda, hasta sayısına bağlı olarak driveline enfeksiyonlu hastaların oranı gösterilmiştir. Bu oranlar ile driveline enfeksiyonunun etkisini görülmektedir.

2.3. Driveline Enfeksiyon Tespiti ve Bölütlemesi Üzerine Yapılan Çalışmalar

Shravan Aras ve arkadaşları tarafından yapılan InDetector adlı çalışmada derin öğrenme yöntemi kullanılarak enfeksiyon tespiti yapılmıştır. Derin öğrenmede evrişimli sinir ağı mimarisi kullanılmıştır. Bu mimari çatısında var olan VGG-16 modeline yaptıkları birkaç düzeltme ile modellerini geliştirmişlerdir. Geliştirilen model 8 enfeksiyonlu, 8 enfeksiyonsuz veri ile %93.75 başarı oranı elde etmektedir (Aras vd., 2018).

Noël Lüneburg ve arkadaşları derin öğrenme ile driveline bölütlemesi ve enfeksiyon tespiti üzerine çalışmışlardır. Çalışmalarında evrişimli sinir ağı mimarisi tercih etmişlerdir. Driveline bölütleme için U-net modelini kullanmışlardır. Driveline bölütlemesinde başarı olarak 0.95’lik bir Dice skor katsayısı elde etmişlerdir. Enfeksiyon tespitinde doğruluk başarıları %67’dir (Lüneburg vd., 2019).

3. MATERYAL VE METOT

3.1. Önışleme Aşaması

Bir görüntünün ön işlenmesi; sistemin çalışması esnasında görüntüyü doğru bir şekilde tanıyabilmesi için görüntü üzerinde bulunan, veriyi ayırt etmeyi zorlaştıran gürültülerden arındırmayı amaçlar. Çalışmamızda kullanılan görüntülerde de bu işlem uygulanarak, cilt üzerinde bulunan kıl, tüy vb. istenmeyen gürültülerden arındırılması sağlanmıştır. Bu sayede görüntülerin kalitesi artırılmış, sonraki işlemler için hazır hale getirilmiştir. Görüntülerin ön işlenmesi kısmında, görüntülerden gürültüleri ayırabilirlik için ileri aşamalarda açıklanmış olan filtreler uygulanmıştır.

3.1.1. Gaussian filtresi

Gaussian filtresi görüntüyü yumuşatmak amacıyla kullanılmaktadır. İki boyutlu Gaussian filtresi formülü formül 3.1' de ifade edilmiştir (Deng ve Cahill, 1993).

$$g(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.1)$$

Burada σ dağılımın standart sapmasını, y satır, x sütunu göstermektedir.

3.1.2. Yerel olmayan yöntemlerle gürültü arındırma

Yerel olmayan yöntemlerle gürültü arındırma algoritması; Antoni Buades ve arkadaşları tarafından 2005 yılında ortaya koyulmuştur. Algoritma temel olarak, pikselin rengini benzer piksellerin ortalaması ile yer değiştirir. Bu işlemi yaparken pikselin komşu piksellerinden daha çok görüntünün geniş alanında bu piksele en çok benzeyen piksellerin ortalamasını alır (Coll ve Morel, 2011).

$$u = (u_1, u_2, u_3) \quad (3.2)$$

$$\hat{u}_i(p) = \frac{1}{C(p)} \sum_{q \in B(p,r)} u_i(q) w(p, q) \quad (3.3)$$

$$C(p) = \sum_{q \in B(p,r)} w(p, q) \quad (3.4)$$

$$d^2(B(p, f), B(q, F)) = \frac{1}{3(2f+1)^2} \sum_{i=1}^3 \sum_{j \in B(0,f)} (u_i(p+j) - u_i(q+j))^2 \quad (3.5)$$

$$w(p, q) = e^{-\frac{\max(d^2 - 2\sigma^2, 0, 0)}{h^2}} \quad (3.6)$$

$w(p,q)$ ağırlık fonksiyonu, d^2 , p ve q arasındaki Öklid mesafesinin karesi, $C(p)$ normalleştirme faktörü, σ gürültünün standart sapması, h ; σ değerine bağlı olarak ayarlanan filtreleme parametresidir.

3.1.3. Ortalama kaydırma filtresi

Ortalama kaydırma filtresi, ortalama kaydırma algoritması temeline dayanmaktadır. Algoritma genel olarak kümeleme algoritmasıdır. Ortalama kaydırma

filtresi prensip olarak filtre içerisindeki piksellerin ortalamasını hesaplanır. Filtre merkezinin hesaplanan yoğunluk merkezine kaydırılmasıdır (Demirović, 2019).

$$K_{h_s, h_r}(x) = \frac{c}{h_s^2 h_r^p} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (3.7)$$

C normalizasyon katsayısını, x^s uzaysal kısmı, x^r spektral kısmı ifade eder. h_s ve h_r ise filtredeki uzaysal ve spektral kısımların boyutlarıdır.

Görüntünün her pikseli ve belirtilen parametreler dahilindeki komşu piksel seti için, sırasıyla h_s , h_r , uzamsal yarıçap ve renk mesafesi belirlenir. Bu komşu piksel seti için yeni uzamsal merkez ve yeni renk ortalama değerleri hesaplanır. Bu yeni değerler, bir sonraki yinelemenin yeni merkezi olarak hizmet verecektir. Bu prosedür, uzamsal ve renk araçları değişmeyi durdurana veya maksimum yineleme sayısına ulaşılan kadar yinelenmektedir.

3.2. Görüntü Bölütleme

Görüntü bölütleme (segmentasyon) bir görüntü içindeki farklı özelliklerin barındırdığı bölümlere ayrılmasıdır. Bölütleme; herhangi bir görüntüdeki nesneleri ve sınırlarını tanımlar. Bu tanımlama ile görüntü üzerinde istenen bölgelere erişebilir ve işlemler yapılabilir. Görüntüyü bölütlemek için global ve standart bir yöntem yoktur. Bölütleme işlemi için birçok yöntem vardır. Örneğin; kenar belirleme, yapay zekâ uygulamaları, K- Ortalamalar algoritması vb. yöntemlerle görüntü bölütleme yapılabilir. Çalışma kapsamında K-Ortalamalar algoritması kullanılmıştır.

3.2.1. K-Ortalamalar algoritması

K-Ortalamalar (K-Means) algoritması gözetimsiz öğrenme (unsupervised learning) ve kümeleme (clustering) algoritmasıdır. Algoritma prensip olarak N tane verinin k tane kümeye ayrışmasını sağlar. K tane kümeye ayrışması algoritmaya da ismini vermektedir. Her bir veri sadece bir kümeye dahil olur. Bu kümeleme işlemi başlatılmadan önce k seçilmelidir. K değeri, pozitif bir tam sayı olmalıdır. Sağlıklı bir kümeleme işlemi sonrasında, bir küme içerisindeki verilerin birbirlerine olabildiğince benzemesi istenmektedir. Ayrıştırılan kümeler için ise tam tersi olarak, birbirlerine benzemesi istenmez. Algoritmada başlangıçta K adet rastgele küme merkezi seçilir. Veriler küme merkezi mesafelerine göre, en yakın küme merkezinin kümesine dahil olur. Kümelerin kendi içinde ortalamaları hesaplanır ve yeni küme merkezleri seçilir. Bu işlemler bütün veriler bir kümeye dahil olana kadar devam eder. Mesafe hesaplaması yaparken genellikle öklid yöntemi kullanılmaktadır. Küme içindeki değişimi görebilmek için ise, karesel hata fonksiyonu kullanılmaktadır. Algoritmanın dezavantajına bakacak olursak, gürültü ve istisnai verilerden etkilenmektedir. Bu etkilenme de küme merkezi seçiminde kaymalara sebep olmaktadır.

Algoritmayı adım adım ifade edersek:

- 1- K seçimi
- 2- Rastgele küme merkezlerinin seçilmesi
- 3- Verilerin mesafelere göre kümeleneceği

- 4- Yapılan kümeleme sonrasında yeni merkezlerin belirlenmesi
- 5- İstenilen hale gelinceye kadar 3. ve 4. adımların tekrarlanması (J. Wang ve Su, 2011).


3.3. Öznitelik Çıkarma

Öznitelik bir veriden elde edilen, ölçülebilen veya gözlenebilen bilgi parçacığıdır. Öznitelik çıkarımı ile verinin karakteristik özelliği elde edilir. Bu sayede veriden gereksiz veya fazla bilgilerin ayrıştırılması sağlanmış olur. Öznitelikler ile benzer veriler arasında ilişki veya karşılaştırma işlemleri yapılabilir. Ayrıca öznitelik çıkarımı sonucunda, veri tanımlama süreci daha kısa sürelerle indirgenir.

3.3.1. Ayırık dalgacık dönüşümü

3.3.1.1. Ayırık dalgacık dönüşümü

Ayrık Dalgacık Dönüşümü görüntülerin sıkıştırılmasında, sınıflandırılmasında ve öznitelik elde edilmesinde kullanılmaktadır. Mallat tarafından 1988’de yayınlanan çoklu çözünürlük (Multiresolution) çalışmasında yer verdiği algoritma sayesinde bugünkü ayırık dalgacık dönüşümün temellerini atılmıştır (Mallat, 1988). Şekil 3.1’de gösterildiği üzere temel alçak frekans bandına çoklu çözünürlüklü dalgacık ayrıştırma uygulaması için alçak geçiren ve yüksek geçiren filtre uygulanır. Elde edilen çıktılara tekrar alçak ve yüksek geçiren filtre uygulandığında dört adet frekans bandı edilir. Bu frekans bantları: temel alçak frekans (LL), yatay orta frekans (HL), dikey orta frekans (LH) ve köşegensel yüksek frekans (HH) olarak adlandırılır. Çoklu çözünürlük yöntemi ile doku analizi yapılabilmektedir.



Şekil 3.1. Çoklu çözünürlüklü dalgacık ayrıştırma işlemi

3.3.1.2. 2 Boyutlu dalgacık dönüşümü

Bir görüntüye ayırık dalgacık dönüşümü uygulandığında, dört adet frekans bandına dönüştürülür. Bu dört frekans bantları; temel alçak frekans (LL), yatay orta frekans (HL), dikey orta frekans (LH) ve köşegensel yüksek frekans (HH) olarak ayrılmaktadır. Bir seviye daha dalgacık dönüşümü uygulanmak istenirse, en son oluşturulmuş olan LL bandına tekrardan ayırık dalgacık dönüşümü uygulanır.

Görüntü, 2-B ölçek fonksiyonu ve 2-B dalgacık fonksiyonları kullanılarak yaklaşık bileşenlere ve ayrıntı bileşenlerine ayrıştırılır.

$$\phi_{j,m,n}(x,y) = 2^{\frac{j}{2}} \phi(2^j x - m, 2^j y - m) \quad (3.8)$$

$\phi_{j,m,n}(x,y)$ ölçek fonksiyonudur.

$$\psi^i_{j,m,n}(x,y) = 2^{\frac{j}{2}} \psi^i(2^j x - m, 2^j y - m) \quad i = H, V, D \quad (3.9)$$

$\psi^i_{j,m,n}(x,y)$ dalgacık fonksiyonudur. ψ^H yatay değişimleri, ψ^V ise dikey değişimleri ve ψ^D ise köşegensel değişimleri göstermektedir.


İki boyutlu ayrık dalgacık dönüşümü ile görüntü analizleri aşağıdaki şekilde gösterilmektedir:

$$W_\phi(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \phi_{j_0,m,n}(x,y) \quad (3.10)$$

$$W_\psi^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \psi^i_{j,m,n}(x,y) \quad (3.11)$$

Burada $f(x,y)$ görüntü yoğunluğunun fonksiyonudur. Görüntünün boyutu $M \times N$ 'dir. j_0 rastgele başlangıç ölçeğini belirtir. Eğer $j_0 = 0$ alınırsa $N = M = 2^j$ dir. $j = 0, 1, 2, \dots, J-1$ ve $m, n = 0, 1, 2, 3, \dots, 2^{j-1}$ değerlerini alır. Üç yönlü detay bileşeni $W_\psi^i(j, m, n)$ ile tanımlanır.

2-D ayrık dalgacık dönüşümü ile yüksek skaladan alçak skalaya ayrıştırma işlemi, Şekil 3.2'de gösterilmektedir. LL (W 'ye karşılık gelir), yaklaşık bileşenleri gösterir. HH, HL, LH (ψ^D , ψ^H ve ψ^V 'ye karşılık gelir) ayrıntılı bileşenleri belirtir. İkinci seviye ayrıştırma, yukarıdaki işlem olarak LL1 bileşeni üzerinde genişletilir. Şekil 3.2'de iki boyutlu ayrık dalgacık birinci ve ikinci seviye ayrıştırma gösterilmektedir.



Şekil 3.2. İki boyutlu ayrık dalgacık dönüşümü kullanılarak görüntü analizi: birinci seviyede ayrışma (a), ikinci seviyede ayrışma (b)

3.3.2. Shannon entropi

Entropinin tanımı için birkaç ifade vardır. Bu ifadelerden bazıları bilgi miktarı, rastlantınlık, düzensizlik vb. ifadelerdir. Çalışmamız için en uygun tanım ise düzensizlik ve rastgelelik ölçüsü olacaktır. Entropi kavramını ilk olarak Rudolf Clausius kullanmıştır (Cropper, 1986). Bu kavram üzerine birçok bilim insanının katkısı ve yorumu olmuştur. Bu çalışmada Mathematical Theory of Communication kitabında bu kavrama yer veren Claude Elwood Shannon entropi kavramını tercih etmiştir. Shannon entropiyi, bilgi kaynağının olasılıklı davranışı olarak da tanımlamaktadır (Shannon, 2001).

$$E(p_1, p_2, \dots, p_n) = -K \sum_{i=1}^n p_i \log p_i \quad (3.12)$$

p olasılığı ifade etmektedir. Ayrıca K pozitif bir sayıdır.

3.3.3. Gri seviyeli eş-oluşum matrisleri

Gri seviye eş oluşum matrisi (Gray Level Co-Occurrence Matrices-GLCM) 1970'lerde M. Haralick tarafından doku analizi için önerilen istatistiksel bir yöntemdir. Yöntemin diğer bir ismi ise Haralick matrisi olarak geçmektedir. Haralick ve arkadaşları 1973'te yayınladığı makalede gri seviye eş oluşum matrisinden 14 tane öznelik çıkarabileceğini ifade etmiştir. Bu özneliklerden bazıları açısıl moment, kontrast, korelasyon, varyans, ikinci ters diferansiyel momenttir (Haralick vd., 1973). Fakat 1980'de Richard W. Connors ve arkadaşı tarafından 5 özneliğe indirgenmiştir. Bu beş öznelik, enerji, entropi, korelasyon, yerel homojenlik ve eylemsizliktir. Akademik ve endüstriyel alanlarda daha çok bu maddeler tercih edilmiştir. GLCM'de, gri tonlu bir görüntünün iki komşu piksel arasındaki ilişkisi irdelenmektedir. Bu iki pikselin ilkinde referans piksel ikinci piksele ise komşu piksel adı verilir. Bu iki piksel arasındaki mesafe ve açısıl bilgi önem arz etmektedir.

$$C_d[i, j] = |\{ [r, c] \mid I[r, c] = i \text{ ve } I[r + dr, c + dc] = j \}| \quad (3.13)$$

Burada $C_d[i, j]$ gri eş oluşum matrisini tanımlar.

$$N_d[i, j] = \frac{C_d[i, j]}{\sum_i \sum_j C_d[i, j]} \quad (3.14)$$

$N_d[i, j]$ ise normalize edilmiş gri eş oluşum matrisi tanımlamaktadır.

$$Enerji = \sum_i \sum_j N_d^2[i, j] \quad (3.15)$$

$$Entropi = \sum_i \sum_j N_d[i, j] \log_2 N_d[i, j] \quad (3.16)$$

$$Kontrast = \sum_i \sum_j (i - j)^2 N_d[i, j] \quad (3.17)$$

$$Homojenlik = \sum_i \sum_j \frac{N_d[i, j]}{1 + |i - j|} \quad (3.18)$$

$$Korelasyon = \frac{\sum_i \sum_j (i - \mu_i)(j - \mu_j) N_d[i, j]}{\sigma_i \sigma_j} \quad (3.19)$$


μ_i, μ_j , ortalamalardır; σ_i ve σ_j satır ve sütun $N_d[i]$ ve $N_d[j]$ toplamalarının standart sapmalarıdır.

Entropi: Görüntünün düzensizliği hakkında bilgi vermektedir. Dokulardaki değişim fazla ise entropi değeri yüksektir.

Kontrast: Görüntünün zıtlığı hakkında bilgi verir.

Homojenlik: Görüntünün farklı bölgelerindeki benzerliğinin bir ölçüsüdür.

Korelasyon: Görüntünün doğrusallığı hakkında bilgi verir.




Şekil 3.3. Gri seviye eş oluşum matrisi çıkarılması sırasındaki mesafe ve açı bilgisinin uygulanması

Şekil 3.3'te örnek olarak 5*5 matrisin merkez noktasına göre mesafe açısal bilgilere bağlı olarak d=2 ve 90° değerleri ve d=1 ve 135° değerlerin matris üzerinde uygulaması gösterilmektedir. Bununla birlikte temsili matrislerde açısal bilgilerin uygulaması ifade edilmektedir.

3.4. Derin Öğrenme

Derin öğrenme, bir veriyi tanıma, tanımlama, sınıflandırma veya tahmin etme gibi insani davranışların bilgisayarlar tarafından yapılabilmesini sağlayan makine öğrenmesinin alt kümesidir. Makine öğrenmesi ise yapay zekanın alt kümesi olarak kabul edilir. Şekil 3.4' de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki ifade edilmektedir.



Şekil 3.4. Yapay sinir ağları, makine öğrenmesi ve derin öğrenme diyagramları

Makine öğrenmesinde girdi olarak, ham veri yerine o ham veriden manuel olarak elde edilen öznitelikler sisteme dahil olur. Fakat burada doğru öznitelikleri seçmek önemlidir. Doğru seçilemeyen öznitelikler doğru karar verme yetisini saptırmaktadır. Buna ek olarak makinenin eğitim süresini uzatabilmektedir. Derin öğrenmede ise girdi olarak ham veriyi kullanabiliriz. Bu sayede ham veriden insanlar tarafından öngörülemeyen özniteliklerin sisteme dahil olması sağlanır. Bu yöntemin kullanılması istenirse, makinenin eğitimi için makine öğrenmesi yöntemine kıyasla daha fazla veriye ihtiyaç duyulacaktır. Ek olarak makine öğrenmesine karşılık, daha güçlü donanımsal cihazlara ihtiyaç duymaktadır. Her geçen gün ilerleyen donanımsal gelişmelerle derin öğrenme mimarileri gelişmekte ve artmaktadır. En çok tercih edilen mimariler ise evrişimli sinir ağları (CNN, ConvNet), tekrarlayan sinir ağları (RNN), uzun kısa süreli hafıza (LSTM), sınırlı Boltzman makineleri (RBM), derin inanç ağı (DBN) ve derin oto-kodlayıcılarıdır.

Tekrarlayan sinir ağları temelleri, Jeff Elman tarafından basit tekrarlayan sinir ağları ile atılmıştır. Tekrarlayan sinir ağları temel düşünce olarak, sadece o an ağı giren girdileri değil zamansal olarak daha önceki girdileri de ağı dahil eder. Bu sayede sıralı bilgileri kullanabilmiş olur. Örneğin makine böylece bir cümledeki kelimenin anlamını, daha önceki kelimelerden yola çıkarak anlayabilir. Örnekten de anlaşılacağı üzere daha çok doğal dil işleme (NLP) alanında tercih edilmektedir.

Uzun-kısa süreli hafıza, mimari olarak tekrarlayan sinir ağlarına benzemektedir. Hochreiter ve Schmidhuber tarafından geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). RNN'den farklı olarak hafıza hücreleri bulunmaktadır. Hafıza hücreleri ile önceki durum girdilerini saklayabilir ya da silebilir. Bu sayede dizi içerisindeki bağlamı daha düzenli hale getirmektedir.


Sınırlı Boltzman makineleri, girdi seti üzerinde olasılık dağılımlarını öğrenebilen rastlantısal bir yapay sinir ağıdır. Mimari genel olarak sınıflandırma ve regresyon işlemleri için tercih edilmektedir (Le vd., 2011).

Derin inanç ağı, Hinton tarafından sınırlı Boltzman makineleri yığınlarına sahip bir mimaridir. Bu mimari daha çok görüntü tanıma ve üretme alanında tercih edilmektedir.

Derin oto-kodlayıcılar, denetimsiz öğrenme yöntemi olarak kullanılır. Mimari de girdileri sıkıştırarak minimum kayıpla sisteme dahil olur. Üç katmandan oluşmaktadır. Bu katmanlar, girdi katmanı, gizli katmanı ve çıkış katmanı olarak adlandırılırlar.

3.4.1. Evrişimli sinir ağları

Evrişimli Sinir Ağları, Yann LeCun ve arkadaşları tarafından ilk olarak 1989'da el yazısı ile yazılan rakamların sınıflandırılması için önerilmiştir. Bu mimari ile geliştirilen modele LeNet adı verilmiştir (Lecun vd., 1998). Şekil 3.5'te LeNet-5 modelinin katman yapısı gösterilmektedir. Fakat o yıllarda büyük veri yetersizliği ve donanımsal yetersizlikten dolayı belli bir süre çalışmalar yavaş ilerlemiştir. Bu süreç boyunca bu tarz problemleri genel görüntü işleme yöntemleri ile çözüme ulaştırmaya çalışmışlardır. Ama ilerleyen süreçle birlikte teknolojiye gelişmeler ve büyük veriler ile mimari beklenen ilgiyi görmüştür. Burada teknolojik olarak GPU kullanılmaya başlanmasının etkisi büyüktür. Şu anda derin öğrenme mimarilerinden en çok ilgi gören, üzerinde çalışılan ve geliştirilen mimaridir. Mimari görüntü sınıflandırma, görüntü ve videolardan nesne tanıma, sinyal işleme vb. birçok alanda tercih edilmektedir.



Şekil 3.5. LeNet-5 modelinin katmanları (Lecun vd., 1998)

3.4.2. Evrişimli sinir ağı katman yapısı

Evrişimli sinir ağı temel olarak üç katmandan oluşmaktadır. Bu katmanlar evrişim katmanı, havuzlama katmanı ve tam bağlı katmanlardır. Bu katmanların yanında aktivasyon katmanı, yığın normalizasyon katmanı ve düğüm seyreltme katmanları da kullanılarak modelin başarı oranı artırılabilir.


3.4.2.1. Evrişim katmanı

Evrişim katmanında matematiksel işlem olan evrişim (konvolüsyon) işlemi gerçekleştirilmektedir. Bu katmanda iki boyutlu evrişim kullanılmaktadır. Evrişim işleminde iki matris kullanılmaktadır. Birinci matris görüntü matrisidir. İkinci matris ise seçilen filtre matrisidir. Evrişim işleminde, görüntü matrisinin başından başlayarak seçilen filtre boyutu kadar bölge karşılıklı olarak çarpılır. Bu çarpma işlemi sonunda toplanır. Bu işlem

bütün görüntü boyunca kaydırılarak devam edilir. Bütün işlem bittiğinde yeni bir matris elde edilir. Elde edilen matris de öznelik tespitine yardımcı olur.

$$Y[x, y] = \sum_j \sum_i X[i, j] h[x - i, y, -j] \quad (3.20)$$


Denklemleri açıklarsak X matrisi görüntü/girdi matrisidir. h matrisi ise evrişim filtresidir. Y matrisi işlem sonucu elde edilen görüntü matrisidir.



Şekil 3.6. Evrişim işleminin matris uygulaması (Sameep Tandon, t.y.)

Şekil 3.6'da Örnek olarak 5*5 boyutunda girdi matrisine 3*3 boyutunda evrişim matrisi uygulanmaktadır. Bu evrişim matrisi sırayla sağa tarafa birer adım kaydırılarak devam etmektedir. Matrisin sonuna gelindiğinde bir satır alta kaydırılır. Bu işlem bütün matris tamamlanana kadar devam eder. İşlem sonunda 3*3 boyutunda yeni görüntü matrisi elde edilir.

Bu işlem renkli görüntülerde 3 renk katmanı (RGB) için ayrı ayrı gerçekleştirilir. Daha sonrasında elde edilen üç matris tekrardan birleştirilir. Şekil 3.7'de 6*6*3 boyutunda girdi matrise (RGB) 3*3*3 boyutunda evrişim matrisi uygulanmıştır.




Şekil 3.7. RGB görüntü için evrişim işlemi

Evrişim işlemi sonrasında, girdi matrisi, çıkış matrislerinde boyut farkını yönetebilmektedir. Bu kısımda iki yöntem vardır. Birinci yöntem olan same padding yöntemi matris çevresini benzer değerler ile doldurulabilir. İkinci yöntem olan zero padding ise matris çevresini sıfır değeri ile doldurulabilir. İki yöntemden birisi tercih edilmelidir (Dumoulin ve Visin, 2018).

3.4.2.2. Havuzlama katmanı

Havuzlama katmanında görüntü matrisinin kanal sayısı sabit tutularak piksel sayısı azaltılır. Bu sayede ağdaki parametre sayısı ve hesaplama yükü azalır bununla birlikte çalışma hızı artar. Aynı zamanda aşırı öğrenme etkisi azaltılmış olur. Fakat bu işlem sırasında veri kaybına bağlı olarak başarımlarından ödün verilmektedir. Bu katmanda öğrenilen herhangi bir parametre yoktur. Havuzlama tekniği olarak maksimum, ortalama, minimum vb. teknikler mevcuttur. Genellikle maksimum havuzlama tekniği kullanılmaktadır. Maksimum havuzlama tekniğinde girdi, matrisin başlangıcından başlayarak havuzlama boyutu kadar alana karşılık gelen kısımda en büyük değeri seçer. Bu işleme havuzlama boyutu kadar kaydırılarak girdi boyunca devam edilir. Bu işlem sonucunda, elde edilen maksimum değerlerden oluşan bir matris elde edilir. Minimum havuzlamada ise minimum değer seçilir. Ortalama havuzda ise bu seçilen alanın ortalaması alınır ve bu değer kullanılır (Gholamalinezhad ve Khosravi, 2020).




Şekil 3.8. Maksimum havuzlama, ortalama havuzlama, minimum havuzlama teknikleri

Şekil 3.8’de örnek olarak 4*4 boyutunda girdi matrisine, havuzlama uygulanmıştır. Sırayla maksimum havuzlama, ortalama havuzlama ve minimum havuzlama çıktı matrisleri hesaplanmış ve gösterilmiştir.

3.4.2.3. Tam bağlı katman

Tam bağlı katman, CNN en son katmanında bulunur. Bu katmanda girdi olarak gelen matris tek boyutlu vektöre dönüştürülür. Bu dönüştürme sonrasında vektör yapay

sinir ağırlarına verilir. Şekil 3.9’da örnek olarak 4*4 boyutlu bir matris tam bağlı katman uygulanarak 16*1 vektöre dönüştürülmüştür.



Şekil 3.9. Tam bağlı katmanda düzleştirme işlemi

3.4.2.4. Aktivasyon katmanı

Aktivasyon katmanı; doğrusal işlemler uygulanan sisteme anti doğrusallık katar. Bu dönüşüm aktivasyon fonksiyonları ile yapılmaktadır. Aktivasyon katmanında kullanılan doğrusal olmayan aktivasyon fonksiyonlarının ağırların daha güçlü öğrenmesine katkısı büyüktür.

Derin öğrenme modellerinde en popüler dört aktivasyon fonksiyonu ReLU, Softmax, Sigmoid, TanH’dır.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.21)$$

Sigmoid fonksiyonunun çıktı aralığı $[0,1]$ aralığındadır. İkili sınıflandırmalarda tercih edilir.

$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad (3.22)$$

TanH fonksiyonu Sigmoid fonksiyonuna çok benzemektedir. Fonksiyonun çıktı aralığı $[-1,1]$ aralığındadır.


$$f(x) = f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.23)$$

ReLU fonksiyonunda girdi değeri sıfırdan küçükse çıktı sıfır, eğer sıfırdan büyük eşit ise çıktı girdiye eşit olur. Sıfır değerini alması öğrenmeyi hızlandırmaktadır.

Softmax fonksiyonu sinir ağı fonksiyonunun çoğunlukla son katmanında tercih edilir. İki'den daha fazla sınıf bulunan sistemlerde girdinin hangi sınıfa ait olduğuna dair çıktı verir.

$$P(y = j|x) = \frac{e^{x^T w_j}}{\sum_{k=1}^K e^{x^T w_k}} \quad (3.24)$$

Burada; $x^T w$, x giriş ve w ağırlık değerlerinin iç çarpımını göstermektedir. Bu fonksiyon, tam bağlı katmanın çıktılarını normalize ettiğinden, çapraz doğrulamanın uygulanmasına ve entropi kaybının hesaplanmasına olanak tanır.



Şekil 3.9. ReLU, sigmoid, tanh ve softmax fonksiyonlarının [-4,4] aralığındaki gösterimi


3.4.2.5. Yığın normalizasyonu katmanı

Yığın normalizasyon katmanı, her bir giriş kanalının mini yığın başına bir katmana ortalama ve standart sapması hesaplanarak standardizasyonunun gerçekleştirilmesi için kullanılan bir tekniktir. Yığın normalizasyon katmanının modele etkisi ise öğrenme sürecini stabilize etme ve derin ağları eğitmek için gereken eğitim dönemi sayısını önemli ölçüde azaltma etkisine sahip olmasıdır.

3.4.2.6. Düğüm seyreltme katmanı

Evrişimli sinir ağlarında modelin fazla eğitilmesi durumunda veya az veri sayısına bağlı olarak model ezberleme başlar. Bu ezberlemeyi azaltmak veya ortadan kaldırmak için düğüm seyreltme katmanı kullanılması tavsiye edilir. Düğüm seyreltme katmanı prensip olarak sinir ağları arasında belli kurallara bağlı olarak belli nöronların kullanılmamasını sağlar. Bu sayede ezberlemeyi azaltır. Düğüm seyreltme katmanında belli bir eşik değeri seçilir. Seçilen eşik değeri oranında nöronlar kullanılmaz. Şekil 3.10'da

örnek olarak standart yapay sinir ağına düğüm seyreltme uygulanması sonrasında oluşan yapay sinir ağı temsili olarak görselleştirilmiştir.



Şekil 3.10. Düğüm Seyreltme a.) standart yapay sinir ağı b.) düğüm seyreltme uygulanmış yapay sinir ağı (Z.-S. Wang vd., 2020)

3.4.3. Veri artırma

Derin öğrenmede küçük veri seti ile geliştirilen modellerin başarı oranlarını artırmak ve modelin verileri ezberlemesini engellemek için veri artırmaya ihtiyaç duyulmaktadır. Özellikle veri sayılarının azlığından dolayı tıbbi görüntülerin elde edilmesi zorluğuna bağlı olarak sentetik veri artırma seçilmektedir. Veri artırmada orijinal görüntüyü referans alarak resmi çevirme, simetriğini alma, yeniden boyutlandırma, belli bir kısmını alma, resmi rastgele kesme, resme gürültü ekleme vb. teknikler kullanarak veriler çoğaltılır (Shorten ve Khoshgoftaar, 2019). Şekil 3.11’de örnek olarak bir görüntünün veri artırma yöntemi ile oluşturulan yeni veriler gösterilmiştir.




Şekil 3.11. Veri artırma yönteminin uygulaması sonucu elde edilen veriler

3.4.4. Derin öğrenme hiperparametreleri

3.4.4.1. Öğrenme oranı

Öğrenme oranı, modelin geri yayılım sonucunda ağırlık değerlerinin tekrardan hesaplanması sırasında kullanılan bir parametredir. Bu parametre ağırlık değerinin güncelleme hızı olarak tanımlanmaktadır. Öğrenme oranı eğitim başlamadan sabit bir değer olarak seçilebilir ya da eğitim boyunca artıp-azalan bir değer olarak ayarlanabilir.

Öğrenme oranı 0 ile 1 arasında seçilmelidir. Bu değer ne kadar büyük seçilirse model eğitim verisinden o kadar az etkilenir. Eğer değer çok küçük seçilirse model eğitim verilerinden daha çok etkilenir fakat bu süreçte eğitim süresi uzar. İdeal öğrenme modele ve eğitim verilerine göre seçilmelidir.




Şekil 3.12. Farklı öğrenme oranları uygulanan temsili modelin (a) kayıp fonksiyon dağılımları (b) doğruluk fonksiyon dağılımları (Deijn, 2018)

Şekil 3.12’de farklı öğrenme oranlarına bağlı olarak kayıp fonksiyon dağılımları ve doğruluk fonksiyon dağılımları gösterilmektedir. Model için ideal öğrenme oranı seçimi yaparken kayıp fonksiyon dağılımlarının 0’a yaklaşması istenmektedir. Bununla birlikte doğruluk fonksiyon dağılımının 1’e yaklaşması beklenmektedir. Modelin kayıp fonksiyon dağılım ve doğruluk fonksiyon dağılım eğilimlerini inceleyerek modelin öğrenme durum hakkında eksik öğrenme, aşırı öğrenme gibi yorumlarda bulunabiliriz.

3.4.4.2. Momentum

Momentum, modelin geri yayılım sonucunda ağırlık değerlerinin güncellenmesinde kullanılan bir hiperparametredir. Modelin eğitim hızını ve doğruluğu direkt etkilemektedir. Momentum çalışma prensibi olarak geri yayılım sırasında bir önceki ağırlık artış miktarını beta momentum katsayısı oranında işin içine katarak yeni ağırlık artış miktarı hesaplanmaktadır. Doğru momentum katsayısı seçimi ile salınımlar önlenir.



Şekil 3.13. Stokastik Gradyan İnişi (a) momentum değeri olmadan (b) momentum yöntemi kullanılarak (Raghuwanshi ve Pateriya, 2021)

3.4.4.3. Optimizasyon Yöntemleri

Optimizasyon yöntemleri, eğitim sırasında oluşabilecek hataları minimum seviyeye indirmek ve optimum değerleri bulabilmek için kullanılan yöntemlerdir. En yaygın optimizasyon yöntemleri Stokastik Gradyan İnişi, Adam, RMSProp ve AdaGrad gibi optimizasyon yöntemleridir. Bu yöntemleri modelin başarı ve hızında farklılıklar göstermektedir.

Stokastik Gradyan İnişi

Gradyan iniş yönteminde, tüm gradientler hesaba katılarak ağırlık hesaplamaları yapılmaktadır. Bu durum bir iterasyonun çok uzun sürmesine neden olmaktadır. Ayrıca bütün gradientler işleme dahil edildiğinden hafıza yetersizliği yaşanabilmektedir. Buna karşılık Stokastik Gradyan İnişi önerilmektedir. Stokastik Gradyan İnişte rastgele seçilen belirli sayıdaki gradient hesaba katılarak ağırlık hesaplamaları yapılır (Hardt vd., 2016).

AdaGrad

Adagrad adaptif bir yöntemdir. Adaptif yöntemler SGD yönteminde başlangıçta sabit verilen öğrenme katsayısına karşılık, başlangıçta herhangi bir öğrenme katsayısına gerek duymamaktadır. Adaptif yöntemler öğrenme oranını kendisi öğrenmektedir ve dinamiklerdir.

Adagrad'da her parametrenin kendi öğrenme hızı vardır. Her güncelleme işleminde öğrenme katsayısı değerinin bölüldüğü ifadenin eğitim süresince büyümeye devam etmesi sonucunda öğrenme katsayısı aşırı küçülmektedir (Ward vd., 2021).

RMSprop

RMSprop'da adaptif bir yöntemdir. RMSprop optimizasyon yöntemi AdaGrad optimizasyon yöntemi gibi başlangıçta sabit öğrenme katsayısına ihtiyaç duymamaktadır. AdaGrad yönteminde öğrenme katsayısının aşırı küçülmesine karşılık alternatif olarak önerilmiştir. AdaGrad yönteminde önceki bütün eğimlerin karelerini hesaplayarak değer hesaplaması yapılırken RMSprop'da buna karşılık bütün eğim yerine pencereleme yönetimi ile hesaplamayı kısıtlar. Bu sayede aşırı küçülmeyi önlemiş olur (Mukkamala ve Hein, 2017).

Adam

Adam optimizasyon yöntemi RMSprop ve momentum yöntemlerinin olumlu yönlerinin birleşimiyle geliştirilmiştir. Bu yöntemde RMSprop'daki gibi öğrenme oranı hesaplanır. Ayrıca yönteme momentum değeri dahil edilir.

3.4.5. Derin öğrenme performans ölçümü

Derin öğrenme performans ölçümü için ortalama hata (MSE) ve hata (karmaşıklık) matrisi (Confusion Matrix) tercih edilmiştir.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (3.25)$$

$$e_t = (y - \hat{y}) \quad (3.36)$$

Burada y gerçek değer, $\hat{y}$ tahmin edilen değerdir.

MSE değeri 0 değerine yakın ise başarı oranı yüksektir.

Hata matrisi, veri setindeki durum ile modelin tahminleri arasındaki ilişki modelin doğruluğu hakkında bilgi vermektedir.

$$Sen = \frac{T_p}{T_p + F_N} \quad (3.37)$$

$$Spe = \frac{T_N}{T_N + F_P} \quad (3.38)$$


$$Acc = \frac{T_p + T_N}{T_p + F_P + T_N + F_N} \quad (3.39)$$

$$Pre = \frac{T_p}{T_p + F_N} \quad (3.40)$$

$$F1\ Score = \frac{2 * T_p}{2 * T_p + F_N + F_P} \quad (3.41)$$


Burada T_p doğru pozitif, T_N doğru negatif, F_p yanlış pozitif, F_N yanlış negatiftir. Sen değeri duyarlılık, Spe özgüllük, Acc doğruluk ve Pre kesinlik faktörünü vermektedir.

3.5. Driveline Enfeksiyon Tespitinde Görüntü İşleme ve Derin Öğrenme Yönteminin Uygulanması




Şekil 3.14. Driveline bölgesinden görüntü elde edilmesi

Çalışma kapsamında Şekil 3.14'te görselleştirilen şekilde hastalardan görüntüler alınmıştır. Hastalardan elde edilen görüntülere ilk olarak ön işleme uygulanmıştır. Ön işleme aşamasında hastalardan elde edilen görüntülerde gürültü olarak nitelendirilen cilt üzerinde bulunan kıl ve/veya tüy gürültüleri temizlenmektedir. Bu işlem sayesinde cilt dokusu daha görünür ve belirgin hale gelmektedir. Şekil 3.15'te ham görüntü verisi üzerine ön işleme uygulanmış hasta görüntüsü sunulmaktadır.




Şekil 3.15. Ham görüntü üzerine önişleme uygulanmış görüntüler Ham driveline bölgesi görüntüsü (a) Önişleme uygulanmış görüntü (b)

Ön işleme başarı ile uygulandıktan sonra driveline'nin vücut bölgesine çıkış yaptığı bölgesinin tespit edebilmesi için ilk olarak cilt ve driveline arasında bölütleme yapıldı. Bölütme işlemi için K-Ortamalar algoritması uygulanmaktadır. K-Ortamalar algoritmasının seçilmesinin birkaç sebebi vardır. İlki hastaların cilt renklerinin farklı olması, ikincisi hastaların kullandığı LVAD cihazlarının farklı marka model bağlı olarak driveline renklerinin değişmesidir. Üçüncü bir sebep olarak hastaların pansuman sırasında kullandıkları ilaç sebebi ile driveline renginin değişmesidir. Bu tür sebeplerden dolayı bölütleme işleminde sabit değerler yerine dinamik bir hale getirmek için K-Ortamalar yöntemi tercih edilmiştir. Elde edilen renk sonrasında maskeler oluşturuldu. Oluşturulan maske ile bölütleme işlemi gerçekleştirilmiştir. Şekil 3.16'ta cilt dokusu driveline bölütleme çıktıları görülmektedir.



Şekil 3.16. Cilt dokusu driveline bölütleme çıktıları Ham görüntü (a) Önişleme uygulanmış görüntü (b) Driveline bölütleme uygulanmış görüntü (c) Cilt bölütleme uygulanmış görüntü (d)




Şekil 3.17. Vücut Rengi, Kablo Rengi çıkarılması

Şekil 3.17’de örnek bir bölütleme sonrası cilt ve driveline renkleri gösterilmektedir.




Şekil 3.18. Driveline’nın vücuda giriş bölgesinin tespiti

Bu işlemler sonucunda driveline vücuda giriş bölgesi tespit edilmektedir. Şekil 3.18’de ham görüntüden elde edilen ROI gösterilmektedir. Bu tespit sonrasında elde edilen görüntünün analizi ve sınıflandırma işlemi gerçekleştirilmiştir. Analizinde üç yöntem kullanılmıştır. İlk olarak Shannon Entropileri hesaplandı. İkinci olarak Ayrık Dalgacık Dönüşümü uygulanan resmin enerjisi hesaplandı. Ayrık Dalgacık olarak Haar ve Daubechies dalgacık aileleri kullanılmıştır. Üçüncü yöntem olarak GLCM yöntemi uygulanmıştır. Bu yöntem kullanılırken uzaklık olarak 1,2,3 ve açısal olarak $0^\circ, 45^\circ, 90^\circ$ ve 135° parametreleri seçilmiştir. Bunlardan ayrı olarak sınıflandırma işlemi için derin öğrenme yöntemi tercih edilmiştir. Derin öğrenme evrişimli sinir ağ mimarisi uygulanmıştır. Geliştirilen modelde evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, yığın normalizasyonu katmanı, düğüm seyreltme katmanı, tam bağlı katmanı kullanılmıştır. Şekil 3.19’da sistemin işleyişi akış şeması üzerinden gösterilmektedir.



Şekil 3.19. Tasarlanan sistemin akış şeması


Derin öğrenme modeline girdi olarak $224 \times 224 \times 3$ görüntü verisi verilmiştir. Sequential katmanda görüntü normalize edilmiştir. Normalizasyon katmanında matrisler 255 değerine bölünerek matris değerleri 0 ile 1 aralığına dönüştürülür. Evrişim katmanında konvolüsyon işlemi gerçekleştirilmektedir. Bu işlem sonrasında matris boyutunun küçülmesi beklenmektedir. Bunu önlemek için same padding yöntemi kullanılmıştır. Bu sayede evrişim katmanı çıktısında matris verisinin boyutunda azalma olmamıştır. Matris çevresi benzer değerleri çevrelenmiştir. Yığın normalizasyon katmanında katmanın standart sapması ve ortalama değerleri hesaplanır ve standardizasyon işlemi gerçekleştirilir. ReLU aktivasyon katmanında katmandaki sıfırdan küçük değerler sıfıra çekilir. Böylece eğitim süresi kısaltılmış olur. Havuzlama katmanında maksimum havuzlama kullanılmıştır. Havuzlama matrisi 2×2 seçilmiştir. 2×2 matrisinde maksimum değer, bir sonraki katmana aktarılır. Bu işlem sonrasında girdi matris boyutu yarı yarıya düşürülerek çıktı matris boyutu hesaplanır. Bu işlem sonunda, tekrar sırayla evrişim katmanı, yığın normalizasyon katmanı, ReLU katmanı, evrişim katmanı, yığın normalizasyon katmanı, ReLU katmanı ve havuzlama katmanı kullanılmıştır. Bu işlem sonrasında $56 \times 56 \times 32$ matrisi elde edilmiştir. İşlemde düğüm seyreltme katmanı kullanılmıştır. Düğüm seyreltme katmanı prensip olarak sinir ağlarındaki belli bir standartla belli orandaki sinir ağlarının kullanılmamasını sağlar. Bu katman ile aşırı öğrenme engellenmeye çalışılır. Bu katman sonrasında tekrar sırayla evrişim katmanı, yığın normalizasyon katmanı, ReLU katmanı, evrişim katmanı, yığın normalizasyon katmanı, ReLU katmanı, havuzlama katmanı, düğüm seyreltme katmanı kullanılmıştır. Sonrasında tam bağlı katman modele eklenir. Bu katman ile matris tek boyutlu vektöre dönüştürülür. Sonrasında sırayla ReLU katmanı, düğüm seyreltme katmanı, ReLU katmanı ve en son sınıflandırma katmanı eklenmiştir. Sınıflandırma katmanında 2 sınıf olduğu için Sigmoid fonksiyonu tercih edilmiştir. Eğer 2 sınıftan daha fazla sınıf olsaydı softmax fonksiyonu tercih edilmeliydi. Şekil 3.20’de derin öğrenme modelinin katman yapısı sunulmaktadır.



Şekil 3.20. Derin öğrenme modeli katman yapısı


4. BULGULAR VE TARTIŞMA

Görüntü işleme teknikleriyle enfeksiyon durumu hakkında yorum yapabilmek için GLCM matrislerine bağlı olarak homojenlik, enerji, kontrast ve korelasyon hesaplamaları yapılmıştır. İkinci bir yöntem olarak görüntülerinin Shannon entropileri incelenmiştir. Üçüncü bir yöntem olarak ayırık dalgacık dönüşümü ile elde edilen ayrıştırma sonuçlarının enerjileri hesaplanmıştır.



Şekil 4.1 Enfeksiyonsuz(sol figürler) ve enfeksiyonlu (sağ figürler) verilerin homojenlik, enerji, kontrast ve korelasyon dağılımları


Şekil 4.1'de enfeksiyonsuz verilerin homojenlik ve korelasyon değerlerinin, enfeksiyonlu verilerden daha fazla oldukları görülmektedir. Homojenlik ortalama değerleri enfeksiyonsuz veriler için 0.35 hesaplanırken enfeksiyonlu veriler için 0.26 hesaplanmıştır.



Şekil 4.2. Enfeksiyonsuz (sol figürler) ve enfeksiyonlu (sağ figürler) verilerin Shannon entropi, Haar ayırık dalgacık enerji ve db1 ayırık dalgacık enerji dağılımları


Şekil 4.2’de Enfeksiyonlu verilerin Şanon entropi değerleri enfeksiyonsuz verilerin entropi değerlerinden daha yüksek çıkmıştır. Enfeksiyonlu verilerin Şanon entropi ortalaması 7.30 hesaplanırken enfeksiyonsuz verilerin Şanon entropi ortalaması 6.80 hesaplanmıştır.

Derin öğrenme modeli geliştirilmesi sırasında, modelin eğitim için optimizasyon yöntemi seçilmesi gerekmektedir. Geliştirilen modelde dört farklı optimizasyon yöntemi uygulanmıştır. Bu optimizasyon yöntemleri SGD, Adam, RMSprop ve AdaGrad’dır




Şekil 4.3. Derin öğrenme modeline SGD optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları

Şekil 4.3’te SGD optimizasyon yöntemi uygulanmıştır. Doğruluk değeri 1’e ve kayıp değeri 0’a yaklaşmaktadır. Model için seçilecek ideal momentum değeri ve öğrenme oranı ile SGD optimizasyon yöntemi tercih edilebilir.




Şekil 4.4. Derin öğrenme modeline Adam optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları

Şekil 4.4'te Adam optimizasyon yöntemi uygulanmıştır. Epoch 30-35 arasında doğrulama kayıp değerleri 100'ün üzerinde çıkmıştır. Bu çıkış modelin başarısını düşürmektedir.



Şekil 4.5 Derin öğrenme modeline RMSprop optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları


Şekil 4.5'te RMSprop optimizasyon yöntemi uygulanmıştır. Doğrulama kaybı 0'dan uzaklaşmaktadır. Uzaklaşma modeli için seçilen optimizasyon yönteminin başarısız olduğu görülmektedir.



Şekil 4.6. Derin öğrenme modeline AdaGrad optimizasyon yöntemi uygulanması sonucu doğruluk ve kayıp dağılımları


Uygulanan optimizasyon yöntemlerinden elde edilen çıktılar ile geliştirdiğimiz model için en uygun olan optimizasyon yönteminin SGD olduğu sonucuna ulaşılmıştır. SGD seçilirken, doğrulama grafiğinde 1 değerine yaklaşılması beklenirken kayıp grafiğinde 0 değerine yaklaşılması beklenmektedir. Adam, RMSprop ve AdaGrad yöntemleri incelendiğinde, doğrulama grafiği ve kayıp grafiklerinde istenmeyen pikler oluştuğu gözlemlenmiştir.

Model için seçilen SGD optimizasyon yönteminde öncelikli olarak iki hiperparametre değeri seçilmesi gerekmektedir. Bu parametrelerden bir tanesi momentum değeridir. Model için 4 farklı momentum değeri için analiz yapılmıştır. Bu momentum değerleri seçilirken 0 ile 1 arasında olmalıdır. Analizlerde kullanılmak üzere 0, 0.5, 0.9 ve 0.99 momentum değerleri seçilmiştir.




Şekil 4.7. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.7’te SGD optimizasyon yönteminde ve momentum değeri 0 uygulanmıştır. Doğrulama kayıp değeri, eğitim kayıp değerinden daha çok sıfıra yaklaşmıştır. Bu yaklaşım, model için seçilen değerin doğru olmadığını göstermektedir.




Şekil 4.8. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.5 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.8’te SGD optimizasyon yöntemi ve momentum değeri olarak 0.5 kullanılmıştır. Doğrulama kayıp değeri, eğitim kayıp değerinden daha çok sıfıra yaklaşmıştır. Bu yaklaşım model için seçilen değerinin doğru olmadığını göstermiştir.



Şekil 4.9. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.9 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.9’te SGD optimizasyon yöntemi ve momentum değeri olarak 0.9 uygulanmıştır. Doğrulama ve kayıp değerleri istenen değerlere yaklaşmıştır. Seçilecek öğrenme oranı ile model için ideal hiperparametreler belirlenebilir.




Şekil 4.10. SGD optimizasyon yönteminin momentum hiperparametresinin değerinin 0.99 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.10'te SGD optimizasyon yöntemi ve momentum hiperparametresinin 0.99 seçilmesi sonucu doğruluk ve kayıp dağılımları gösterilmektedir. Epoch 10-20 arasındaki kayıp değerleri 1'in üzerine çıkmış olup bazı epochlarında 3'ün üzerine çıktığı görülmüştür. Bu çıkışlar model başarı oranında düşüşe neden olmaktadır.


Momentum 0 ve 0.5 doğrulama kayıp değerleri, eğitim kayıp değerlerinden daha küçüktür. Bu durum sağlıklı bir model için istenmeyen durumdur. Doğrulama kaybı, olabildiğince eğitim kaybından büyük olmalıdır ve her ikisi de sıfıra yaklaşmalıdır. Momentum değeri, 0.99 seçildiğinde salınım olacağından verilerden hızlı bir şekilde etkilenecektir. Model için en ideal momentum değerinin 0.9 olduğu tespit edilmiştir.

SGD optimizasyon yöntemi için önemli diğer hiperparametre ise öğrenme oranıdır. Öğrenme oranı 1 ile 0 arasında seçilmelidir. Öğrenme oranının sıfıra yaklaşması eğitim süresini artırmaktadır, ancak bu durumda aşırı öğrenme meydana gelir. Bunun için ideal öğrenme oranı seçilmelidir. Bu çalışmada öğrenme oranı olarak 1, 0.1, 0.01, 0.001, 0.0001, 0.00001, 0.000001 ve 0.0000001 değerleri test edilmiştir.



Şekil 4.11. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 1 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.11'te SGD optimizasyon yöntemi ve öğrenme oranı değeri olarak 1 uygulanmıştır. Doğruluk değeri eğitim boyunca sabittir ayrıca kayıp değerleri ölçülemez. Bunlara bağlı olarak model eğitimi başarısız gerçekleşmiştir.



Şekil 4.12. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.1 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.12’te SGD optimizasyon yöntemi ve öğrenme oranı olarak 0.1 uygulanmıştır. Doğruluk değeri eğitim boyunca sabittir ayrıca kayıp değerleri ölçülememiştir. Bunlara bağlı olarak model eğitimi başarısız gerçekleşmiştir.

Öğrenme oranı 1 ve 0.1 değerlerinde öğrenme gerçekleşmemiştir. Bu değerlerde kayıp değerleri oluşmamıştır.




Şekil 4.13. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.01 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.13'te SGD optimizasyon yöntemi ve öğrenme oranı 0.01 uygulanmıştır. Doğruluk grafiğinde eğitim doğrulama değerleri arasında korelasyon olması beklenmektedir.



Şekil 4.14. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.001 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.14'te SGD optimizasyon yöntemi ve öğrenme oranı 0.001 seçilmiştir. Kayıp doğrulama değerleri epoch 8-12 ve 32-40 aralığında tepe değerlere ulaşmıştır. Bu tepe değerler modelin başarı oranını düşürmektedir.



Şekil 4.15. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.0001 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.15'te SGD optimizasyon yöntemi ve öğrenme oranı olarak 0.0001 uygulanmıştır. Doğruluk grafiğinde eğitim doğrulama değerleri arasında korelasyon olması beklenmektedir.

Öğrenme oranı 0.01, 0.001 ve 0.0001 olduğunda istenen çıktılar elde edilmektedir. Fakat 0.01 değerinde kayıp değerleri diğer değerlerden daha büyüktür. Model için seçilen ideal öğrenme oranı 0.0001'dir.




Şekil 4.16. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.00001 seçilmesi sonucu doğruluk ve kayıp dağılımları

Şekil 4.16'da SGD optimizasyon yöntemi ve öğrenme oranı olarak 0,00001 uygulanmıştır. Doğrulama kayıp değeri eğitim kayıp değerinden daha çok sıfıra yaklaşmıştır. Bu yaklaşım model için seçilen değerin doğru olmadığını göstermektedir.



Şekil 4.17. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.000001 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.17’da SGD optimizasyon yöntemi ve öğrenme oranı olarak 0,000001 seçilmiştir. Doğrulama kayıp değeri eğitim kayıp değerinden daha çok sıfıra yaklaşmıştır. Bu yaklaşım model için seçilen değerin doğru olmadığını göstermektedir.



Şekil 4.18. SGD optimizasyon yönteminin öğrenme oranı hiperparametresinin değerinin 0.0000001 seçilmesi sonucu doğruluk ve kayıp dağılımları


Şekil 4.18’da SGD optimizasyon yöntemi ve öğrenme oranı olarak 0,0000001 uygulanmıştır. Doğrulama kayıp değeri eğitim kayıp değerinden daha çok sıfıra yaklaşmıştır. Bu yaklaşım model için seçilen değerin doğru olmadığını göstermektedir.

Öğrenme oranları 0.00001, 0.000001 ve 0.0000001 değerler için kayıp doğrulama değerleri kayıp test değerlerinden daha küçüktür. Bu çıktılar model için sağlıklı sonuç vermemektedir.




Şekil 4.19. SGD optimizasyon yönteminin hiperparametre olarak öğrenme oranının 0.0001 ve momentum değerinin 0.9 seçilmesi sonucu doğruluk ve kayıp dağılımları

Model için farklı optimizasyon yöntemleri uygulanmıştır. Model için SGD optimizasyon yöntemi tercih edilmiştir. SGD optimizasyon yöntemine hiperparametre seçimleri için farklı momentum ve öğrenme oranları uygulanmıştır. Bu uygulamalar sonrasında momentum değeri 0.9 ve öğrenme oranı 0.0001 seçilmiştir. Bu seçimler doğrultusunda kayıp değerleri 0’a yaklaşırken doğrulama değerleri 1’e yaklaşmıştır.



Şekil 4.20. Eğitilen modele test verilerinin gerçek ve tahmini değerlerinin dağılımı

Şekil 4.20’de eğitilen modele test için ayrılan 5 enfeksiyonlu 5 enfeksiyonsuz veri ile modelin verilerin enfeksiyon durumu hakkında tahmin gösterilmektedir. ‘+’ ile modelin tahmini değeri, ‘O’ ile gerçek değeri gösterilmektedir. Önerilen model 10 veriden 9’u veri hakkında doğru tahminde bulunmuştur.



Şekil 4.21. Eğitilen modele test verilerin normalize hata matrisi

řekil 4.21’de eęitilen modele test iin ayrılan 5 enfeksiyonlu 5 enfeksiyonsuz veri ile modelin verileri zerinden enfeksiyon durumu hakkında tahminde bulunmuřtur. Elde edilen tahmini veriler ve verilerin gerek durumları ile hata (karmařıklık) matrisi ıkarılmıřtır.

Performans lm iin iki farklı yntem kullanılmıř olup birinci yntem olan MSE ynteminde %90 bařarı oranı elde edilmiř olup, ikinci yntem olarak Hata matrisi yntemi ile modelin doęruluęu %90 doęrulukta hesaplanmıřtır.

Hata matrisi ile modelin enfeksiyonsuz veriler iin %100 doęrulukta tahmin yaparken, enfeksiyonlu verilerin tahmininde %80 oranında bařarı elde edilmektedir. Hata matrisine baęlı doęruluk deęeri 0.9 olarak hesaplanmıřtır. F1 skoru ise 0.8889 olarak elde edilmiřtir.

5. SONUÇLAR

Tez çalışmasında kalp yetersizliği yaşayan hastalara tedavi amaçlı uygulanan LVAD implantasyonu sonrasında driveline kablosunun cilt dokusundan çıkış bölgesinde yaratmış olduğu enfeksiyon durumu incelenmiştir. Öncelikle driveline'nın vücuda giriş bölgesi tespit edilmiştir. Tespit işlemi için önışleme ve bölütleme işlemleri gerçekleştirilmiştir. İşlemler sonucunda elde edilen driveline'ın vücut bölgesine giriş bölgesi analiz ve sınıflandırma için girdi olarak kullanılmıştır.

Driveline'nın vücuda giriş bölgesi analizi için gri seviye eş oluşturma matrisinden çıkarılan homojenlik, enerji, kontrast ve korelasyon bilgileri kullanılmıştır. Bu bilgiler ile enfeksiyon kapmamış hastaların cilt dokusundaki homojenlik ve korelasyon değerleri, enfeksiyon kapmış hastalara göre daha yüksek çıkmıştır. Bu da aslında önerilen yöntemi doğrulamaktadır. Çünkü enfeksiyon kapmış hastaların cilt dokularında eritem (erythema), ödem (edema), pürülan (purulent) gibi bozulmalar olmuştur. Bu bozulmalar cilt dokusundaki homojenliğin bozulduğunu doğrular. Enfeksiyon kapmış hastaların kontrast değerleri enfeksiyon kapmamış hastalara göre daha yüksek çıkmıştır. İkinci analiz yöntemi olarak Shanon entropileri kullanılmıştır. Enfeksiyon kapmış hastaların Shanon entropi değerleri enfeksiyon kapmamış hastalara göre daha yüksek çıkmıştır. Shanon entropi ile cilt dokusundaki düzensizlik ve farklılıklar matematiksel olarak ifade edilmiştir. Üçüncü analiz yöntemi olarak ayrık dalgacık dönüşümü uygulanmıştır. Ayrık dalgacık dönüşümü sonrasında elde edilen frekans bantlarının enerjileri hesaplanmıştır. Bu hesaplamalar sonucunda enfeksiyonlu hastaların enfeksiyonsuz hastalara oranla enerji değerleri daha yüksek çıkmıştır.

Derin öğrenme ile hastaların driveline enfeksiyonu durumu hakkında doğru tahminde bulunabilmek amaçlanmıştır. Bu amaçla evrişimli sinir ağı mimarisine bağlı kalınarak model geliştirilmiştir. Bu model evrişim katmanları, aktivasyon katmanları, yığın normalizasyon katmanları, düğüm seyreltme katmanları, havuzlama katmanları, tam yığın katmanı ve sınıflandırma katmanı olacak şekilde tasarlanmıştır. Modelin eğitimi için SGD optimizasyonu tercih edilmiştir. Gerçekleştirilen analizler sonucunda, optimizasyonun hiperparametreleri için 0.0001 öğrenme oranı ve 0.9 momentum değerleri seçilmiştir. Bu seçimler doğrultusunda model eğitilmiştir. Eğitilen modele eğitim verileri dışında ayrılan test verileri ile tahminde bulunmuştur. Tahmin verilerine bağlı olarak ortalama kare hatası 0,10 olarak bulunmuştur. Modelin başarı oranı %90 olarak bulunmuştur. Modelin performansını değerlendirmek için ikinci bir yöntem olarak hata matrisi kullanılmıştır. Hata matrisine bağlı olarak modelin doğruluğu 0.9 olarak elde edilmiştir. Hata matrisine bağlı olarak F1-Skoru 0.8889 olarak hesaplanmıştır.

Eldeki mevcut veriler ışığında önerilen yöntemin, klinik ortamlarda enfeksiyon tespiti, yara tespiti ve cilt kanseri tespitinde temassız bir tamamlayıcı olarak kullanılabileceği düşünülmektedir. Medikal görüntüler dışında doku analizi sınıflandırması problemlerinde modele yapılacak revizyonlarla birlikte problemin çözümüne katkısı olacağı düşünülmektedir.

Veri sayısının artırılması ile model üzerinde gerçekleştirilecek revizyonlarda birlikte önerilen yöntemin doku analizi sınıflandırılması üzerine de kullanılabileceği ön görülmektedir. Gelecek çalışma olarak enfeksiyon durumunun kademelendirilmesi enfeksiyonlu verilerin kendi içinde sınıflandırılması amaçlanmaktadır. Toplamda

enfeksiyon kapmamış, başlangıç, orta ve ileri seviyeli enfeksiyon olarak sınıflandırma yapılması planlanmaktadır.

Kalp nakli ve yapay kalp nakli alanlarında dünyada öncü bilim insanlarından olan Prof. Dr. Ömer BAYEZİD'in katkıları ile driveline kelimesinin Türkçe karşılığı olan "bağlantı kablosu" literatüre sunulmaktadır. Türkçe literatüre katkılarından dolayı Prof. Dr. Ömer BAYEZİD hocamıza teşekkür ederiz.



6. KAYNAKLAR

- Aras, S., Johnson, T., Gniady, C., Skaria, R., Khalpey, Z. 2018. "InDetector – Automatic detection of infected driveline regions". *Smart Health*, 9-10, 170-178.
- Aslam, S., Hernandez, M., Thornby, J., Zeluff, B., Darouiche, R. O. 2010. "Risk Factors and Outcomes of Fungal Ventricular-Assist Device Infections". *Clinical Infectious Diseases*, 50(5), 664-671.
- Authors/Task Force Members, Dickstein, K., Cohen-Solal, A., Filippatos, G., McMurray, J. J. V., Ponikowski, P., ... Zannad, F. 2008. "ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure 2008: The Task Force for the Diagnosis and Treatment of Acute and Chronic Heart Failure 2008 of the European Society of Cardiology. Developed in collaboration with the Heart Failure Association of the ESC (HFA) and endorsed by the European Society of Intensive Care Medicine (ESICM)". *European Heart Journal*, 29(19), 2388-2442.
- Barg, F. K., Kellom, K., Ziv, T., Hull, S. C., Suhail-Sindhu, S., Kirkpatrick, J. N. 2017. "LVAD-DT: Culture of Rescue and Liminal Experience in the Treatment of Heart Failure". *The American Journal of Bioethics*, 17(2), 3-11.
- Coll, B., Morel, J.-M. 2011. "Non-Local Means Denoising". *Image Processing On Line*, 1.
- Cropper, W. H. 1986. "Rudolf Clausius and the road to entropy". *American Journal of Physics*, 54(12), 1068-1074.
- Davis, R. C. 2000. "ABC of heart failure: History and epidemiology". *BMJ*, 320(7226), 39-42.
- Deijn, J. de. 2018. "Automatic Car Damage Recognition using Convolutional Neural Networks".
- Demirović, D. 2019. "An Implementation of the Mean Shift Algorithm". *Image Processing On Line*, 9, 251-268.
- Deng, G., Cahill, L. W. 1993. "An adaptive Gaussian filter for noise reduction and edge detection". İçinde *1993 IEEE Conference Record Nuclear Science Symposium and Medical Imaging Conference* (ss. 1615-1619). San Francisco, CA, USA: IEEE.
- Dumoulin, V., Visin, F. 2018. "A guide to convolution arithmetic for deep learning". arXiv:1603.07285 [cs, stat]. Geliş tarihi gönderen <http://arxiv.org/abs/1603.07285>
- Gholamalinezhad, H., Khosravi, H. 2020. "Pooling Methods in Deep Neural Networks, a Review". arXiv:2009.07485 [cs]. Geliş tarihi gönderen <http://arxiv.org/abs/2009.07485>
- Hannan, M. M., Husain, S., Mattner, F., Danziger-Isakov, L., Drew, R. J., Corey, G. R., ... Mooney, M. L. 2011. "Working formulation for the standardization of definitions of infections in patients using ventricular assist devices". *The Journal of Heart and Lung Transplantation*, 30(4), 375-384.
- Haralick, R. M., Shanmugam, K., Dinstein, I. 1973. "Textural Features for Image

- Classification". IEEE Transactions on Systems, Man, and Cybernetics, *SMC-3*(6), 610-621.
- Hardt, M., Recht, B., Singer, Y. 2016. "Train faster, generalize better: Stability of stochastic gradient descent". arXiv:1509.01240 [cs, math, stat]. Geliş tarihi gönderen <http://arxiv.org/abs/1509.01240>
- Hochreiter, S., Schmidhuber, J. 1997. "Long Short-Term Memory". Neural Computation, *9*(8), 1735-1780.
- Holman, W. L., Kirklin, J. K., Naftel, D. C., Kormos, R. L., Desvign-Nickens, P., Camacho, M. T., Ascheim, D. D. 2010. "Infection after implantation of pulsatile mechanical circulatory support devices". The Journal of Thoracic and Cardiovascular Surgery, *139*(6), 1632-1636.e2.
- Holman, W. L., Park, S. J., Long, J. W., Weinberg, A., Gupta, L., Tierney, A. R., ... REMATCH Investigators. 2004. "Infection in permanent circulatory support: experience from the REMATCH trial". The Journal of Heart and Lung Transplantation: The Official Publication of the International Society for Heart Transplantation, *23*(12), 1359-1365.
- Kemp, C. D., Conte, J. V. 2012. "The pathophysiology of heart failure". Cardiovascular Pathology, *21*(5), 365-371.
- LaleTokgözoğlu. t.y. "TÜRKİYE'DE KALP YETERSİZLİĞİ YOL HARİTASI Kalp yetersizliğinin ve buna bağlı ölümlerin önlenmesi amacıyla geliştirilebilecek politikalarailişkin öneriler". Türk Kardiyoloji Derneği.
- Larose, J. A., Tamez, D., Ashenuga, M., Reyes, C. 2010. "Design concepts and principle of operation of the HeartWare ventricular assist system". ASAIO Journal (American Society for Artificial Internal Organs: 1992), *56*(4), 285-289.
- Le, Q., Ngiam, J., Coates, A., Lahiri, A., Prochnow, B., Ng, A. 2011. "On Optimization Methods for Deep Learning". *Proceedings of the 28th International Conference on Machine Learning (ICML-11)* (C. 2011, s. 272).
- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P. 1998. "Gradient-based learning applied to document recognition". Proceedings of the IEEE, *86*(11), 2278-2324.
- Leuck, A.-M. 2015. "Left ventricular assist device driveline infections: recent advances and future goals". Journal of Thoracic Disease, *7*(12), 2151-2157.
- Lippi, G., Sanchis-Gomar, F. 2020. "Global epidemiology and future trends of heart failure". AME Medical Journal, *5*.
- Lüneburg, N., Reiss, N., Feldmann, C., van der Meulen, P., van de Steeg, M., Schmidt, T., ... Jansen, S. 2019. "Photographic LVAD Driveline Wound Infection Recognition Using Deep Learning". Studies in Health Technology and Informatics, *260*, 192-199.
- Mallat, S. G. 1988. "Multiresolution representations and wavelets" (Ph.D.). *ProQuest Dissertations and Theses*. University of Pennsylvania, Ann Arbor. Geliş tarihi gönderen <https://www.proquest.com/dissertations-theses/multiresolution-representations-wavelets/docview/303720387/se-2?accountid=15340>

- Martin, S. I., Wellington, L., Stevenson, K. B., Mangino, J. E., Sai-Sudhakar, C. B., Firstenberg, M. S., ... Sun, B. C. 2010. "Effect of body mass index and device type on infection in left ventricular assist device support beyond 30 days". *Interactive Cardiovascular and Thoracic Surgery*, 11(1), 20-23.
- Miller, L. W., Pagani, F. D., Russell, S. D., John, R., Boyle, A. J., Aaronson, K. D., ... HeartMate II Clinical Investigators. 2007. "Use of a continuous-flow device in patients awaiting heart transplantation". *The New England Journal of Medicine*, 357(9), 885-896.
- Monkowsky, D. H., Axelrod, P., Fekete, T., Hollander, T., Furukawa, S., Samuel, R. 2007. "Infections associated with ventricular assist devices: epidemiology and effect on prognosis after transplantation". *Transplant Infectious Disease: An Official Journal of the Transplantation Society*, 9(2), 114-120.
- Morshuis, M., El-Banayosy, A., Arusoglu, L., Koerfer, R., Hetzer, R., Wieselthaler, G., ... Nojiri, C. 2009. "European experience of DuraHeart magnetically levitated centrifugal left ventricular assist system". *European Journal of Cardio-Thoracic Surgery: Official Journal of the European Association for Cardio-Thoracic Surgery*, 35(6), 1020-1027; discussion 1027-1028.
- Mukkamala, M. C., Hein, M. 2017. "Variants of RMSProp and Adagrad with Logarithmic Regret Bounds". arXiv:1706.05507 [cs, stat]. Geliş tarihi gönderen <http://arxiv.org/abs/1706.05507>
- Pae, W. E., Connell, J. M., Adelowo, A., Boehmer, J. P., Korfer, R., El-Banayosy, A., ... Clinical Utility Baseline Study (CUBS) Group. 2007. "Does total implantability reduce infection with the use of a left ventricular assist device? The LionHeart experience in Europe". *The Journal of Heart and Lung Transplantation: The Official Publication of the International Society for Heart Transplantation*, 26(3), 219-229.
- Pagani, F. D., Miller, L. W., Russell, S. D., Aaronson, K. D., John, R., Boyle, A. J., ... Frazier, O. H. 2009. "Extended Mechanical Circulatory Support With a Continuous-Flow Rotary Left Ventricular Assist Device". *Journal of the American College of Cardiology*, 54(4), 312-321.
- Peberdy, M. A., Gluck, J. A., Ornato, J. P., Bermudez, C. A., Griffin, R. E., Kasirajan, V., ... O'Neil, B. 2017. "Cardiopulmonary Resuscitation in Adults and Children With Mechanical Circulatory Support: A Scientific Statement From the American Heart Association". *Circulation*, 135(24).
- Pereda, D., Conte, J. V. 2011. "Left ventricular assist device driveline infections". *Cardiology Clinics*, 29(4), 515-527.
- Raghuwanshi, S. K., Pateriya, R. K. 2021. "Accelerated Singular Value Decomposition (ASVD) using momentum based Gradient Descent Optimization". *Journal of King Saud University - Computer and Information Sciences*, 33(4), 447-452.
- Saito, S., Matsumiya, G., Sakaguchi, T., Miyagawa, S., Yoshikawa, Y., Yamauchi, T., ... Sawa, Y. 2010. "Risk Factor Analysis of Long-Term Support With Left Ventricular Assist System". *Circulation Journal*, 74(4), 715-722.

- Sameep Tandon, A. N. t.y. "*UFLDL Tutorial*". Geliş tarihi gönderen <http://deeplearning.stanford.edu/tutorial/supervised/FeatureExtractionUsingConvolution>
- Schnegg, B., Spano, G., Gisler, F., Walti, L., Schnegg-Kaufmann, A., Martinelli, M., ... Hayward, C. 2021. "A 10 Years Retrospective Cohort Review on Driveline Infection in Ventricular Assist Devices". *The Journal of Heart and Lung Transplantation*, 40(4), S411-S412.
- Shannon, C. E. 2001. "A mathematical theory of communication". *ACM SIGMOBILE Mobile Computing and Communications Review*, 5(1), 3-55.
- Shorten, C., Khoshgoftaar, T. M. 2019. "A survey on Image Data Augmentation for Deep Learning". *Journal of Big Data*, 6(1), 60.
- Trachtenberg, B. H., Cordero-Reyes, A., Elias, B., Loebe, M. 2015. "A Review of Infections in Patients with Left Ventricular Assist Devices: Prevention, Diagnosis and Management". *Methodist DeBakey Cardiovascular Journal*, 11(1), 28-32.
- Wang, J., Su, X. 2011. "An improved K-Means clustering algorithm". İçinde *2011 IEEE 3rd International Conference on Communication Software and Networks* (ss. 44-46). Xi'an, China: IEEE.
- Wang, Z.-S., Lee, J., Song, C. G., Kim, S.-J. 2020. "Efficient Chaotic Imperialist Competitive Algorithm with Dropout Strategy for Global Optimization". *Symmetry*, 12(4), 635.
- Ward, R., Wu, X., Bottou, L. 2021. "AdaGrad stepsizes: Sharp convergence over nonconvex landscapes". arXiv:1806.01811 [cs, stat]. Geliş tarihi gönderen <http://arxiv.org/abs/1806.01811>
- Zinoviev, R., Lippincott, C. K., Keller, S. C., Gilotra, N. A. 2020. "In Full Flow: Left Ventricular Assist Device Infections in the Modern Era". *Open Forum Infectious Diseases*, 7(5), ofaa124.

7. EKLER

Ek-1 Geliştirilen Python Kodları

Tez süresince geliştirilen kodlar teze dahil edilmemiştir. Kodları kemalkandemir07@gmail.com adresi üzerinden iletişime geçerek isteyebilirsiniz.



ÖZGEÇMİŞ

KEMAL KANDEMİR

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2017-2021	Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim dalı, Antalya
Lisans	Akdeniz Üniversitesi
2013-2017	Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Antalya

MESLEKİ VE İDARİ GÖREVLER

Elektrik-Elektronik Mühendisi	İnnolife Mekatronik Mühendislik ve Danışmanlık San. Tic. Ltd. Şti
2017-Devam Ediyor	İzmir

ESERLER

Uluslararası hakemli dergilerde yayımlanan makaleler

1- Carlak, H.F., Kandemir, & K. Ünlüsayın, M. (2021). Fisheye Imaging Approach With The Supervised Machine Learning For The Determination of Freshness of Fish *Fresenius Environmental Bullet*, (accepted)

Ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1- Kandemir, K., Topcu, C., & Carlak, H. F. (2017, August). Assessment of respiratory responses to emotional virtual reality stimuli with non-contact respiration monitoring system. In *2017 International Conference on Engineering and Technology (ICET)* (pp. 1-3). IEEE