

EĞİTİM
yayınevi

GÖRÜNTÜ İŞLEME VE YAPAY ZEKA

UYGULAMALARINDA GÜNCEL YAKLAŞIMLAR



EDİTÖRLER
DOÇ. DR. M. OZAN İNCETAŞ
DR. MAHMUT KILIÇASLAN

GÖRÜNTÜ İŞLEME VE YAPAY ZEKA

UYGULAMALARINDA GÜNCEL YAKLAŞIMLAR

Editörler

DOÇ. DR. M. OZAN İNCETAŞ
DR. MAHMUT KILIÇASLAN

EĞİTİM
yayınevi

GÖRÜNTÜ İŞLEME VE YAPAY ZEKA UYGULAMALARINDA GÜNCEL YAKLAŞIMLAR

Editörler: Doç. Dr. M. Ozan İncetaş, Dr. Mahmut Kılıçaslan

Genel Yayın Yönetmeni: Yusuf Ziya Aydoğan (yza@egitimyayinevi.com)

Genel Yayın Koordinatörü: Yusuf Yavuz (yusufyavuz@egitimyayinevi.com)

Sayfa Tasarımı: Kübra Konca Nam

Kapak Tasarımı: Eğitim Yayınevi Grafik Birimi

T.C. Kültür ve Turizm Bakanlığı

Yayıncı Sertifika No: 76780

E-ISBN: 978-625-6251-72-4

1. Baskı, Temmuz 2024

Kütüphane Kimlik Kartı

GÖRÜNTÜ İŞLEME VE YAPAY ZEKA UYGULAMALARINDA GÜNCEL YAKLAŞIMLAR

Editörler: Doç. Dr. M. Ozan İncetaş, Dr. Mahmut Kılıçaslan

IV+119 s., 135x215 mm

Kaynakça var, dizin yok.

E-ISBN: 978-625-6251-72-4

Kitapta yer alan yazıların sorumluluğu yazarına aittir.

Eser'de kitapta yer alan bölümlerden, şekillerden, resimlerden, şablonlardan, bölüm yazarları sorumludur. Editör /Yayıncı hiçbir şekilde sorumlu tutulamaz ve sorumluluk kabul etmeyeceğini beyan eder.

Copyright © Bu kitabın Türkiye'deki her türlü yayın hakkı Eğitim Yayınevi'ne aittir. Bütün hakları saklıdır. Kitabın tamamı veya bir kısmı 5846 sayılı yasanın hükümlerine göre kitabı yayımlayan firmanın ve yazarlarının önceden izni olmadan elektronik/mekanik yolla, fotokopi yoluyla ya da herhangi bir kayıt sistemi ile çoğaltılamaz, yayımlanamaz.

EĞİTİM

yayınevi

Yayınevi Türkiye Ofis: İstanbul: Eğitim Yayınevi Tic. Ltd. Şti., Atakent mah.

Yasemen sok. No: 4/B, Ümraniye, İstanbul, Türkiye

Konya: Eğitim Yayınevi Tic. Ltd. Şti., Fevzi Çakmak Mah. 10721 Sok. B Blok,

No: 16/B, Safakent, Karatay, Konya, Türkiye

+90 332 351 92 85, +90 533 151 50 42, 0 332 502 50 42

bilgi@egitimyayinevi.com

Yayınevi Amerika Ofis: New York: Eğitim Publishing Group, Inc.

P.O. Box 768/Armonk, New York, 10504-0768, United States of America

americaoffice@egitimyayinevi.com

Lojistik ve Sevkiyat Merkezi: Kitapmatik Lojistik ve Sevkiyat Merkezi, Fevzi Çakmak

Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye

sevkiyat@egitimyayinevi.com

Kitabevi Şubesi: Eğitim Kitabevi, Şükran mah. Rampalı 121, Meram, Konya, Türkiye

+90 332 499 90 00

bilgi@egitimkitabevi.com

İnternet Satış: www.kitapmatik.com.tr

+90 537 512 43 00

bilgi@kitapmatik.com.tr

İÇİNDEKİLER

BEYİN TÜMÖRÜ BÖLÜTLEMEDE GÜNCEL YAKLAŞIMLAR 1

Murat Uçar

ŞEKİL TEMSİL METOTLARI 15

Haydar Tuna

GÖRÜNTÜLEME UYGULAMALARINDA YAYINIM FİLTRELERİNİ GELİŞTİRMEK İÇİN KULLANILAN SON TEKNİKLER37

Ufuk Tanyeri

KARDİYOVASKÜLER HASTALIKLARIN ERKEN TEŞHİSİNDE MAKİNE ÖĞRENİMİ: 2019-2024 YILLARI ARASI İNCELEME58

Rukiye Uzun Arslan, İrem Şenyer Yapıcı

YOLO SERİLERİ İLE GÖRÜNTÜ SEGMENTASYONU: TEMELLER, YÖNTEMLER VE UYGULAMALAR82

Mehmet Ali Şimşek, Ahmet Sertbaş, Hadi Sasani

ANNE SAĞLIĞI RİSK GRUPLARININ BELİRLENMESİNDE MAKİNE ÖĞRENMESİ YAKLAŞIMLARI 104

Rukiye Uzun Arslan, İrem Şenyer Yapıcı 104

BEYİN TÜMÖRÜ BÖLÜTLEMEDE GÜNCEL YAKLAŞIMLAR

Murat Uçar¹

Özet

Beyin kanseri, hastaların yaşamları üzerinde olumsuz etkilere neden olan yıkıcı ve yaşamı tehdit eden bir hastalıktır. Bu nedenle, beyin tümörlerinin erken evrede tespiti tedavilerin etkisini iyileştirir ve hastaların sağ kalma oranlarını artırır. Beyin tümörü çalışmalarında, anormal dokuların varlığı çoğu zaman kolayca tespit edilebilir. Ancak, anormalliklerin doğru ve tekrarlanabilir bölütlenmesi ve karakterizasyonu basit değildir. Tıbbi görüntüleme ve bilişim alanındaki birçok araştırmacı beyin tümörü segmentasyonu alanında önemli araştırmalar yapmıştır. Hem yarı otomatik hem de tam otomatik yöntemler önerilmiştir. Bölütleme tekniklerinin klinik kabulü, bölütleme işleminin basitliğine ve kullanıcı denetiminin derecesine bağlıdır. Bu derlemede, görüntünün elde edilmesinden sonra gerçekleştirilen derin öğrenme temelli tam otomatik beyin tümörü bölütleme yöntemleri incelenmiş ayrıca manyetik rezonans görüntülemenin diğer tanısal görüntülemelere göre avantajları göz önüne alındığından, manyetik rezonans görüntülerini kullanan yaklaşımlara odaklanılmıştır. Yapılan inceleme beyin tümörü bölütlemenin geliştirilen yeni yaklaşımların hızla uygulandığı

¹ Bilgisayar Mühendisliği Bölümü, İzmir Bakırçay Üniversitesi, İzmir, murat.ucar@bakircay.edu.tr, ORCID: 0000-0001-9997-4267

araştırmacıların dikkatini çeken, aktif bir çalışma alanı olduğunu ortaya çıkarmıştır.

Anahtar Kelimeler: Beyin tümörü, derin öğrenme, bölütleme

Current Approaches for Brain Tumor Segmentation

Abstract


Brain cancer is a devastating and life-threatening disease that has negative effects on patients' lives. Therefore, early detection of brain tumors improves the effectiveness of treatments and increases the survival rate of patients. The presence of abnormal tissues in brain tumor research is generally easy to identify. However, it is not easy to accurately and reproducibly segment and characterize anomalies. Many researchers in medical imaging and informatics have conducted extensive research on brain tumor segmentation. Both semi-automatic and fully automatic methods have been proposed. The clinical acceptance of segmentation techniques depends on the simplicity of the segmentation process and the simplicity of user control. In this review, deep learning-based fully automatic brain tumor segmentation methods performed after image acquisition are examined, and, considering the advantages of magnetic resonance imaging over other diagnostic imaging methods, it focuses on approaches using magnetic resonance images. The review revealed that brain tumor segmentation is an active field of study that attracts the attention of researchers, with novel techniques being created and deployed at a quick pace.

Keywords: Brain tumor; deep learning; segmentation

1. Giriş

Anormal hücrelerin kontrolden çıkarak bölünmesi ile oluşan tümörler, doku veya organın normal şekilde işlev görme yeteneğini bozabilirler [1], [2]. Beyin tümörleri, erken evrede çoğunlukla serebrum bölgesinde görünürler [2]. Kanserli tümörler kötü huylu (yüksek dereceli) veya iyi

huylu (düşük dereceli) olarak sınıflandırılırlar. Kötü huylu beyin tümörleri, iyi huylu beyin tümörlerinden daha hızlı gelişirler ve çevre dokuları enfekte etme olasılıkları daha yüksektir [3]. Doktorlar beyin tümörlerini teşhis etmek için beyin tomografisi, manyetik rezonans görüntüleme (MRG) ve pozitron emisyon tomografisi (PET) taramaları kullanır [4]. MRG görüntülerinde yer alan farklı modalitelerin önemi Şekil 1’de ifade edilmektedir. Tümörlerin erken teşhis edilmesi hastalığın tedavisi için faydalıdır [5]. Beyin tümörü tedavisinde kemoterapi ve radyasyon seçenekleri kullanılabilir. Bu seçenekler dışında tümörün beyine uyguladığı baskı nedeniyle cerrahi yöntemlerde yaygın olarak tercih edilmektedir [6], [7].



Şekil 1. Farklı modalitelerde beyin tümörünün görüntüsü [8]

Klinik uygulamada, tümörün belirlenmesi genellikle deneyimli bir radyolog tarafından gerçekleştirilir. Radyolog etkilenen bölgeleri bölümlere ayırarak hastaların taranmış görüntülerini inceler. Bu işlem neticesinde elde edilecek başarı intra ve interrater değişkenliğe tabidir [9]. Bu belirleme yöntemi sadece nitel değerlendirme veya görsel inceleme

ile sınırlıdır. Beyin tümörlerinin kantitatif değerlendirilmesi, tedavi planlaması için tümör özelliklerinin daha iyi anlaşılmasına yardımcı olur ayrıca hastalığın ilerlemesi ve anatomik yapı üzerindeki etkilerinin anlaşılması için değerli bilgiler sağlar [10], [11]. Deneyimli radyologlar tarafından gerçekleştirilen tümör belirlenmesi en doğru sonuçları sağlasa da büyük veri tabanlarında yer alan görüntülerin analizi için verimli olmayacaktır. Bu nedenle birçok araştırmacı beyin tümörlerinin ölçeklenebilir şekilde otomatik bölütlenmesi için görüntü bölütleme algoritmaları üzerinde çalışmaktadır [12].

Görüntü bölütlemenin temel amacı, görüntüyü birbirini dışlayan bölgelere ayırarak her bölgenin uzamsal olarak bitişik olmasını ve bölgedeki piksellerin belirli bir kritere göre homojen olmasını sağlamaktır [13]. Bölütlenecek tümörler çoğu zaman sertlik ve şekil bakımından hastadan hastaya önemli ölçüde değişkenlik gösteren anatomik yapılardır, bu bölgelerin doğru ve tekrarlanabilir şekilde bölütlenmesi zorlu bir görüntü işleme görevidir [14].

Son yıllarda artan derin öğrenme çalışmaları birçok alanda olduğu gibi tıp alanında da uzmanlara yardımcı sistemlerin geliştirilmesini hızlandırmış ve başarılarını arttırmıştır. Bu derleme çalışmasında özellikle son 5 yıl içerisinde beyin tümörü bölütleme için geliştirilen derin öğrenme modellerine dair bir inceleme sunulmaktadır.

2. Beyin Tümörü Bölütlemeye Derin Öğrenme Temelli Çalışmalar

Beyin tümörlerinin erken teşhisi, tedavinin başarısı için önemli bir faktördür. Tümörün tespitinin yanı sıra tedavi sürecinde tümör boyutundaki değişiklikler takip edilmelidir. Bu noktada tümör bölgesinin otomatik olarak bölütlenmesine imkân tanıyan karar destek sistemleri hekimlere fayda sağlamaktadır. Bu kısımda tümör tespit süreçlerini otomatikleştirmek için derin öğrenme temelli modeller geliştirmeye odaklanmış çalışmalar incelenmiştir.

Ventakasubbu ve Ramasubramanian [15] tam bağlantılı evrişim katmanları kullanan bir derin öğrenme modeli önermişlerdir. Önerilen modeli eğitmek ve test etmek için LGG MRI [16] veri setini kullanmışlardır. Modelin başarısını arttırmak için görüntüler üzerinde ön işleme süreçleri ile MRG görüntülerindeki kemik dokularını temizlemişlerdir. Önerdikleri modeli eğitmek için Relu ve Leaky Relu aktivasyon fonksiyonlarını denemişlerdir. Gerçekleştirdikleri testler sonucunda Leaky Relu aktivasyon fonksiyonu ile %87.00 lik bir dice değeri elde etmişlerdir.

Bouchaour ve Mazouzi [17] gerçekleştirdikleri çalışmada birden çok evrişimli yapay sinir ağı sınıflandırıcısı ve bu sınıflandırıcı sonuçlarını değerlendiren bir ada boost sınıflandırıcısından oluşan hibrit bir model önermişlerdir. Önerdikleri model MRG görüntülerini bir adımda bölütleme yerine görüntülerden alınan parçalar üzerinde çalışmaktadır bu nedenle bir görüntünün bölütlenmesi için modelin birden çok kez çalışması gerekmektedir. Bu dezavantajına rağmen önerilen yöntem hibrit modellerin tümör bölütlemede kullanılabileceğini ortaya koymuştur. Çalışmalarını BraTS2014 veri seti üzerinde test etmişler ve tümör çekirdeğinin tespitinde %86.46 lık bir dice skora ulaştıklarını rapor etmişlerdir.

Aboussaleh ve arkadaşları [18] önerdikleri mimaride evrişim katmanları yerine inception bloklarını kullanan bir U-Net yapısı kullanmışlardır. Inception - UDet adını verdikleri mimari aktivasyon fonksiyonu olarak mesh fonksiyonunu kullanmaktadır. Tüm tümör bölgesine odaklanan araştırmacılar kayıp fonksiyonu olarak ikili çapraz entropi fonksiyonunu kullanmışlardır. Önerilen modelin tüm tümör bölgesini tespit etmedeki başarısını ortaya koymak için üç farklı veri seti üzerinde testler yapmışlardır. BraTS2020, BraTS2018, ve BraTS2017 veri setlerinde raporladıkları dice skorları sırasıyla %87.9, %85.5, ve %83.9 olmuştur.

Ranjbarzadeh ve arkadaşları [19] hiper parametreleri Şempanze Optimizasyon Algoritması ile ayarlanmış bir

evrişimli yapay sinir ağı modeli önermişlerdir. Önerdikleri yaklaşımda MRG görüntülerinin farklı modalitelerinden çıkartılan özellikler evrişimli sinir ağına iletilmeden önce şempanze optimizasyon algoritması ve destek vektör makineleri ile gerçekleştirilen bir özellik seçimi adımına tabi tutulmaktadır. Çalışmalarında tüm tümör bölgesini dikkate alarak iki sınıflı bölütleme yapan araştırmacılar BraTS2018 veri setinde %97.04 dice skoruna ulaşmışlardır.

Kumar ve Biswal [20] U-Net mimarisini temel almış ve bu modelin kodlayıcı bloğuna hem düşük seviyeli hem de yüksek seviyeli özellikleri çıkarmasını sağlayan çok ölçekli özellik toplama ve evrişim bloğu dikkat modüllerini entegre etmişlerdir. Ayrıca, çıkarılan özellikleri, paralel bir havuzlama modülüne tabi tutmuşlardır. Bu özelliklere ek olarak önerdikleri modele paralel genişletilmiş bir bağlam toplama modülü eklemişlerdir eklenen bu modülün en boy oranını arttırarak bulanık kenar sorunlarını ortadan kaldırdığını ifade etmişlerdir. Önerdikleri yaklaşımın BraTS2018 veri seti ile tüm tümör bölgesinin tespitinde %90.1 dice değerine ulaştığını rapor etmişlerdir.

Zou Ke ve Yuan [21] kodlayıcı ve kod çözücü bloklar ve bu blokların devamında belirsizlik durumlarında karar vermek için Dirichlet dağılımından faydalanan bir model önermişlerdir. Önerdikleri modelin kodlayıcı bölümünde V-Net [22] ve Attention-UNet [23]mimarilerini kullanarak başarılarını BraTS2019 veri seti üzerinde test etmişlerdir. Test sonuçlarında V-Net temelli mimarileri ile %86 civarında dice değerine ulaşmışlardır.

Yan ve arkadaşları [24]klasik U-Net mimarilerinin, beyin tümörlerinin yapısal çeşitlilikleri ve farklı yoğunlukları nedeniyle kodlayıcı bölümünde yetersiz özellik çıkarımı, kod çözücü bölümde ise bilgi kaybına neden olduğunu belirtmişlerdir. Bu problemlerin önüne geçmek için U-net katmanlarında kalıntılı katmanlar kullanılarak çıkartılan özellik bilgisini arttırmış ve ağ bozulması sorununu

çözdüklerini rapor etmişlerdir. Model eğitimleri sürecinde minimize etmeye çalıştıkları hata fonksiyonu için dice ve çapraz entropi değerlerini bir arada kullanan birleşik bir fonksiyon seçmişlerdir. Bu hata fonksiyonu ile veri dengesizliği probleminde çözüm üretmişlerdir. Geliştirdikleri modeli BraTS2018 ve BraTS2019 veri setleri ile eğitim test etmişlerdir. En yüksek başarılarını BraTS2019 veri setinde tüm tümör, tümör çekirdeği ve genişleyen tümör bölgesi için sırasıyla %93.73, %91.08 ve %87.58 dice skoru olarak elde etmişlerdir.

Bajwa ve arkadaşları [25] beyin tümörlerinin alt yapılarını kaba yapıdan inceye doğru bölütlemek için iki aşamalı bir U-Net mimarisi tasarlamışlardır. Birinci aşama sonrasında gerçekleştirilen kaba tahmin için bir adet ve ikinci aşama sonrasında gerçekleştirilen ince tahminler için ise iki adet hata fonksiyonu belirlemişlerdir. İkinci aşamada hesaplanana hata değerlerinden biri için İnterpolasyon, diğeri için ise ters evrişim katmanı kullanılmıştır. Hata fonksiyonlarının oransal bir değerini kullanmak yerine fonksiyonları birbirine ekleyerek toplam hatayı elde etmişlerdir. BRaTS2019 veri seti üzerinde gerçekleştirdikleri testler de genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %83.26 , %88.79 ve %83.26 dice skorlarını elde etmişlerdir.

Amian Mehdi ve Soltaninejad [26] iki farklı çözünürlüğe sahip iki paralel akış çizgisinden oluşan bir derin mimari önermiştir. Düşük çözünürlüklü akışı giriş verilerinin yerel özelliklerini öğrenmek için yüksek çözünürlüklü akışı tüm görüntü üzerinde küresel bir gözlem yapmak için ayarlamışlardır. İki paralel akışın çıktılarını birleştirerek nihai tahmin için Rastgele orman sınıflandırıcısı kullanmışlardır. Önerdikleri çözümü BraTS2019 veri seti üzerinde test ederek genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %70 , %72 ve %82 lik başarı rapor etmişlerdir.

Fabian ve Jäger [27] nnU-Net [28] mimarisini temel alan çalışmalarında agresif bir veri artırma yöntemi ve bölge

tabanlı eğitim yaklaşımı ile geleneksel nnU-Net mimarisi ile elde edilen başarıyı arttırdıklarını rapor etmişlerdir. Önerdikleri yaklaşımı BraTS2020 veri seti üzerinde test ederek genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %82.03, %85.06 ve %88.95 dice değerleri elde etmişlerdir.

Magadza ve Viriri [29] U-Net mimarisinde yer alan klasik evrişim katmanlarını derinlik açısından ayrılabilir evrişim katmanları ile değiştirerek modelin parametre sayısını ve karmaşıklığını azaltmışlardır. Parametre sayısında azalmadan kaynaklanan bölütleme başarısındaki düşüşe engel olmak için atlamalı bağlantılar ve dikkat katmanlarını eklemişlerdir. Çalışmalarında önerdikleri modeli BraTS2020 veri seti üzerinde test ederek genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %79.2, %91.2 ve %84.8 dice skorları elde etmişlerdir. Önerdikleri modelin 2,51M parametreye sahip olduğunu rapor etmişlerdir.

Colman ve Zhang [30] DR-Unet104 ismini verdikleri model ile klasik U-Net mimarisini atlamalı katmanlarla güçlendirmiş ve bırakma katmanları ile modelin aşırı öğrenme problemi yaşamasını ortadan kaldırarak test başarısını arttırmışlardır. BraTS2020 veri seti üzerinde elde ettikleri test sonuçlarına göre genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %86.73, %75.14 ve %79.83 dice skorları elde etmişlerdir.

Lucas ve Ourselin [31] BraTS2020 veri seti yarışmasında en başarılı dördüncü başarıyı elde ettikleri çalışmalarında model yapısı yerine kayıp fonksiyonu ve optimizasyon metoduna odaklanmışlardır. Kullandıkları model mimarisi genel bir 3D U-Net mimarisi olmakla birlikte, her bir örnek için hesaplanan kayıp fonksiyonlarını birleştirerek topluluk kaybını hesaplamak için Wasserstein Dice kayıp fonksiyonunu önermişlerdir. Kayıp fonksiyonunu minimize etmek için optimizasyon metodu olarak küçük topluluk sayılarında ve gürültülü etiketlerde daha kararlı olan ve yaygın olarak kullanılan Adam optimize edicisinin bir

genellemesi olan Ranger metodunu kullanmışlardır. Test sonuçlarında genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %81.40 , %84.10 ve %88.9 dice skorlarını elde etmiştir.

BraTS2020 yarışmasında ilk ona giren bir diğer çalışmada ise Henry ve Carré [32] tek bir derin öğrenme modeli kullanmak yerine U-Net benzeri iki farklı sinir ağını farklı parametreler ile eğiterek bir topluluk ağı oluşturmuşlardır. Modellerinin eğitimi esnasında veri arttırımı tekniklerini kullanarak aşırı öğrenmenin önüne geçmeyi amaçlamışlardır. Model parametrelerini ayarlamak için Adam yöntemini uygulamış ve eğitim adım sayısını maksimum 400 olacak şekilde belirlemişlerdir. Eğitim sonucunda iki numaralı modellerinin tümör bölgesini tahmin etmede daha başarılı olduğunu belirlemişler ve nihai sonuç için her iki modelin çıktısını değerlendirerek çıktılarının farklı olması durumunda tümör bölgeleri için iki numaralı modelin tahminini dikkate almışlardır. Test sonuçlarında genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %79 , %84 ve %89 dice skorlarını elde etmiştir.

Aboussaleh ve arkadaşları [33]3D U-Net ve V-Net [22] mimarilerinin kodlayıcısından çıkarılan özellikler ile her katmanı 3 boyutlu evrişim bloğu ve transformatör bloklarından oluşan bir kod çözücüyü besleyen hibrit bir model önermişlerdir. Önerdikleri modelin başarısını BraTS2020 veri seti üzerinde test eden araştırmacılar genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %81.70 , %82.80 ve %91,95 dice değerleri rapor etmişlerdir.

Liu ve arkadaşları [34] 3 boyutlu U-Net mimarisini temel alan bir model önermişlerdir. Önerdikleri modelde olası gürültüyü azaltmak için dikkat bloklarını kullanmışlardır. Gürültüyü azaltmak için modele ilave edilen dikkat blokları çok düşük parametre sayıları ile model karmaşıklığını arttırmadan gürültü sorununu çözmüştür. Geliştirdikleri modeli BraTS2020 ve BraTS2021 veri setleri ile test etmişlerdir. BraTS2021 veri setinde genişleyen tümör bölgesi,

tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %83.31 , %86.85 ve %91.64 skorları elde etmiştir.

Luu Huan Minhand ve arkadaşları [35] nn-UNet [28] modelini modifiye ederek ağ boyutunu arttırmış ve ağ başarısını arttırmayı hedeflemişlerdir. Model boyutunu arttırmak dışında grup normalizasyonu ve modelin kod çözücü bölümüne ekledikleri dikkat mekanizmaları ile orjinal nn-UNet [28]modeline nazaran küçük bir iyileşme sağladıklarını rapor etmişlerdir. BraTS2021 veri seti üzerinde elde ettikleri test sonuçlarına göre genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %88.35, %88.78 ve %93.19 dice skorları elde etmişlerdir.

Tang Jiarui ve Li [36] BraTS2020 veri seti üzerinde gerçekleştirdikleri çalışmalarında 3B U-Net modelini [37] ve MultiResUNet modelini [38] birleştirerek hibrit bir model tasarlamışlardır. Tasarladıkları modelin dayanıklılığını arttırmak için her bir görüntüyü 10 defa rastgele çevirerek bu verilerden 10 farklı eğitim kümesi oluşturmuşlardır ve bu eğitim kümelerini kullanarak 10 farklı model eğitmişlerdir. Test aşamasında bu modelleri bir arada kullanarak tahmin sonuçlarının ortalamasını almışlardır. Önerdikleri yaklaşım ile genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %70, %89 ve %79 dice skorlarını elde etmişlerdir.

Pani ve Chawla [39]beyin tümörü bölütlemesi için 3D U-Net mimarisini temel alan, transfer öğrenme ve kendi kendine denetlenen öğrenmeyi birleştiren karma bir yaklaşım önermişlerdir. Önerilen model MRG görüntülerinin her bir modalitesinden özellik çıkarılmasını amaçlayan bir özellik çıkarma modülü içermektedir. Bunun yanında model yapısı atlamalı bağlantılar ve özellik haritalarını farklı şekillerde birleştiren Hibrit Özellik Füzyon Modüllerini içermektedir. Araştırmacılar geliştirilen modelin başarısını BraTS2020 veri seti üzerinde 5 katlı çapraz doğrulama tekniği ile ölçmüş ve genişleyen tümör bölgesi, tümör çekirdeği ve tüm tümör bölgesi için sırasıyla %85.64, %89.56 ve %95.25 dice değerlerini rapor etmişlerdir.

4. Sonuç ve Tartışma

Beyin tümörlerinin teşhis edilmesi ve tümör bölgesinin farklı alt türlerini de içerecek şekilde işaretlenmesi büyük önem taşımaktadır. Hastalığın tedavi sürecinin takibi açısından da oldukça önemli olan bu süreç birçok araştırmacının dikkatini çekmekte ve aktif bir çalışma alanı olmayı sürdürmektedir. Bu derlemede ele alınan çalışmalar derin öğrenme mimarilerinde ortaya çıkan yeniliklerin tümör bölütleme alanına da uygulandığını ve bu gelişmeler ile yüksek başarılı modellerin ortaya çıkarıldığını göstermektedir.

Özellikle dikkat mekanizmalarını kullanan yaklaşımlar bu alanda ön plana çıkmaktadır. Büyük dil modelleri gibi yapay zekâ alanında en çok dikkat çeken çalışmalarda kullanılan transformatör yapıları görüntü işleme tekniklerine uyarlanarak geniş bağlam bilgilerini işlemede kullanılmaktadır.

Derin öğrenme modellerinin yapılarında oluşan değişikliklerin dışında araştırmacılar farklı veri artırımı teknikleri, hata fonksiyonları, optimizasyon yöntemleri gibi alanlara eğilerek elde edilen başarıları daha yüksek seviyelere çıkarmaya çalışmaktadır.

Derin öğrenme çalışmalarının en zorlu kısımlarından biri etiketlenmiş büyük veri setlerine ulaşmaktır. Bu kapsamda literatürde yapılan incelemede 2012 yılından beri düzenli olarak Tıbbi Görüntü İşleme ve Bilgisayar Destekli Müdahaleler Derneği (MICCAI) gerçekleştirilen beyin tümörü bölütleme yarışmaları için hazırlanan BraTS veri setleri araştırmacıların bu ihtiyacını karşılamakta ve ortaya konan modellerin başarılarını sınamak için ideal bir kaynak oluşturmaktadır.

Yapılan çalışmalar göstermektedir ki hekimlere yardımcı olan karar destek sistemlerinin hızları ve başarıları artmaya devam etmektedir. Bu gelişmeler karar destek sistemlerinin yaygınlaşmasını sağlayacak ve sağlık hizmetlerinin kalitesini arttıracaktır.

Kaynaklar

- [1] M. Rizwan, A. Shabbir, A. R. Javed, M. Shabbir, T. Baker, and D. Al-Jumeily Obe, "Brain Tumor and Glioma Grade Classification Using Gaussian Convolutional Neural Network," *IEEE Access*, vol. 10, pp. 29731–29740, 2022, doi: 10.1109/ACCESS.2022.3153108.
- [2] "Retraction: Deep Learning Model for Automatic Classification and Prediction of Brain Tumor (Journal of Sensors (2022) 2022 (11) DOI: 10.1155/2022/3065656)," 2023, *Hindawi Limited*. doi: 10.1155/2023/9814852.
- [3] M. and M. F. Khanmohammadi Shaghayegh and Mobarakabadi, "The Economic Burden of Malignant Brain Tumors," in *Human Brain and Spinal Cord Tumors: From Bench to Bedside. Volume 1: Neuroimmunology and Neurogenetics*, S. Rezaei Nima and Hanaei, Ed., Cham: Springer International Publishing, 2023, pp. 209–221. doi: 10.1007/978-3-031-14732-6_13.
- [4] M. Rasool, N. A. Ismail, A. Al-Dhaqm, W. M. S. Yafooz, and A. Alsaedi, "A Novel Approach for Classifying Brain Tumours Combining a SqueezeNet Model with SVM and Fine-Tuning," *Electronics (Switzerland)*, vol. 12, no. 1, Jan. 2023, doi: 10.3390/electronics12010149.
- [5] E. Petrosyan *et al.*, "Endoplasmic Reticulum Stress in the Brain Tumor Immune Microenvironment," May 01, 2023, *American Association for Cancer Research Inc*. doi: 10.1158/1541-7786.MCR-22-0920.
- [6] Ö. Polat and C. Güngen, "Classification of brain tumors from MR images using deep transfer learning," *Journal of Supercomputing*, vol. 77, no. 7, pp. 7236–7252, Jul. 2021, doi: 10.1007/s11227-020-03572-9.
- [7] S. Kokkalla, J. Kakarla, I. B. Venkateswarlu, and M. Singh, "Three-class brain tumor classification using deep dense inception residual network," *Soft comput*, vol. 25, no. 13, pp. 8721–8729, Jul. 2021, doi: 10.1007/s00500-021-05748-8.
- [8] A. Corso *et al.*, "UCLA Department of Statistics Papers Title Efficient Multilevel Brain Tumor Segmentation with Integrated Bayesian Model Classification Publication Date Efficient Multilevel Brain Tumor Segmentation with Integrated Bayesian Model Classification," 2008. [Online]. Available: <https://escholarship.org/uc/item/0gv683h5>
- [9] A. Işin, C. Direkoğlu, and M. Şah, "Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods," in *Procedia Computer Science*, Elsevier B.V., 2016, pp. 317–324. doi: 10.1016/j.procs.2016.09.407.
- [10] M. I. Razzak, M. Imran, and G. Xu, "Efficient Brain Tumor Segmentation with Multiscale Two-Pathway-Group Conventional Neural Networks," *IEEE J Biomed Health Inform*, vol. 23, no. 5, pp. 1911–1919, Sep. 2019, doi: 10.1109/JBHI.2018.2874033.
- [11] K. Kamnitsas *et al.*, "Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation," *Med Image Anal*, vol. 36, pp. 61–78, Feb. 2017, doi: 10.1016/j.media.2016.10.004.
- [12] T. Magadza and S. Viriri, "Deep learning for brain tumor segmentation: A survey of state-of-the-art," Feb. 01, 2021, *MDPI AG*. doi: 10.3390/jimaging7020019.

- [13] S. M. Bhandarkar, J. Koh, and M. Suk, "Multiscale image segmentation using a hierarchical self-organizing map," 1997.
- [14] N. Gordillo, E. Montseny, and P. Sobrevilla, "State of the art survey on MRI brain tumor segmentation," Oct. 2013. doi: 10.1016/j.mri.2013.05.002.
- [15] P. Ventakasubbu and P. Ramasubramanian, "Deep Learning-based Brain Tumour Segmentation," *IETE J Res*, vol. 69, no. 6, pp. 3156–3164, 2023, doi: 10.1080/03772063.2021.1919219.
- [16] C. G. A. R. Network, "Comprehensive, integrative genomic analysis of diffuse lower-grade gliomas," *New England Journal of Medicine*, vol. 372, no. 26, pp. 2481–2498, 2015.
- [17] N. Bouchaour and S. Mazouzi, "Deep pattern-based tumor segmentation in brain MRIs," *Neural Comput Appl*, vol. 34, no. 17, pp. 14317–14326, Sep. 2022, doi: 10.1007/s00521-022-07422-y.
- [18] I. Aboussaleh, J. Riffi, A. M. Mahraz, and H. Tairi, "Inception-UDet: An Improved U-Net Architecture for Brain Tumor Segmentation," *Annals of Data Science*, vol. 11, no. 3, pp. 831–853, Jun. 2024, doi: 10.1007/s40745-023-00480-6.
- [19] R. Ranjbarzadeh, P. Zarbakhsh, A. Caputo, E. B. Tirkolaee, and M. Bendeche, "Brain tumor segmentation based on optimized convolutional neural network and improved chimp optimization algorithm," *Comput Biol Med*, vol. 168, Jan. 2024, doi: 10.1016/j.combiomed.2023.107723.
- [20] S. Kumar and B. Biswal, "MAEU-NET: A novel supervised architecture for brain tumor segmentation," *Int J Imaging Syst Technol*, vol. 34, no. 2, p. e22988, 2024.
- [21] X. and S. X. and W. M. and F. H. Zou Ke and Yuan, "TBraTS: Trusted Brain Tumor Segmentation," in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2022*, Q. and F. P. T. and S. S. and L. S. Wang Linwei and Dou, Ed., Cham: Springer Nature Switzerland, 2022, pp. 503–513.
- [22] F. Milletari, N. Navab, and S.-A. Ahmadi, "V-net: Fully convolutional neural networks for volumetric medical image segmentation," in *2016 fourth international conference on 3D vision (3DV)*, 2016, pp. 565–571.
- [23] O. Oktay *et al.*, "Attention U-Net: Learning Where to Look for the Pancreas," Apr. 2018, [Online]. Available: <http://arxiv.org/abs/1804.03999>
- [24] C. Yan, J. Ding, H. Zhang, K. Tong, B. Hua, and S. Shi, "SEResU-Net for Multimodal Brain Tumor Segmentation," *IEEE Access*, vol. 10, pp. 117033–117044, 2022, doi: 10.1109/ACCESS.2022.3214309.
- [25] M. N. Bajwa *et al.*, "Two-stage framework for optic disc localization and glaucoma classification in retinal fundus images using deep learning," *BMC Med Inform Decis Mak*, vol. 19, no. 1, p. 136, 2019.
- [26] M. Amian Mehdi and Soltaninejad, "Multi-resolution 3D CNN for MRI Brain Tumor Segmentation and Survival Prediction," in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2020, pp. 221–230.
- [27] P. F. and F. P. M. and V. P. and M.-H. K. H. Isensee Fabian and Jäger, "nnU-Net for Brain Tumor Segmentation," in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2021, pp. 118–132.

- [28]F. Isensee, P. F. Jaeger, S. A. A. Kohl, J. Petersen, and K. H. Maier-Hein, “nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation,” *Nat Methods*, vol. 18, no. 2, pp. 203–211, Feb. 2021, doi: 10.1038/s41592-020-01008-z.
- [29]T. Magadza and S. Viriri, “Efficient nnU-Net for Brain Tumor Segmentation,” *IEEE Access*, vol. 11, pp. 126386–126397, 2023, doi: 10.1109/ACCESS.2023.3329517.
- [30]L. and D. W. and Y. X. Colman Jordan and Zhang, “DR-Unet104 for Multimodal MRI Brain Tumor Segmentation,” in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2021, pp. 410–419.
- [31]S. and V. T. Fidon Lucas and Ourselin, “Generalized Wasserstein Dice Score, Distributionally Robust Deep Learning, and Ranger for Brain Tumor Segmentation: BraTS 2020 Challenge,” in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2021, pp. 200–214.
- [32]A. and L. M. and E. T. and R. C. and P. N. and D. E. Henry Théophraste and Carré, “Brain Tumor Segmentation with Self-ensembled, Deeply-Supervised 3D U-Net Neural Networks: A BraTS 2020 Challenge Solution,” in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2021, pp. 327–339.
- [33]I. Aboussaleh, J. Riffi, K. el Fazazy, A. M. Mahraz, and H. Tairi, “3DUV-NetR+: A 3D hybrid semantic architecture using transformers for brain tumor segmentation with MultiModal MR images,” *Results in Engineering*, vol. 21, Mar. 2024, doi: 10.1016/j.rineng.2024.101892.
- [34]D. Liu, N. Sheng, T. He, W. Wang, J. Zhang, and J. Zhang, “SGEResU-Net for brain tumor segmentation,” *Mathematical Biosciences and Engineering*, vol. 19, no. 6, pp. 5576–5590, 2022, doi: 10.3934/mbe.2022261.
- [35]S.-H. Luu Huan Minh and Park, “Extending nn-UNet for Brain Tumor Segmentation,” in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2022, pp. 173–186.
- [36]T. and S. H. and Z. H. Tang Jiarui and Li, “Variational-Autoencoder Regularized 3D MultiResUNet for the BraTS 2020 Brain Tumor Segmentation,” in *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, S. Crimi Alessandro and Bakas, Ed., Cham: Springer International Publishing, 2021, pp. 431–440.
- [37]A. Myronenko, “3D MRI brain tumor segmentation using autoencoder regularization,” Oct. 2018, [Online]. Available: <http://arxiv.org/abs/1810.11654>
- [38]N. Ibtehaz and M. S. Rahman, “MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation,” *Neural Networks*, vol. 121, pp. 74–87, Jan. 2020, doi: 10.1016/j.neunet.2019.08.025.
- [39]K. Pani and I. Chawla, “A hybrid approach for multi modal brain tumor segmentation using two phase transfer learning, SSL and a hybrid 3DUNET,” *Computers and Electrical Engineering*, vol. 118, Sep. 2024, doi: 10.1016/j.compeleceng.2024.109418.

ŞEKİL TEMSİL METOTLARI

Haydar Tuna¹

Abstract

In recent times, advancements in mobile technology and social media have led to an influx of images and videos on the Internet that are freely accessible to millions. The practice of searching for content based solely on color and texture is insufficient, as they are confused in the process. Nonetheless, analyzing objects based on their shape, in addition to the two characteristics being sought, can produce more accurate results. In the field of image processing, the concept of shape is initiated by segmenting an object from the background using different methods. Studies related to shapes can be classified into three categories: representation, similarity, and recognition. The representation category involves extraction and vectorization of the shape properties of an object. On the other hand, the similarity category aims to quantify the degree of similarity between two shapes. Finally, shape recognition is used to determine the class of an object based on its shape. The methods used for shape representation can be divided into two categories: region-based and boundary-based. In region-based methods, the properties of all pixels of the shape are considered, whereas in boundary-based methods, only edge pixels are considered. In this study, both region-based and boundary-based methods are compared and reviewed.

¹ Department of Computer Engineering, Osmaniye Korkut Ata University, Osmaniye, Turkey, haydartuna@osmaniye.edu.tr, ORCID: 0000-0003-2388-653X

Keywords: shape; representation; region-based; boundary-based.

1. Giriş

Son yıllarda mobil teknolojiler ve sosyal medya alanında meydana gelen gelişmeler nedeniyle milyarlarca resim ve video içeriği internette serbestçe dolaşmaktadır. Söz konusu içerikler arasında renk ve doku tabanlı arama yapmak ise tek başına yeterli değildir. Çünkü benzer renk ve dokuda kimi nesnelere yönteminiz ne olursa olsun arama esnasında birbirine karıştırılabilir. Fakat aranan bu iki özellik yanında nesnelere şekline bakıldığında işlem daha gerçekçi sonuçlar verebilir.

Görüntü işlemede şekil kavramı nesnelere arka plandan segmentasyon yöntemleriyle ayrıştırılmasıyla başlar. Şekil ise temel olarak birbiri ile bağlantılı nokta kümesi olarak tanımlanabilir [1]. Noktalar bir araya gelerek bir form oluştururlar. İnsan beyni ise oluşan formları ilişkilendirir ve anlamlandırır [2-3]. Şekil ile ilgili çalışmalar temsil, benzerlik ve tanıma olarak üç gruba ayrılır. Şekilde temsil, bir nesnenin özneliğinin çıkartılıp vektöre dönüştürülmesidir. Benzerlikte ise iki şeklin birbirine ne kadar yakın olduğu sorusuna cevap aranır. Şekil tanıma ise bir nesnesinin sınıfını bulmada kullanılan metotlardır [4].

Bir şekli temsil etmede kullanılan yöntemler bölge ve sınır olmak üzere ikiye ayrılır [5-6]. Bölge tabanlı yöntemlerde şeklin tüm piksellerine, sınır tabanlı yöntemlerde ise sadece kenar piksellerine bakılır. Bu çalışmada ise bölge ve sınır tabanlı yöntemler incelenerek bunların karşılaştırılması gerçekleştirilecektir.


2. Bölge Tabanlı Şekil Temsil Yöntemleri

Bölge tabanlı şekil temsil yöntemleri kapalı bir nesnenin iç noktalarının tamamı kullanılarak elde edilen öz niteliklerdir. Söz konusu metotlar kendi içinde global ve yapısal olarak ikiye ayrılır. Global temsil yöntemlerinde tüm pikseller işin

içerisine katılırken, yapısal tekniklerde şekil primitive olarak adlandırılan alt parçalara bölünür [5].

2.1. Basit Şekil Temsil Yöntemleri

Basit şekil temsil yöntemleri tüm pikseller kullanılarak elde edilen alan, ağırlık merkezi, dairesellik (çevre²/alan) gibi skaler büyüklüklerdir. Söz konusu metrikler doğrudan bir nesneyi ayırt etmekten uzaktır. Örneğin Şekil 1(a) ve 1(b)'de iki farklı nesne olmasına rağmen dairesellikleri aynıdır. Buradan daireselliğin tek başına ayırt edici olmadığı söylenebilir. Benzer durum diğer basit şekil temsil yöntemleri için de geçerlidir. Bu yöntemler nesnelere ayırt etmekten çok diğer yöntemlerin başarısını artırmada da kullanılabilir. Yukarıda bahsedilen öz nitelikler haricinde convexity, ana eksen oranları, kompaktlık gibi öz niteliklerde basit şekil temsil yöntemleri arasında sayılır [7].



Şekil 1. Farklı şekillerin dairesellik durumları [5]

2.2. Moment


Şekil momentleri geometrik, cebirsel ve ortogonal olmak üzere üçe ayrılır. Örüntülerde kullanılan moment fikri iki boyutlu düzlemde ilk olarak Hu tarafından (1) ile ifade edilmiştir [9].

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad p, q = 0, 1, 2, \dots \quad (1)$$

Burada sıfırcı seviye moment m_{00} şeklin alanıdır. Hesaplamlarda $f(x,y)$ şekle ait fonksiyondur ve şeklin içinde 1 ve dışında 0 değerini alır. Birinci seviye moment ise şeklin ağırlık merkezini hesaplamada temel alınır. Örneğin ağırlık merkezinin x_c ve y_c koordinatları birinci seviye moment kullanılarak sırasıyla $x_c = m_{10}/m_{00}$ ve $y_c = m_{01}/m_{00}$ şeklinde hesaplanır. İkinci seviye moment ise şeklin ana eksenini hakkında bizlere fikir verir [4]. Moment seviyesi arttıkça değerlerin arasında çok küçük farklılıklar meydana gelir. Bu yüzden z-normalizasyonu gibi bir metotla moment değerlerinin normalize edilmesine ihtiyaç vardır [11]. Genel (1)'deki denklemle elde edilen geometrik moment bir şeklin kenarlarındaki bozulmalardan etkilenir. Basit şekillerde ise daha iyi sonuç verir [8]. Bu problemlerden dolayı farklı moment teknikleri ortaya atılmıştır. Örneğin Teague (1)'deki ifade de x^p ve y^q yerine Zernike ve Legendre polinomlarını kullanarak ortogonal moment yöntemini önermiştir [12]. Bunun dışında cebirsel moment ilk m merkez momenti ve bunların eigen değerleri ile elde edilen matrisler kullanılarak hesaplanır [12-13].

2.3. Izgara Tabanlı Modelleme

Izgara tabanlı şekil modellemede nesne kendisini tamamen içine alan eşit karesel hücreler içeren ızgara içine alınır. Söz konusu yapıda ızgara içinde en az %15 yer kaplayan şekil hücresi 1 (nesne), diğerleri 0 (arka plan) kabul edilir. Sonuç olarak şekil 1 ve 0'lardan oluşan binary sayılarla kodlanır. Örneğin Şekil 2'de yer alan nesne 11100000 11111000 01111110 01111111 binary sayıları ile kodlanır. Ayrıca elde edilen ikilik sistemdeki sayı 4 byte'lık tam sayı olarak saklanır. Şekiller tarama yapılmadan önce döndürme ve ölçeklenmeden etkilenmemek için normalize edilir. Döndürmeye bağlı normalizasyon işleminde şeklin ana eksenini dikkate alınır [14].




Şekil 2. Izgara metodu ile ikilik sayı sisteminde kodlama [14]

Bu yöntemde karşılaşılan en temel problemlerden bir tanesi şeklin binary sayıya dönüştürülmeden önce ana eksene göre döndürülmesidir. Söz konusu işlem aynı şeklin farklı açılardaki hallerini ana eksene göre x ya da y eksenine paralel hale getirir. Fakat ana eksene göre yapılan bu döndürme işlemi gürültüye karşı duyarlıdır.

2.4. Şekil Matrisi

Şeklin matrise dönüştürülmesinde ızgara metodu kullanıldığında dönüşüm, döndürme ve ölçeklenmeye karşı duyarlı olacaktır. Buna ek olarak şekil üzerinde fazladan normalizasyona ihtiyaç vardır [6]. Goshtasby tarafından önerilen metotta ise şekil merkezinden itibaren eş içine dairelere bölünür. Ayrıca bu daireler yine şekil merkezinden çizilen eşit miktarda ve açılara bölünmüş ışınlarla kesiştirilir. Söz konusu kesişen noktalar kullanılarak matris elde edilir. Şeklin eş merkezli dairelere bölünmesinden önce en büyük yarıçap uzunluğuna göre normalizasyon yapılır [15]. Örneğin Şekil 3(a)'da görülen nesne Şekil 3(b)'deki matris formuna dönüştürülmüştür. Burada $m=10$ ışın sayısını, $n=4$ ise iç içe daire sayısını göstermektedir.



Şekil 3. (a) Uçak şekli (b) Şekle ait matris [16]

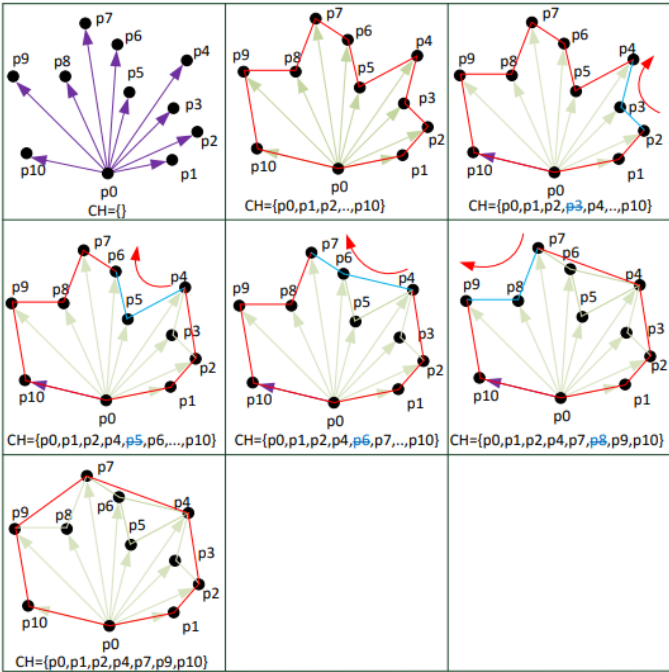
Taza ve Suen ise şekil matrisinde kenar noktaların daha çok ağırlıklandırıldığı farklı bir teknik önermiştir [17]. Bu çalışmaya ek olarak Parui ve arkadaşları içi içe dairesel bölgelerdeki bağlı alanları baz alan farklı bir çalışmada gerçekleştirmiştir [18]. Elde edilen şekil matrisi ötelemeden, döndürmeden ve ölçeklenmeden bağımsızdır. Fakat gürültüden çok etkilenir. Bir diğer sorun ise matris boyutu büyüdükçe işlem karmaşıklığının artmasıdır.

2.5. Convex Hull

Convex hull, basit olarak bir iç bükey nokta kümesini çevreleyen en küçük dış bükey şekil olarak tanımlanabilir. Bilgisayar bilimleri açısından en önemli geometrik problemler arasındadır. Söz konusu problemin çözümünde klasik olarak Graham Scan [19], Jarvis March [20], Chan çıkış-duyarlıkları algoritması [21], Andrew Monotone-Chain [22], Torch [23] ve Quickhull [24-25] olmak üzere beş temel algoritma kullanılır. Bu algoritmalara ek olarak standart metodların başlangıç durumundaki performanslarını artırmada heuristic tabanlı poles-first [26] ve throw-away [27] algoritmaları da literatürde yer almaktadır.

Literatüre ilk kazandırılan Graham Scan algoritmasında zaman karmaşıklığı $O(n \log n)$ 'dir. İlgili algoritmada

başlangıçta y koordinatı en düşük nokta referans olarak alınır. İkinci aşamada seçilen referansa göre tüm noktalar açısal olarak sıralanır. Bir sonraki nokta açısal olarak en küçük koordinatta yer alır. İşleme en son eklenen noktadan itibaren devam edilir. Eğer yön değişikliği varsa bu nokta hull çokgeninden çıkartılır. İlgili algoritmada genellikle stack ya da linked list veri yapıları kullanılabilir [28]. Örnek bir nokta kümesi ve bu kümeye ait Graham Scan algoritmasıyla bulunan Convex Hull ise Şekil 4'te gösterilmiştir.




Şekil 4. Graham Scan algoritmasıyla Convex Hull bulunması [28]

Convex hull farklı uygulama alanlarına sahiptir. Bu teknikle iki nesnenin bilgisayar grafikleri ve fizik simülasyonlarında çarpışıp çarpışmayacağı tespit edilebilir [29-31]. Nesne tanıma işleminde de convex hull algoritmalarından faydalanılır [32-33]. Bunların dışında bilgisayarda geometri alanında ve robotikte birçok uygulama alanı olan ve bilgisayar bilimlerinin en önemli problemlerinden biridir.

2.5. Medial Axis Transform

Medial Axis Dönüşümü (MAT), bir nesnenin orta ekseninde yer alan ve sınırlarına birden fazla en yakın noktaya sahip kümedir. Orta eksen dönüşümü olarak düşünüldüğünde elde edilen şekil nesnenin iskeletidir. Söz konusu metot ilk olarak Blum tarafından biyolojik şekil tanımada bir yöntem olarak kullanılmıştır [34]. Bu yöntemde göre dört adet el şekline ait MAT ile elde edilen iskelet görünümleri Şekil 5’de görülebilir. Söz konusu dört şekil incelendiğinde sınır noktalarında meydana gelen değişimlerin iskelet üzerinde dallarda farklılıklara neden olduğu görülebilir. Bu noktada metodun sınır noktalarında meydana gelen bozulmalardan etkilendiği söylenebilir [35]. Metodun bu problemini giderebilmek için kenar noktalarına teğet olan ve kesmeyen daireler kullanılmıştır. Kenarlarda dolaştırılan daireleri temel olarak metot iyileştirilmeye çalışılmıştır [36].



Şekil 5. Farklı gürültülerdeki el şekillerine ait MAT dönüşümleri [35]

3. Sınır Tabanlı Şekil Temsil Yöntemleri

Sınır tabanlı şekil temsil yöntemleri bir nesnenin kenar pikselleri kullanılarak elde edilen öz niteliklerdir. Bölge tabanlı yöntemlerden farklı olarak şekillerin tüm pikselleri taranarak elde edilmediği için daha hızlıdır. Fakat kenar piksellerde meydana gelen gürültülerden daha çok etkilenirler. Söz konusu temsil metotları bölge tabanlı tekniklerde olduğu gibi global ve yapısal olarak ikiye ayrılır. Global yöntemlerde tüm sınır pikselleri kullanılırken, yapısal metotlarda nesnelere primitive olarak adlandırılan alt parçalara ayrılır [5].

3.1. Şekil İmzası

Şekil imzası, bir nesnenin sınır pikselleri kullanılarak elde edilen bir boyutlu bir fonksiyondur [5] [37-38]. İmza alınan referans noktasına ve özelliklere bağlı olarak çeşitli şekillerde olabilir. Radyal mesafe sınır pikselleri $(x(u), y(u))$ olan bir nesnede ilgili noktalar ile şekil merkezi arasındaki uzaklık hesaplanarak (2)'deki denklem kullanılarak [39-40] Şekil 6a'daki gibi bulunur [41].

$$RD(u) = \sqrt{(x(u) - x_c)^2 + (y(u) - y_c)^2} \quad (2)$$

Burada $RD(u)$ şekil kenar piksellerinden elde edilen bir boyutlu bir sinyal ya da fonksiyondur. Denklemden geçen x_c ve y_c ağırlık merkezleri ise (3)'deki gibi hesaplanabilir [41].

$$x_c = \frac{1}{N} \sum_{u=0}^{N-1} x(u) , \quad y_c = \frac{1}{N} \sum_{u=0}^{N-1} y(u) \quad (3)$$

Ağırlık merkezi hesabında N toplam kenar piksel sayısını göstermektedir. Şekil 6b'de görülen kelebek nesnesinde a noktasından bir teğet çizilir. Bu teğete dik ve b noktasından çizilen doğru parçası ab ya da kiriş bir boyutlu imza olarak düşünülebilir. Söz konusu sınır noktalarından birden fazla olması durumunda bir tane uzaklık seçilir [39].

Açısal fonksiyon bir şeklin kenar pikselleri arasındaki yön ifade etmek için kullanılır [39]. Bu açısal değişim Şekil 6c'deki gibi bulunabilir. Söz konusu imza çeşidinde açısal fonksiyon (4)'deki gibi bulunabilir. Burada w seçilen adım sayısını göstermektedir.

$$\varphi(u) = \arctan\left(\frac{y(u) - y(u-w)}{x(u) - x(u-w)}\right) \quad (4)$$

Burada $\varphi(u)$ açısal fonksiyondur ve imza elde etmede kullanılır. Üçgen alanı da şekil imzasında kullanılan yöntemlerden biridir. Şekil temsil yöntemi olarak iki çeşit

üçgen alanı tanımlanabilir. Birincisi Şekil 6d'de görülen nesnenin ardışıl iki noktası ve merkezi arasında kalan üçgen alanıdır [40] ve (5)'deki gibi hesaplanabilir.

$$TCA(u) = \frac{1}{2} |x_1(u) y_2(u) - x_2(u) y_1(u)| \quad (5)$$

Şekil 6e'de görülen ikinci üçgen imza çeşidinde birinci üçgen imza çeşidinden farklı olarak 3 nokta kullanılarak alan bulunur. Burada bir noktadan s birim uzaklıktaki iki piksel kullanılır. Söz konusu üç nokta konkav, konveks ve düz çizgi oluşturabilir [42].

Şekil imzasında ağırlık merkezi kullanılarak her bir sınır noktası karmaşık sayıya dönüştürülebilir [40]. Bu dönüşüm gerçekleştiğinde şekil kenar noktaları dönüşümden bağımsız hale gelir. Örneğin Şekil 6f'de görülen imza çeşidinde bir noktanın karmaşık fonksiyonu (6)'daki gibi bulunabilir.

$$CC(u) = (x(u) - x_c) + (y(u) - y_c)j \quad (6)$$

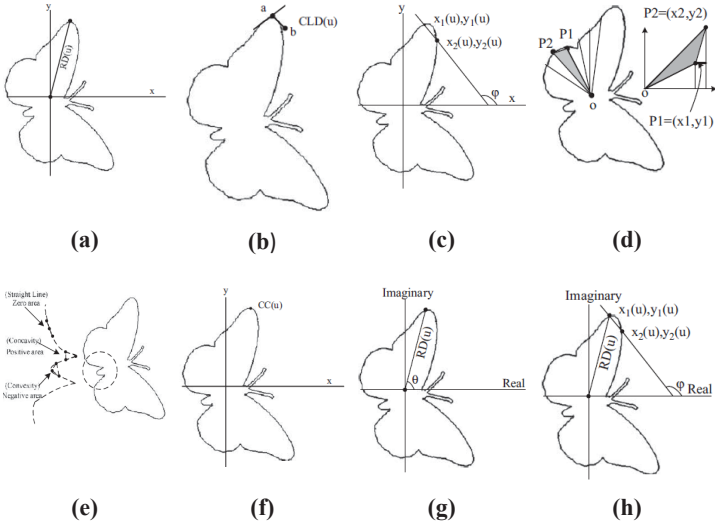
Burada karmaşık sayının gerçel kısmında ağırlık merkezinin x_c ve sanal kısmının hesaplanmasında y_c değeri kullanılmıştır. Şekil 6g'de görülen imza çeşidi ise radyal mesafe karmaşık gösterimin birleştirilmiş halidir. Bu imza çeşidine polar fonksiyon denir [43] ve (7)'deki gibi hesaplanabilir.

$$PC(u) = RD(u) + j\theta(u) \quad (6)$$

Burada karmaşık sayının reel kısmı $RD(u)$ radyal fonksiyonuyla ve sanal kısmı ise $\theta(u)$ polar açı fonksiyonu ile ifade edilmiştir. Açısız radyal imza fonksiyonu ise polar'dan farklı olarak Şekil 6h'deki gibi şeklin merkezi ile arasındaki açı yerine nesnenin dışındaki bir nokta ile arasındaki açı kullanılır [43]. Bu imza çeşidine ait fonksiyon ise (8)'deki gibi tanımlanabilir.

$$ARC(u) = RD(u) + j\varphi(u) \quad (8)$$

Şekil imzası kullanılan büyüklükler normalize edilerek öteleme ve ölçeklemeden bağımsız hale getirilebilir. Fakat şekiller döndürüldüğünde imzada kaymalar meydana gelir. Örneğin farklı iki imza karşılaştırıldığında bir tanesi sabit tutulup diğeri döndürülerek en iyi benzerlik bulunmaya çalışılır. Söz konusu işlemle imza vektörü kadar döndürme gerektirir ve şekil tanıma açısından oldukça maliyetlidir. İmza ile ilgili karşılaşılabilecek ikinci problem ise sınır noktalarda meydana gelen gürültülerden etkilenmesidir. Nesnenin sınır noktalarındaki bu ufak değişimler bazen tanıma noktasında büyük hatalara neden olabilir. Bu yüzden imza üzerinde çeşitli filtreler kullanılarak işlem yapılması gerekebilir.




Şekil 6. Şekil imzaları: a) radyal uzaklık, b) kiriş, c) açılal fonksiyon, d) üçgen merkez alanı, e) üçgen alan gösterimi, f) karmaşık koordinat, g) polar koordinat, h) açılal radyal koordinat [41].

3.2. Zincir Kodları

Zincir kodları bir şeklin sınır piksellerindeki yön değişimleri kullanılarak elde edilen bir temsil yöntemidir. İlk olarak Freeman tarafından ortaya atılan zincir kodlarının temelde şu üç temel özelliği taşıması gerekir: saklanabilme, sıkıştırılabilme ve işlemleri kolaylaştırma [44]. Referans

noktaya göre yön değişimleri farklı şekillerde zincir kod oluşturulmasına neden olur. Papert kaplumbağası yaklaşımında $\{0,1\}$ karakterleri kullanılır. $\{0\}$ sağa dönüşü, $\{1\}$ ise sola dönüşü sembolize eder [45]. DCC zincir kodunda ise $\{R, L, S\}$ olmak üzere üç sembol kullanılır. R (Right) sembolü sağa dönüşü, L (Left) sembolü sola dönüşü ve S (Straight) sembolü ise ileri gidişi gösterir [46]. Diğer taraftan VCC zincir kodunda kenarların birleşim noktaları temel alınır ve birleşim şekillerine göre Şekil 7a'daki gibi $\{0, 1, 2\}$ olmak üzere üç karakter kullanılır [47]. 3OT zincir kodu ise ortogonal yön değişimlerini temel alır ve Şekil 7b'deki gibi $\{0, 1, 2\}$ sembolleri ile ifade edilir [48]. Freeman zincir kodları FR4 ve FR8 olarak ikiye ayrılır. FR4 zincir kodu 4 komşuluk ve FR8 ise 8 komşuluk prensibine göre yön değişimleri Şekil 7c ve 7d'de verilmiştir. Buna göre her iki zincir kodunda yönler sırasıyla $\{0, 1, 2, 3\}$ ve $\{0, 1, 2, 3, 4, 5, 6, 7\}$ sembolleriyle temsil edilir [49].



Şekil 7. Zincir kod sembolleri: a) VCC, b) 3OT, c) FR4, d) FR8 [50]

Zincir kodlarında karşılaşılan en temel problem başlangıç noktası bağımlılığıdır. Aynı şeklin farklı açılardaki zincir kodları farklı olacaktır. Çünkü zincir kodları döndürmeye karşı duyarlıdır. Örneğin FR4 ve FR8 zincir kodları 90^0 ve katlarında döndürme kaynaklı zincir kod değişimlerinden etkilenmediği halde ara açı değerlerinde zincir kod değişecektir. Bu yüzden kullanılan tekniklerden biri şeklin zincir kodunun alınmadan önce oryantasyonunun yatay ya da dikeye alınmasıdır. Ayrıca zincir kodları döndürülüp alfabetik olarak sıralanarak en küçük zincir kodu bulunabilir. Söz konusu işleme başlangıç noktasına göre normalizasyon denilir. Zincir kodlarının ayrıca normalize edilmiş histogramları alınabilir [51]. Fakat


zincir kod histogramı da sadece 90^0 ve katlarında döndürmeye duyarlı değildir.

3.3. Bükülme Enerjisi

Bükülme enerjisini tarif etmeden önce curvature teriminin tanımını yapmak gerekir. Curvature, sınır noktalarındaki eğimde meydana gelen değişimdir. Bükülme enerjisi ise bir çubuğu belli bir şekle sokmak için gerekli enerjidir ve n sınır noktası için curvature değeri $c(n)$ ise enerji (9)'daki gibi bulunabilir [52].

$$BE = \frac{1}{L} \sum_{n=0}^{L-1} c(n) \quad (9)$$

Burada L kenar uzunluğunu göstermektedir. Parvesal teoremine göre zaman düzlemindeki enerji toplamı frekans boyutundaki enerji toplamına eşittir. Buradan söz konusu teorem kullanılarak Fourier tanımlayıcısıyla bükülme enerjisi hesaplanabilir [53-54]. Bükülme enerjisi Freeman zincir kodu kullanılarak da bulunabilir. Örneğin Şekil 8a'da görülen FR8 zincir kodu ile ortaya çıkan curvature grafiği Şekil 8b'deki gibidir. Söz konusu grafik (9) kullanılarak bükülme enerjisine Şekil 8c'deki gibi dönüştürülebilir. Ayrıca grafikteki noktalar birleştirilerek Şekil 8d'deki görüldüğü gibi daha düzgün ve yumuşatılmış hale getirilebilir.



Şekil 8. Bükülme enerjisi: a)FR8, b) Curvature, c) Bükülme Enerjisi, d) Bükülme Enerjisi (Yumuşatılmış) [52]

3.4. Sınır Momentleri

Moment şeklin tamamı düşünülerek hesaplanacağı gibi sınır noktaları kullanılarak da bulunabilir. Kapalı ve N sayıda sınır pikseli oluşan bir nesnenin ağırlık merkezi ile

arasındaki uzaklıklar $z(i)$ şeklinde sıralı bir nokta kümesi ile gösterildiğinde r . moment moment m_r ve merkez momentleri μ_r (10) ve (11)'deki gibi hesaplanabilir.

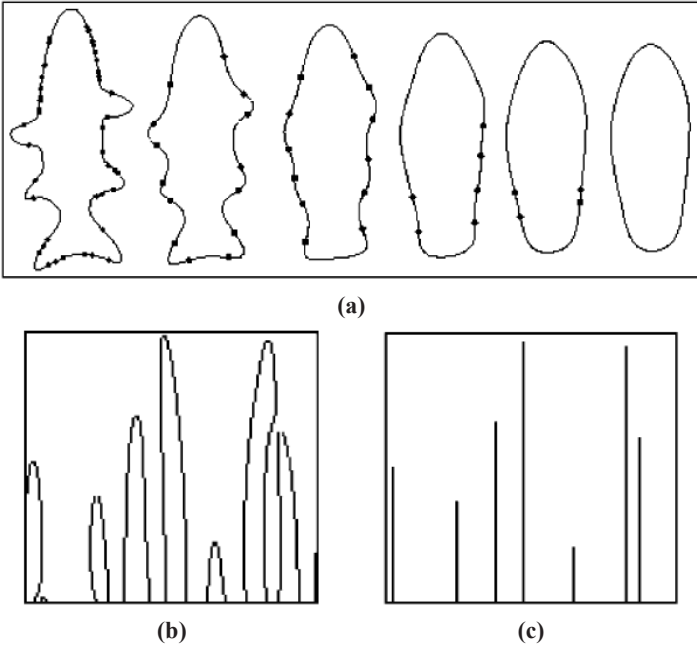
$$m_r = \frac{1}{N} \sum_{i=1}^N (z(i))^r \quad (10)$$

$$\mu_r = \frac{1}{N} \sum_{i=1}^N (z(i) - m_1)^r \quad (11)$$

Bu iki denklem kullanılarak öteleme, döndürme ve ölçeklenmeden bağımsız normalize edilmiş moment ve merkez momentleri bulunabilir [55]. Fakat moment yaklaşımının hesaplaması kolay olmasına rağmen yüksek seviyeli momentlerle şeklin fiziksel özellikleri arasında ilişkilendirmek zordur.

3.5. Ölçek Uzak Yaklaşımı

Ölçek uzak metodunda temel prensip sınır noktalarındaki gürültüye duyarlılık ve kenar noktalarındaki değişime dayanır. Söz konusu yöntemde alçak geçiren ve genişliği σ olan Gauss filtresi şekle uygulanır. Her filtre uygulamasından sonra şekle ait sınırdaki gürültüler azalacak ve önemli noktalar Şekil 9a'daki gibi ortaya çıkacaktır. Buradaki önemli noktalar ile interval tree olarak adlandırılan ve uygulanan filtre genişliğine göre Şekil 9b ve 9c'deki gibi imza oluşturulabilir.



Şekil 9. Gauss filtre genişliği $\sigma = 1, 4, 7, 10, 12, 14$ için: a) Şekil üzerindeki önemli noktaların belirlenmesi, b) Elde edilen interval tree, c) Interval tree tepe noktaları [56]

Asada ve Brady tarafından önerilen ölçek uzay metodunda interval tree oluşturmada Gauss filtresi yanında ikinci türev de kullanılmıştır [57]. Bir diğer çalışmada ise Mokhtarian ve Mackworth ise bir önceki çalışmayı temel alan CSS (Curvature Scale Space) yöntemini önermişlerdir. Söz konusu çalışmada bulunan tepe noktaları şekilleri karşılaştırmada kullanılmıştır [58]. Ölçek uzay yaklaşımında karşılaşılan en temel problem gauss filtresinin ne kadar uygulanacağıdır. Gauss filtresi fazla uygulandığında şekle ait önemli noktalarda kaybolacaktır.

3.6. Fourier Tanımlayıcısı

Fouier tanımlayıcısını açıklayabilmek için Şekil 10'daki C harfi örnek verilebilir. Bu şekle göre herhangi bir (x_0, y_0) noktasından saat ibresinin tersi yönünde gidilirse sırasıyla $(x_0, y_0), (x_1, y_1), (x_2, y_2) \dots (x_{K-1}, y_{K-1})$ noktaları ile karşılaşılır. Söz konusu koordinatlar $x(k)=x_k$ ve $y(k)=y_k$ şeklindedir ve

her bir nokta $k = \{0, 1, 2, \dots, K-1\}$ için $s(k) = [x(k) \ y(k)]$ ikili gösterimle ifade edilir. Buna ek olarak $s(k)$ noktası (12)'deki gibi karmaşık sayı olarak da kullanılabilir [59].

$$s(k) = x(k) + jy(k) \quad (12)$$

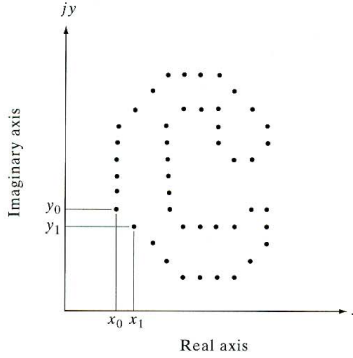
Burada x eksenini gerçel eksen, y eksenini ise sanal eksen olarak $s(k)$ noktasını tarif etmede kullanılır. Nesnenin karmaşık sayı ile gösterimi 2 boyuttan 1 boyuta indirgemeyi sağlar ve $s(k)$ nokta dizisinin ayrık Fourier dönüşümü (13)'deki gibi bulunabilir [59].

$$a(u) = \frac{1}{K} \sum_{k=0}^{K-1} s(k) e^{-j2\pi uk/K} \quad (13)$$

Denklem 13'te $u=0, 1, 2, \dots, K-1$ için $a(u)$ ifadesine sınır noktalarının Fourier tanımlayıcısı denir. Bulunan değerin (14)'deki ters Fourier'i alınarak şekil noktaları tekrardan elde edilebilir [59].

$$s(k) = \sum_{u=0}^{K-1} a(u) e^{j2\pi uk/K} \quad (14)$$

Bulunan katsayılarından yüksek olanlar şekle ait daha global özellikleri taşıırken daha düşük frekanslı olanlar detaylı özellikleri gösterir [59]. Söz konusu dönüşüm ile elde edilen tanımlayıcı ötelemeden bağımsızdır. Uzaysal düzlemde şekilleri döndürmek frekans düzleminde faz kaymasına neden olur. Fakat karmaşık sayının büyüklüğü aynı kalır. Bu yüzden karmaşık sayının büyüklüğü döndürmeye karşı duyarlı değildir. Bunun dışında ölçeklenmeden bağımsız hale getirebilmek için bulunan karmaşık sayı uzunlukları sıfır frekansındaki DC katsayına bölünür [60].



Şekil 10. C harfinin karmaşık düzlemde gösterimi [59]

4. Sonuç ve Tartışma

Bu çalışma var olan şekil temsil yöntemleri üzerinde durulmuştur. Söz konusu yaklaşımlar bölge ve sınır tabanlı olarak ikiye ayrılır. Bölge tabanlı metotlarda şeklin tamamı dikkate alınırken sınır tabanlı metotlarda sadece sınır pikselleri üzerinde çalışılır. Her iki yöntemde de elde edilen özellikler bir vektör ya da karakter dizisine dönüştürülür. İki şeklin karşılaştırılmasında ise bu öz nitelikler kullanılır.

Literatüre bakıldığında sınır tabanlı yaklaşımların bölge tabanlı yaklaşımlara göre daha popüler olduğu söylenebilir. Bunun en önemli sebeplerinden biri insan beyninin daha çok sınır noktaları üzerinden şekilleri ayırt etmesinden kaynaklanmaktadır. Fakat bilgisayarda şekil tanıma açısından bakıldığında bazı zorluklar vardır. Örneğin şekil imzası yaklaşımında sınır noktalarda meydana gelen bozulmalar tanıma noktasında problemlere neden olur. Bu problemler imza üzerinde filtre uygulayarak düzeltilse de bilgi kayıplarına neden olabilir. Döndürme noktasından bakıldığında imzada faz kaymaları olur. Söz konusu kaymalar iki imzanın karşılaştırılmasında çok ciddi algoritmik karmaşıklığa neden olur. Zincir kodları da imza gibi sınır noktalarındaki gürültülere karşı duyarlıdır. Buna ek olarak döndürmeye karşı da duyarlıdır. Zincir kod ve imzada histogram alınabilir. Buna rağmen farklı iki şeklin histogramı arasında yakınlık

olabilir. Bir şeklin sınır momentlerini almak oldukça kolaydır. Yüksek dereceli momentlerde ise yakın sonuçlar bulunur. Rakamsal olarak çok yakın sonuçların elde edilmesi moment değerlerinin normalizasyonunu gerektirir. Ölçek uzay yaklaşımı sınır bölgelerindeki gürültü etkilerini azaltmaya yönelik filtre kullanılmasına izin verse de çok uygulandığında şeklin önemli noktalarında kayıplara neden olabilir.

Bölge tabanlı yöntemler açısından bakıldığında en temel problem algoritma karmaşıklığıdır. İlk olarak gözden geçirilen temel yöntemlerden basit şekil temsil yöntemleriyle bir skaler büyüklük elde edilir. Fakat bu değerler farklı şekiller için aynı olabilmektedir. Bu yüzden basit şekil temsil yöntemleriyle bulunan birden fazla büyüklük vektöre dönüştürülüp anlamlı hale getirilmelidir. Bölge tabanlı moment basittir. Fakat derece arttıkça moment değerinde normalizasyon yapmak gerekir. Izgara tabanlı yöntemde ise şeklin döndürme kaynaklı hatalarını gidermek için başlangıçta yatay ya da dikey eksene göre hizalamak gerekir. Söz konusu işlem nesnenin ana ekseninin x ya da y eksenine paralel yapılmasıyla gerçekleştirilir. Ana eksenin bu şekilde hizalanması döndürmeye karşı duyarlılığı azaltıcı bir etkiye sahiptir. Şekil matrisi de öteleme, döndürme ve ölçeklenmeden bağımsızdır. Fakat matris boyutu arttıkça algoritma zaman karmaşıklığı artar. MAT yöntemi ise şeklin tamamından iskeletin çıkartılmasıdır. İlgili yöntemde gürültüden etkilenir.

Kaynaklar

1. da Fona Costa, Luciano, and Roberto Marcond Cesar Jr. *Shape classification and analysis: theory and practice*. Crc Press, 2018.
2. Marr, David. "Early processing of visual information." *Philosophical Transactions of the Royal Society of London. B, Biological Sciences* 275.942 (1976): 483-519.
3. Warrington, Elizabeth K., and Angela M. Taylor. "The contribution of the right parietal lobe to object recognition." *Cortex* 9.2 (1973): 152-164.
4. Arıca, Nafiz. *Shape: representation, description, similarity and recognition*. 2003. METU, PhD thesis.
5. Loncaric, Sven. "A survey of shape analysis techniques." *Pattern recognition* 31.8 (1998): 983-1001.
6. Zhang, Dengsheng, and Guojun Lu. "Review of shape representation and description techniques." *Pattern recognition* 37.1 (2004): 1-19.
7. Peura, Markus, and Jukka Iivarinen. "Efficiency of simple shape descriptors." *Proceedings of the third international workshop on visual form*. Vol. 5. 1997.
8. Zhang, Dengsheng. *Image Retrieval Based on Shape*. 2002. Monash University, PhD thesis.
9. Hu, Ming-Kuei. "Visual pattern recognition by moment invariants." *IRE transactions on information theory* 8.2 (1962): 179-187.
10. Kennedy, Ruby L. *Solving Data Mining Problems through Pattern Recognition*. Prentice Hall, 1997.
11. Teague, Michael Reed. "Image analysis via the general theory of moments." *Josa* 70.8 (1980): 920-930.
12. Taubin, Gabriel, and David B. Cooper. "Recognition and positioning of rigid objects using algebraic moment invariants." *Geometric Methods in Computer Vision*. Vol. 1570. SPIE, 1991.
13. Taubin, Gabriel, and David B. Cooper. *Object recognition based on moment (or algebraic) invariants*. IBM TJ Watson Research Center, 1991.
14. Lu, Guojun, and Atul Sajjanhar. "Region-based shape representation and similarity measure suitable for content-based image retrieval." *Multimedia Systems* 7 (1999): 165-174.
15. Goshtasby, Ardeshir. "Description and discrimination of planar shapes using shape matrices." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 6 (1985): 738-743.
16. Kondaveeti, Hari Kishan, and Valli Kumari Vatsavayi. "Abridged shape matrix representation for the recognition of aircraft targets from 2D ISAR imagery." *Adv Comput Sci Technol* 10.5 (2017): 1103-1122.X.
17. Warrington, Elizabeth K., and Angela M. Taylor. "The contribution of the right parietal lobe to object recognition." *Cortex* 9.2 (1973): 152-164.
18. Warrington, Elizabeth K., and Angela M. Taylor. "The contribution of the right parietal lobe to object recognition." *Cortex* 9.2 (1973): 152-164.
19. Taza, Antoine, and Ching Y. Suen. "Discrimination of planar shapes using shape matrices." *IEEE Transactions on Systems, Man, and Cybernetics* 19.5 (1989): 1281-1289.

20. Parui, Swapan K., S. Eswara Sarma, and D. Dutta Majumder. "How to discriminate shapes using the shape vector." *Pattern Recognition Letters* 4.3 (1986): 201-204.
21. Graham, Ronald L. "An efficient algorithm for determining the convex hull of a finite planar set." *Info. Proc. Lett.* 1 (1972): 132-133.
22. Jarvis, Ray A. "On the identification of the convex hull of a finite set of points in the plane." *Information processing letters* 2.1 (1973): 18-21.
23. Chan, Timothy M. "Optimal output-sensitive convex hull algorithms in two and three dimensions." *Discrete & Computational Geometry* 16.4 (1996): 361-368.
24. Andrew, Alex M. "Another efficient algorithm for convex hulls in two dimensions." *Information Processing Letters* 9.5 (1979): 216-219.
25. Gomes, Abel JP. "A total order heuristic-based convex hull algorithm for points in the plane." *Computer-Aided Design* 70 (2016): 153-160.
26. Eddy, William F. "A new convex hull algorithm for planar sets." *ACM Transactions on Mathematical Software (TOMS)* 3.4 (1977): 398-403.
27. Green, P. J., and Bernard W. Silverman. "Constructing the convex hull of a set of points in the plane." *The Computer Journal* 22.3 (1979): 262-266.
28. Akl, Selim G., and Godfried T. Toussaint. "A fast convex hull algorithm." *Information processing letters* 7.5 (1978): 219-222.
29. Devroye, Luc, and Godfried T. Toussaint. "A note on linear expected time algorithms for finding convex hulls." *Computing* 26.4 (1981): 361-366.
30. AKGÜL, Bayram, and Hakan KUTUCU. "Convex Hull Problemine Genel Bakış: Algoritmalar ve Karmaşıklıkları." *Akademik Bilişim Konferansı* (2015).
31. Ponamgi, Madhav K., Dinesh Manocha, and Ming C. Lin. "Incremental algorithms for collision detection between polygonal models." *IEEE Transactions on Visualization and Computer Graphics* 3.1 (1997): 51-64.
32. Kockara, Sinan, et al. "Collision detection: A survey." *2007 IEEE International Conference on Systems, Man and Cybernetics*. IEEE, 2007.
33. Jiménez, Juan J., and Rafael J. Segura. "Collision detection between complex polyhedra." *Computers & Graphics* 32.4 (2008): 402-411.
34. Cupec, Robert, et al. "Object recognition based on convex hull alignment." *Pattern recognition* 102 (2020): 107199.
35. Cevikalp, H., Yavuz, H. S., & Triggs, B. (2019). Face recognition based on videos by using convex hulls. *IEEE Transactions on Circuits and Systems for Video Technology*, 30(12), 4481-4495.
36. Blum, Harry. "A transformation for extracting new descriptions of shape." *Models for the perception of speech and visual form* (1967): 362-380.
37. Van Eede, M., et al. "Canonical skeletons for shape matching." *18th International Conference on Pattern Recognition (ICPR'06)*. Vol. 2. IEEE, 2006.
38. Blum, Harry, and Roger N. Nagel. "Shape description using weighted symmetric axis features." *Pattern recognition* 10.3 (1978): 167-180.
39. Davies, E. Roy. *Machine vision: theory, algorithms, practicalities*. Elsevier, 2004.

40. Hu, Yong, and Zuoyong Li. "An Improved Shape Signature for Shape Representation and Image Retrieval." *J. Softw.* 8.11 (2013): 2925-2929.
41. Zhang, Dengsheng, and Guojun Lu. "A comparative study of curvature scale space and Fourier descriptors for shape-based image retrieval." *Journal of Visual Communication and Image Representation* 14.1 (2003): 39-57.
42. Zhang, Dengsheng, and Guojun Lu. "Study and evaluation of different Fourier methods for image retrieval." *Image and vision computing* 23.1 (2005): 33-49.
43. El-ghazal, Akrem, Otman Basir, and Saeid Belkasim. "Farthest point distance: A new shape signature for Fourier descriptors." *Signal Processing: Image Communication* 24.7 (2009): 572-586.
44. El Rubé, Ibrahim, et al. "MTAR: a robust 2D shape representation." *International Journal of Image and Graphics* 6.03 (2006): 421-443.
45. Kunttu, I., and L. Lepistö. "Shape-based retrieval of industrial surface defects using angular radius Fourier descriptor." *IET Image Processing* 1.2 (2007): 231-236.
46. Freeman, Herbert. "Computer processing of line-drawing images." *ACM Computing Surveys (CSUR)* 6.1 (1974): 57-97.
47. Papert, S. "Uses of Technology to Enhance Education". *Artificial Intelligence Technical Report*, vol. 298, 1973, pp. 1-108.
48. Nunes, Paulo, Fernando Pereira, and Ferran Marqués. "Multi-grid chain coding of binary shapes." *Proceedings of international conference on image processing*. Vol. 3. IEEE, 1997.
49. Bribiesca, Ernesto. "A new chain code." *Pattern Recognition* 32.2 (1999): 235-251.
50. Sanchez-Cruz, Hermilo, and Ramon M. Rodriguez-Dagnino. "Compressing bilevel images by means of a three-bit chain code." *Optical engineering* 44.9 (2005): 097004-097004.
51. Freeman, Herbert. "On the encoding of arbitrary geometric configurations." *IRE Transactions on Electronic Computers* 2 (1961): 260-268.
52. Sánchez-Cruz, Hermilo, Ernesto Bribiesca, and Ramón M. Rodríguez-Dagnino. "Efficiency of chain codes to represent binary objects." *Pattern Recognition* 40.6 (2007): 1660-1674.
53. Iivarinen, Jukka, and Ari JE Visa. "Shape recognition of irregular objects." *Intelligent Robots and Computer Vision XV: Algorithms, Techniques, Active Vision, and Materials Handling*. Vol. 2904. SPIE, 1996.
54. Sonka, Milan, Vaclav Hlavac, and Roger Boyle. *Image processing, analysis and machine vision*. Springer, 2013.
55. Oppenheim A. V., Willsky A. S., and Young I. T. *Signals and Systems*. Prentice-Hall, Englewood, 1983.
56. Papoulis A. *Probability, Random Variables, and Stochastic Processes*. McGraw-Hill, New York, 3rd edition, 1991.
57. Gupta L. and Srinath M. D. Contour sequence moments for the classification of closed planar shapes. *Pattern Recognition*, 20(3):267-272, 1987.

58. Mokhtarian, Farzin, Sadegh Abbasi, and Josef Kittler. "Efficient and robust retrieval by shape content through curvature scale space." *Image databases and multi-media search*. 1997. 51-58.
59. Asada, Haruo, and Michael Brady. "The curvature primal sketch." *IEEE transactions on pattern analysis and machine intelligence* 1 (1986): 2-14.
60. Mokhtarian, Farzin, and Alan Mackworth. "Scale-based description and recognition of planar curves and two-dimensional shapes." *IEEE transactions on pattern analysis and machine intelligence* 1 (1986): 34-43.
61. Gonzalez, Rafael C, and Richard E Woods. *Digital Image Processing*. 4th ed., New York, Ny, Pearson, 2018.
62. Tiagrajah, V. J., and AAS Muhammad Razeen. "An enhanced shape descriptor based on radial distances." *2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. IEEE, 2011.

GÖRÜNTÜLEME UYGULAMALARINDA YAYINIM FİLTRELERİNİ GELİŞTİRMEK İÇİN KULLANILAN SON TEKNİKLER

Ufuk Tanyeri¹

Özet

Görüntü filtreleme görüntü kalitesini artırma ve gürültü azaltmada tercih edilen bir yöntem olup pek çok uygulama için bir ön işlemdir. Özellikle kenar algılama ve özellik çıkarma gibi çeşitli görüntü işleme uygulamalarına yardımcı olur. Görüntü filtreleme yumuşatma, keskinleştirme veya belirli özellikleri vurgulama gibi istenen efektleri elde etmek için piksel değerlerine matematiksel işlemler uygulayarak görüntüyü değiştirme veya geliştirme süreci olarak tanımlanır. Bu bağlamda sıklıkla tercih edilen yayılım/difüzyon filtresi, kenarlar ve bölgeler gibi önemli görüntü özelliklerini korurken gürültüyü etkili bir şekilde azalttığı için hayati öneme sahiptir. Difüzyon filtreleri üzerine yapılan son çalışmalar, bir görüntünün diğer alanlarını yumuşatırken kenarları koruyan yön bağımlı/anizotropik yayınımdaki gelişmeleri ve belirli özellikleri geliştirmeyi amaçlayan doğrusal olmayan difüzyon tekniklerine odaklanmaktadır. Ek olarak, görüntü gürültüsünü giderme, bölütleme ve görüntü tanıma sistemlerinin sağlamlığını iyileştirme gibi görevler için makine öğrenimi ve derin öğrenmede difüzyon filtrelerinin

¹ Bilgisayar Teknolojileri Bölümü, Ankara Üniversitesi, Ankara, Türkiye, ufuktanyeri@ankara.edu.tr, ORCID: 0000-0002-7039-9577

uygulanmasına olan ilgi artmaktadır. Bu bölümde, difüzyon filtrelerinin performans ve verimliliğini artırmak için son iki yılda önerilen çalışmalar analiz edilmektedir (2023-2024).

Anahtar Sözcükler: Görüntü; Görüntü Filtreleri; Yayınım Filtresi; Yön Bağımlı Filtre

Latest Techniques Used to Improve Diffusion Filters in Imaging Applications

Abstract

Image filtering is a preferred method for improving image quality and reducing noise, and is a pre-processing method for many applications. It helps in various image processing applications, especially edge detection and feature extraction. Image filtering is defined as the process of modifying or enhancing an image by applying mathematical operations to pixel values to achieve desired effects such as smoothing, sharpening, or emphasizing certain features. In this context, the preferred diffusion filter is vital as it effectively reduces noise while preserving important image features such as edges and regions. Recent studies on diffusion filters have focused on advancements in anisotropic diffusion, which preserves edges while smoothing other areas of an image, and non-linear diffusion techniques, which aim to enhance specific features. Additionally, there is increasing interest in the application of diffusion filters in machine learning and deep learning for tasks such as image denoising, segmentation, and improving the robustness of image recognition systems. In this section, the studies proposed in the last two years to increase the performance and efficiency of diffusion filters are analyzed (2023-2024).

Keywords: Image; Image Filters; Diffusion Filter; Anisotropic Filter

1. Giriş

Günümüzde dijital görüntülerin ve bunları elde eden aygıtların özelliklerinin artması araştırmacıları böylesi büyük bir veri kaynağını analiz etmeye teşvik etmektedir. Görüntü verisi bilindiği üzere değerlidir. Ancak görsellerin atmosferik koşullar ve görüntüleme cihazlarından kaynaklı yapısı bozulabilmektedir. Bahsi geçen durumda görüntü üzerinde işlem yapmak zor olmaktadır. Söz konusu bozulmuş literatürde gürültü olarak bilinmektedir. Gürültü görüntüleme araçlarının yapısından (uydu, medikal, kamera vb.) etkilenmektedir. Bu durum gürültünün görüntü piksellerine matematiksel ifadeyle toplamsal ya da çarpımsal olarak yansımaya neden olur. İlgili durum için gürültünün kenar ve bölge piksellerinden ayrıştırılması adına görüntü filtreleri geliştirilmektedir. Görüntü filtreleri dijital görüntüler üzerinde çeşitli işlemler gerçekleştirerek görüntülerin belirli özelliklerini değiştiren veya iyileştiren yaklaşımlardır. Özellikle, görüntü işleme ve bilgisayar grafikleri alanında yaygın olarak kullanılır. Ancak filtreleme sonrası kenarların bozulması bir problemdir.

Dijital görüntülerin türlerine ve onların kullanım amacına göre çeşitli filtreler bulunmaktadır. Bugüne kadar gürültü azaltma/temizleme, bulanıklaştırma, kenar tespiti, görüntü keskinleştirme, belirli desen veya frekans bileşenlerini analiz etme, X-Ray, MRI, BT, Ultrason, Nükleer Tıp, PET, Fluoroskopi, Mamografi, Elastografi ve OCT medikal görüntüleme, kenar koruma, nesne tespiti, şekil/frekans analizi, desen tanıma, renk düzeltme ve bölütleme amacıyla pek çok filtre önerilmiştir. Filtreleme bir ön işlem olduğundan kendisinden sonra çalıştırılacak algoritmaların uygulamaya etkisini değiştireceği açıktır. Bu bağlamda hangi durumlarda hangi filtrelerin kullanılacağı bilinmeli ya da duruma göre otomatik müdahale eden adaptif/uyarlamalı metotlar tercih edilmelidir.

Bu bölümde ilk olarak, görüntü filtre türleri ve kullanım amaçlarından bahsedilmekte, ardından kenarları koruma

özelliğine sahip geleneksel yayılım filtresi ve onun geliştirilmiş yön bağımlı hali incelenmektedir. Bugüne kadar araştırmacılar ilgili filtrenin yayılım fonksiyonu veya sabiti üzerinden verimlilik ve performansı artırarak pek çok çalışma yapmışlardır. Bahsi geçen çalışmalar da ya yeni bir fonksiyon önerilmekte ya da mevcut fonksiyonda değişiklikler yapılmaktadır. Bu sebeple bölüm sonunda, yön bağımlı yayılım filtresi üzerine geliştirilen yeni teknikler analiz edilmekte ve görüntü işleme uygulamaları üzerindeki etkisi tartışılarak araştırmacılara bir yol haritası sunulmaktadır.

2. Görüntü Filtreleri

Teknik anlamda görüntü filtreleme bir fonksiyon ile görüntüye ait her piksel değerinin yeniden hesaplanmasıdır. Temel anlamda da görüntüde olması beklenmeyen piksellerin varlığını belirleme ve onları komşu kenar ya da bölge piksele dahil etme işlemidir. Ancak görüntü gürültüden arındırılırken kenarlara ait piksellerin korunması önemlidir.

Görüntü filtreleri gürültü ve keskin kenarları baskılayarak görüntüyü yumuşatma, kenarlar ve ince detayları vurgulama, belirli desen veya frekans bileşenlerini analiz etme, gürültüyü azaltırken kenarları koruma, görüntüdeki şekil ve yapısal özellikleri değiştirme, görüntüyü frekans bileşenlerine ayırarak belirli frekansları baskılama veya vurgulama ve belirli renk bileşenlerini ayırma veya manipüle etme gibi çeşitli amaçlara hizmet etmektedirler. Aşağıda temel filtre süreci gösterilmektedir:

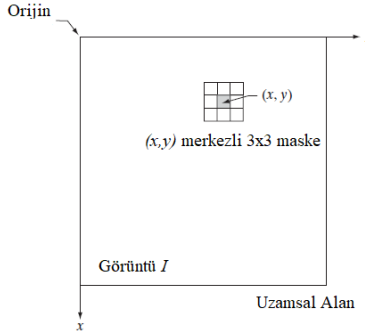
$$I(x,y) \rightarrow h(i,j) \rightarrow q(x,y)$$

Burada $I(x,y)$ girdiyi (işlenecek görüntü), $h(i,j)$ filtre fonksiyonunu ve $q(x,y)$ çıktıyı (filtrelenmiş görüntü) ifade eder. Matematiksel olarak filtreleme

$$q(x,y) = \sum_{i=-m}^m \sum_{j=-n}^n h(i,j)I(x-i,y-j) \quad (1)$$

şeklinde tanımlı olup iki boyutlu evrişim işlemidir. Eşitlik 1'de verilen $I(x-i,y-j)$ ile $M \times N$ büyüklükteki girdi görüntünün (x, y) merkezli i, j komşuluklarına erişilmektedir. Burada

$x=0,1,2,\dots,M-1$ ve $y=0,1,2,\dots,N-1$ aralığını, m ve n ise $h(i,j)$ maske fonksiyonunun uygulanacağı alanın büyüklüğünü belirtmektedir. Bu alan görüntüden küçük lokal bölgelerdir. Filtreleme çekirdek matrisi olarak da bilinen söz konusu alanın görüntüdeki her pikseli merkeze koyacak şekilde gezdirilmesi ile gerçekleşir. İlgili maske alanı 3×3 , 5×5 , 7×7 vb. olacak şekilde değiştirilebilmektedir (Şekil 1). Ancak maske boyutu büyüdükçe hassasiyet azalmaktadır.



Şekil 1. Görüntüdeki (x,y) merkezli herhangi bir noktanın 3×3 komşuluğu [1]

Bir görüntü Şekil 1'de verildiği gibi uzamsal alanda (x, y) koordinatlarına sahip piksel değerleri ile ifade edilen bir matrisi, frekans domeninde ise belli genliğe sahip frekansların oluşturduğu bir renk spektrumunu göstermektedir. Araştırmacılar görüntü filtrelerini geliştirirken her iki alanı da kullanmaktadırlar. Aşağıda hem uzamsal hem de frekans alanında çalışan ve farklı kullanım amaçlarına yönelik filtreler anlatılmaktadır.

Düşük Geçiren (Low-Pass) Filtreler

Sayısal bir görüntü uzamsal alandan Fourier dönüşümü ile frekans domenine taşınmaktadır. Frekans alanında, düşük frekansta olan bileşenler genellikle büyük değişiklikleri ve yumuşak geçişleri; yüksek frekansta olanlar ise keskin kenarları ve ayrıntıları temsil eder. Düşük geçiren filtreler [2-4] yüksek frekanslı detayları (örneğin, gürültü ve keskin kenarlar) baskıladığından görüntüyü yumuşatmaktadır. Ancak

Yang ve diğerleri alçak geçiren filtreleme yöntemlerinin görüntüdeki kontrastı düşürdüğünü ve böylece tam bir filtrelemenin olmadığını farketmişlerdir [5].

Yüksek Geçiren (High-Pass) Filtreler

Düşük frekanslı bileşenleri baskılayarak kenar ve ince detayları barındıran yüksek frekanslı bileşenleri vurgularlar. Laplace filtresi böyle bir filtre olup, kenar tespiti ve görüntü keskinleştirmede kullanılmaktadır. Ayrıca Gauss ve Butterworth yüksek geçiren filtreler de bu bağlamda yaygın olarak kullanılan filtrelerdir [6].

Belirli Frekansları Geçiren (Band-Pass) Filtreler

Belirli frekans aralığındaki bileşenleri geçirip, diğerlerini baskılayan bu filtreler, belirli desen veya frekans bileşenlerini analiz etmek adına kullanılmaktadır. Düşük frekanslar genellikle görüntünün genel yapısını veya pürüzsüz bölgelerini temsil ederken, yüksek frekanslar ince detayları ve keskin kenarları temsil eder. Belirli frekansları geçiren filtre ile de orta frekanslar geçirilerek hem kenar detaylar hem de belirli yapı taşları vurgulanmaktadır [7].

Medyan Filtresi

Bir pikselin değerini, komşu piksellerin ortancası ile değiştirir. Özellikle tuz ve biber (beyaz ve siyah) tarzı gürültüyü azaltmak için kullanılmaktadır [8]. Ancak gürültülü piksel sayısı, filtreleme için kullanılan maske alanındaki toplam piksel sayısının yarısından fazla olduğunda işe yaramamaktadır [9]. Örneğin 3x3 maske ile filtreleme yapıldığını düşünelim. Bu durumda maske alanına 9 piksel gelir. Eğer ilgili alanda gürültülü piksel sayısı 5 ve üzeri ise ortanca değer gürültülü piksele karşılık gelmektedir.

Ortalama Filtresi

Ortalama filtresi her pikselin değerini çevresindeki piksellerin ortalamasıyla değiştiren bir yöntemdir [10]. Bu, basit ve gürültüyü azaltan bir yumuşatma etkisi sağlar. Ancak

filtreleme sonucunda görüntüye ait kenarlar da yumuşatmanın etkisi ile bozulabilmektedir. Ayrıca ilgili filtrede medyan filtresinde olduğu gibi çeşitli boyutlarda maske matrisi kullanılmaktadır. Filtrenin maske katsayıları değiştirilerek ortalama filtresinin etkisi artırılabilir. Ancak kenar piksellerin yumuşatma etkisi ile bozulabilmesi dezavantajıdır.

Gauss Filtresi

Gauss filtresi, iki boyutlu görüntü fonksiyonunun Gauss fonsiyonu ile evrişiminden elde edilmektedir. Piksellere, merkezi piksele yakınlıklarına göre ağırlık vererek yumuşatma işlemi yapar [11]. Gauss filtresi, özellikle doğal görüntülerdeki gürültüyü azaltmada etkili olup ortalama filtresine göre daha doğal bir yumuşatma sağlamaktadır. Ancak geleneksel Gauss filtresinin doğrusal ve yön bağımsız olması görüntünün kenarlarında da istenmeyen yumuşama etkisi yaratmaktadır [12].

Morfolojik Filtreler

Genellikle ikili (binary) ve gri seviye görüntülerde, görüntünün şekil tabanlı özelliklerini değiştirmek, iyileştirmek veya gürültü gidermek için kullanılan iteratif bir filtredir. Görüntüdeki beyaz bölgelere erozyon, genişleme, açma ve kapama olarak bilinen işlemler ile müdahale etmektedir. Bu filtreler, nesnelerin şekillerini ve yapısal özelliklerini değiştirme yeteneğine sahip olduğundan, belirli türdeki imgelerde özellikle medikal görüntülerde ve gürültülerde etkilidir [13].

Yayınım Filtresi

Keskinleştirme ya da yumuşatma işlemi yapan görüntü filtreleri yukarıda bahsedildiği gibi gürültüyü arındırmakta ancak kenara ait pikselleri bozabilmektedir. Ya da söz konusu filtreler sadece belirli tip görüntülerde başarılı olabilmektedir. Araştırmacılar filtrelerin bahsi geçen dezavantajından ötürü filtreyi farklı yaklaşımlarla güncellemekte veya aynı amaca hizmet eden yeni bir fonksiyon önermektedirler. Bunlardan

yön bağımlı yayılım filtresi ise ilk geliştirildiği günden bu yana görüntü kenar piksellerini korumasından dolayı popüler hale gelmiştir.

Yön bağımlı yayılım filtresi ısı denklemi eşitliğine dayanan iteratif bir filtredir. Diğer filtrelerden farklı olarak gezdirilen filtre maskesi bölgedeki komşu piksellerin yapısına uygun farklı işlemler yürütebilmektedir. Böylece görüntüde gürültünün varlığını daha iyi tespit etmektedir. Sonuç olarak imgede gürültüyü azaltırken kenarları koruyabilmektedir.

Görüntü filtrelemede yumuşatma etkisi görüntünün kenarlarından ziyade bölge içlerinde olması gerekir. Yayılım filtresi içerisindeki yayılım iletkenlik katsayısı ile bölge içlerinde 1, sınırlarda 0'a ayarlanarak söz konusu problemi giderilebilmektedir. Bu kapsamda geliştirilen Perona ve Malik'in (PM) [14] iki boyutlu doğrusal olmayan yayılım eşitliği (2) de verilmiştir:

$$\frac{\partial I}{\partial t} = \text{div}(c(x, y, t)\nabla I) \quad (2)$$

Burada $c(x, y, t)$ yayılım katsayısını elde eden bir fonksiyondur. PM, ilgili fonksiyonu yön bağımlı hale getirmekte ve gradyan büyüklüğü adı verilen bir değer ile kuzey-güney ve doğu-batı doğrultularını gözeterek etkili bir sonuç üretmektedir. Neticede görüntü üzerinde gezdirilen maske ile her yerde o bölgeye uygun bir yayılım katsayısı çıkarılmaktadır. Böylece görüntünün sınırları da korunmaktadır. PM'nin kullanmış olduğu yayılım fonksiyonu (3) de gösterilmektedir.

$$c(x, y, t) = g(\|\nabla I(x, y, t)\|) \quad (3)$$

Burada $g(.)$ fonksiyonu hesapladığı gradyan değerini kenar piksellerde 0'a kadar düşürmekte ve bölge içlerinde 1 yapmaktadır. Dolayısıyla kenar piksellerde filtreleme gerçekleşmeyerek ilgili sınır değerler korunmaktadır. Görüldüğü üzere yayılım filtresinde c 'nin hesaplanması önemli bir yer bulmaktadır. Aşağıda (4) ve (5) PM'nin

geliştirdiği, (6) Charbonnier [15] ve (7)'de ise Weickert'e [16-17] ait yayılım fonksiyonlarını göstermektedir.

$$g(\nabla I) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{K}\right)^2} \quad (4)$$

$$g(\nabla I) = e^{-\left(\frac{\|\nabla I\|}{K}\right)^2} \quad (5)$$

$$g(\nabla I) = \frac{1}{\sqrt{1 + \left(\frac{\|\nabla I\|}{K}\right)^2}} \quad (6)$$


$$g(\nabla I) = \begin{cases} 1 & \|\nabla I\| = 0 \\ 1 - \exp\left(-\frac{2,3366}{K} \|\nabla I\|^4\right) & \|\nabla I\| > 0 \end{cases} \quad (7)$$

K filtre maskesinin etkisini belirleyen önemli bir katsayıdır. Tanyeri ve Demirci, söz konusu yayılım katsayısı için ayrık Haar dalgacık dönüşümü tabanlı bir yaklaşım önermişlerdir. Çalışmaları uyarlamalı bir yöntem olup her gürültü ve görüntü türüne göre otomatik olarak gürültü indirgeme yapmaktadır [18]. Araştırmacılar yayılım katsayıları ve yayılım fonksiyonu üzerinden pek çok yön bağımlı yayılım filtresi modelleri önerilmektedir. Yön bağımlı yayılım filtreleri görüntü işleme uygulamalarında pek çok amaçla kullanılmaktadır. İzleyen kısımlarda bahsedilen çalışmalar analiz edilmektedir.

2. Yön Bağımlı Yayılım Filtresi Güncel Çalışmalar

WoS (Web of Science Core Collection)'a veri tabanına göre bugüne kadar yapılan çalışmalarda 1397 görüntü filtreleme çalışması bulunmaktadır. Bunlardan yayılım filtresini anahtar kelimelerde kullananların sayısı ise 289'dur. Bu da yaklaşık olarak yıllık ortalama 11 yayına ve neredeyse her ay 1 çalışmaya karşılık gelmektedir (Şekil 2). Yayılım filtresi kelime grubunun çalışmanın herhangi bir yerinde geçmesi durumuna bakılarak gerçekleştirilen sorgulamada ise 1320 adet makale bulunmaktadır. Anlaşılacağı üzere difüzyon filtresi sadece temel amacı olan filtreleme şeklinde değil daha

pek çok amaca hizmet eden bir ön işlem olarak da kullanıldığı açıktır. Geliştirilen bu çalışmaların araştırma alanlarına bakıldığında ise çoktan aza doğru mühendislik, bilgisayar bilimleri, fotoğraf teknolojisi, nükleer tıp, optik, matematik, telekomünikasyon ve fizik ve diğer alanlarda gerçekleştiği görülmektedir.



Şekil 2. WoS ISI'de Yıllara Göre Yayınım Filtresi Çalışma Sayıları

Son iki yılda (2023-2024) yapılan yayınım filtresi çalışmaları [19-46] Çizelge 1'de çalışma alanlarına göre sınıflandırılmaktadır:

Çizelge 1. 2023-2024 WoS veri tabanı yayınım filtresi kullanan çalışmaların sınıflandırması

Kategori	Kaynak
Görüntü İşleme ve Gürültü Giderme	[19, 24, 25, 28, 30, 32, 33, 35-37, 40, 44, 46]
Medikal Görüntüleme	[26, 27, 29, 45]
Sinyal İşleme ve Algoritmalar	[21, 23, 41-43]
Gürültü Kontrolü ve Ses İşleme	[31, 39]

Çizelge 1'de verilen çalışmaların kullandıkları yöntemler ise aşağıda maddeler halinde verilmektedir.

Görüntü İşleme ve Gürültü Giderme

- Görüntülerdeki gürültüyü azaltmak ve detayları korumak için doğrusal olmayan filtreleme tekniklerini kullanır. Bu, görüntü eşleştirmede hız ve doğruluk sağlar.
- Görüntüyü farklı frekans bileşenlerine ayırır ve yarı-adaptif difüzyon filtreleri ile gürültüyü azaltır.
- Polinomsal uydurma ile gerilme alanlarını düzleştirir ve anizotropik difüzyon ile hassas gürültü azaltma sağlar.
- Seyrek görünüm CT verilerini daha net 3D görüntüler elde etmek için kullanılır.
- Parmak izi gibi görüntülerin kalitesini artırmak için birden fazla filtre uygulanır.
- Birden fazla odak noktasındaki görüntüleri birleştirir ve ağırlıklı anizotropik difüzyon filtresi kullanır.
- Farklı modalitelerden gelen medikal görüntüleri birleştirir ve anizotropik difüzyon filtrelemesi kullanır.
- CT ve MRI görüntülerini birleştirir ve ağırlık optimize edilmiş difüzyon filtreleri kullanır.
- Deri kanseri lezyonlarını segmentler ve çok sınıflı genişletilmiş D-Net kullanır.
- Anizotropik difüzyon filtreleri için adaptif eşik seçiminde sinir ağları kullanılır.
- Radar görüntülerin kaydırılmasında doğrusal olmayan difüzyon filtreleme ve Hessian özellikleri kullanılır.
- Hareketli hedeflerin görüntülenmesi için hız adaptif nokta yayılma fonksiyonu çözme ve X şeklinde gürültü azaltma filtrelemesi kullanılır.
- Dermatoskopik örneklerde deri lezyonlarının otomatik tespiti ve sınıflandırması için DenseNet-169 mimarisini kullanılır.

Medikal Görüntüleme

- Ultrason görüntülerindeki Down sendromu belirtilerini sınıflandırmak için yoğun sinir ağları kullanılır.
- Sıçanlarda sağ ventrikül gerilme tahminini geliştirmek için anizotropik difüzyon filtreleme uygulanır.
- Retinal damar görüntülerindeki uyumluluğun, damar segmentasyonundaki etkisini inceler.
- Beyin MRI'larında tümör segmentasyonunu ve sınıflandırmasını Fuzzy C-Means (FCM) ve Destek Vektör Makineleri (SVM) ile iyileştirir.
- MR görüntülerde beyin tümörlerini bulanık eşikleme ve doku özellik tanımlayıcıları ile tespit eder.

Sinyal İşleme ve Algoritmalar

- Sinyal düzeltmesi için HERS algoritması ve zaman kesirli difüzyon denklemi kullanılır. Bu, sinyal gürültüsünü azaltmada etkili bir yöntemdir.
- Güven temelli bir yaklaşım ile hedef takibinde dağıtılmış H_{∞} difüzyon filtrelemesi kullanılır, siber saldırılar altında performansı artırır.
- Deniz altı su objesi görüntülerinin tespiti ve sınıflandırılması için geliştirilmiş bir optimizasyon yöntemi ve yinelemeli konvolüsyonel sinir ağları kullanılır.
- GOCE yerçekimi gradyanlarının 1D boyunca işlenmesi ve mekansal alanda radial bileşenlerin doğrusal olmayan filtrelemesi yapılır.
- Küçük ve düşük hedeflerin tespiti için mekansal-zamansal filtreleme ve yüksek mertebeden enerji tahmini yöntemleri kullanılır.

Gürültü Kontrolü ve Ses İşleme

- Rüzgar gürültüsünün ANC kulaklıklarının performansını nasıl etkilediği ve dağıtılmış filtered-x LMS algoritmaları ile rüzgar gürültüsünün nasıl bastırıldığı incelenir.

Bu çalışmalara amaç ve uygulama alanları, yöntem ve teknikleri, genel eğilimler ve farklılıklar açısından bakılarak yapılan genel analiz aşağıda verilmektedir.

Amaç ve Uygulama Alanları

Görüntü İşleme ve Gürültü Giderme: Çoğu çalışma, görüntülerin kalitesini artırma, gürültüyü azaltma ve detayları koruma amacını taşır. Bu, özellikle tıbbi görüntüleme, parmak izi analizi ve multi-fokus görüntü birleştirme gibi alanlarda önemlidir.

Medikal Görüntüleme: Bu çalışmalar, tıbbi görüntülerin analizi ve iyileştirilmesi üzerine odaklanır. Anizotropik difüzyon filtreleme ve diğer teknikler, medikal görüntülerde daha iyi segmentasyon ve sınıflandırma sağlamayı hedefler.

Sinyal İşleme ve Algoritmalar: Bu kategori, sinyal düzeltilmesi ve algoritma optimizasyonu üzerine odaklanır. Özellikle HERS algoritması ve zaman kesirli difüzyon denklemleri gibi yöntemler, sinyal kalitesini artırmak için kullanılır.

Gürültü Kontrolü ve Ses İşleme: Rüzgar gürültüsünün etkileri ve gürültü bastırma algoritmaları bu çalışmalarda ele alınır. Aktif gürültü kontrolü ve filtreleme teknikleri ile ses kalitesi iyileştirilir.

Yöntemler ve Teknikler

Söz konusu çalışmalarda yaygın filtreleri tek başına ya da çoklu filtreleme tekniklerinde birleştirerek kullanılmaktadır. İlgili teknikler gruplanarak aşağıda özetlenmektedir.

Anizotropik Difüzyon: Görüntülerde yön bağımlı filtreleme sağlar, detayları korurken gürültüyü azaltır. Medikal görüntüleme, çoklu modalite birleştirme ve diğer görüntüleme uygulamalarında yaygın olarak kullanılır.

Doğrusal Olmayan Filtreleme: Görüntü eşleştirme ve genel gürültü azaltma için kullanılır. Bu teknikler, görüntülerdeki bozulmaları ve gürültüleri azaltmada etkilidir.

Değişken Mod Ayırıştırması (DMA): Görüntüleri farklı frekans bileşenlerine ayırarak ve gürültü azaltma sağlar. Yarı-adaptif difüzyon filtreleri ile birleştirmede, yüksek kaliteli sonuçlar elde edilir.

Çoklu Filtreleme: Birden fazla filtre kullanarak görüntü iyileştirme sağlanır. Bu, farklı türdeki gürültüleri ve bozulmaları etkili bir şekilde ele alır.

Genel Eğilimler

İyileştirilmiş Görüntü Kalitesi: Birçok çalışma, görüntülerin netliğini artırmak ve detayları korumak için çeşitli filtreleme teknikleri kullanır. Bu, medikal görüntüleme, parmak izi analizi ve diğer alanlarda büyük önem taşır.

Adaptif ve Optimizasyon Teknikleri: Adaptif eşikleme ve optimizasyon teknikleri, filtrelemenin etkinliğini artırmak için kullanılır. Bu teknikler, farklı koşullara uyum sağlayarak daha iyi sonuçlar elde edilmesini sağlar.

Multimodal ve Çoklu Odaklı Yaklaşımlar: Çeşitli modalitelerde ve odak noktalarında görüntüleri birleştirme, görüntü kalitesini artırmak ve daha kapsamlı analizler yapmak için kullanılır. Bu, özellikle medikal görüntüleme ve araştırma uygulamalarında önemlidir.

Sinyal ve Gürültü Yönetimi: Sinyal işleme ve gürültü kontrolü, hem görüntü hem de ses uygulamalarında ön plandadır. Bu çalışmalar, sinyal kalitesini artırmak ve istenmeyen gürültüleri azaltmak için geliştirilmiş teknikleri içerir.

Farklılıklar

Kullanım Alanları: Çalışmaların bazıları medikal görüntüleme, bazıları genel görüntü işleme ve bazıları ses işleme alanlarına yöneliktir. Her alan, filtreleme tekniklerini farklı ihtiyaçlara göre uyarlamıştır.

Teknik Yaklaşımlar: Çalışmalar, kullanılan teknikler açısından çeşitlilik gösterir; bazıları anizotropik difüzyon, bazıları DMA ve diğerleri adaptif eşikleme gibi yöntemlere

odaklanır. Bu çeşitlilik, farklı problem türlerine ve veri setlerine uygun çözümler sunar.

Hangi tekniğin daha etkili olduğunu belirlemek, genellikle spesifik uygulama ve veri setine bağlıdır. Ancak, genel olarak aşağıdaki yukarıda bahsi geçen tekniklerin avantajları ve etkili olduğu alanlar hakkında bir değerlendirme yapılmaktadır.

3. Yayınım Filtresi Güncel Çalışmaların Etkililiği, Avantajlar ve Sınırlamalar

Anizotropik Difüzyon Filtreleme

Etkililik: Anizotropik difüzyon filtreleme, özellikle görüntülerin kenarlarını ve detaylarını koruyarak gürültüyü azaltmada çok etkilidir. Yönlü filtreleme uygulayarak, görüntüdeki farklı bölgelerde farklı derecelerde difüzyon yapar.

Avantajlar: Detayları korur ve aşırı düzleştirmeden gürültü azaltımı sağlar. Tıbbi görüntüler, parmak izi analizi ve çoklu modalite görüntü birleştirme gibi uygulamalarda sıklıkla tercih edilir.

Sınırlamalar: Yüksek hesaplama maliyeti olabilir ve bazı durumlarda kontrastı düşürebilir.

Doğrusal Olmayan Filtreleme

Etkililik: Doğrusal olmayan filtreleme, genellikle görüntü eşleştirme ve genel gürültü azaltma için etkilidir. Özellikle yüksek düzeyde gürültü ve bozulma içeren görüntülerde iyi performans gösterebilir.

Avantajlar: Görüntüdeki detayları kaybetmeden etkili gürültü azaltımı sağlar. Görüntü eşleştirme ve desen tanıma gibi uygulamalarda etkilidir.

Sınırlamalar: Filtreleme parametrelerinin ayarlanması gerekebilir ve bazı durumlarda sonuçlar belirsiz olabilir.

Değişken Mod Ayırıştırması (DMA)

Etkililik: DMA, görüntüyü farklı frekans bileşenlerine ayırarak, her bileşeni ayrı ayrı işleyerek gürültüyü azaltmada

etkilidir. Yarı-adaptif difüzyon filtreleri ile birleştğinde, yüksek kaliteli sonuçlar elde edilir.

Avantajlar: Gürültü azaltma ve detay koruma açısından güçlüdür. Özellikle karmaşık ve yüksek frekans bileşenlerine sahip görüntüler için uygundur.

Sınırlamalar: Hesaplama karmaşıklığı yüksek olabilir ve parametre ayarlamaları gerektirebilir.

Çoklu Filtreleme

Etkililik: Birden fazla filtre kullanımı, çeşitli türdeki gürültüleri ve bozulmaları etkili bir şekilde ele alabilir. Filtrelerin kombinasyonu, daha kapsamlı bir iyileştirme sağlar.

Avantajlar: Görüntü kalitesini artırma konusunda esneklik sağlar. Çeşitli türdeki gürültü ve bozulmalarla başa çıkabilir.

Sınırlamalar: Filtreleme süreci karmaşık olabilir ve daha fazla işlem süresi gerektirebilir.

Adaptif Eşikleme

Etkililik: Adaptif eşikleme, filtreleme sürecinin dinamik olarak ayarlanmasını sağlar, böylece farklı koşullara uyum sağlar ve filtrelemenin etkinliğini artırır.

Avantajlar: Filtrelemenin esnekliğini artırır ve değişken veri koşullarına uyum sağlar.

Sınırlamalar: Hesaplama maliyeti artabilir ve doğru eşik değerlerinin belirlenmesi zor olabilir.

4. Sonuç

Yayınım filtresi için analizi yapılan çalışmalar, görüntü ve sinyal işleme alanlarında yayınım filtrelerinin çeşitli uygulamalarını ve etkilerini göstermektedir. Ortak hedefler genellikle görüntü kalitesini artırmak, gürültüyü azaltmak ve detayları korumak üzerine odaklanmıştır. Kullanılan teknikler, uygulama alanına göre değişiklik gösterse de, her biri belirli sorunları çözmek için optimize edilmiştir.

Ayrıca incelenen güncel çalışmalardan medikal görüntüleme anizotropik difüzyon filtrelemenin genellikle tercih edildiği çünkü detayları koruyarak gürültüyü azalttığı anlaşılmaktadır. Doğrusal olmayan filtreleme ve VMD ise yüksek düzeyde gürültü ve bozulma içeren görüntülerde etkili olabilir. Çoklu filtreleme ve adaptif eşikleme yöntemleri, çeşitli türdeki bozulmaları ele almak için esneklik sağlar.

Yön bağımlı yayılım filtresi ile ilgili çalışma yapmak, matematiksel temellerin anlaşılması, uygun yöntemlerin seçilmesi, uygulama ve performans değerlendirmesi aşamalarını içerir. Bu süreçler, her aşamada dikkatli planlama ve optimizasyon gerektirir. Sonuçların değerlendirilmesi ve iyileştirilmesi, araştırmanın kalitesini artıracaktır.

Kaynaklar

- [1] Gonzalez, R. C., & WOODS 3rd, R. E. (2008). Edition. Digital Image Processing. Upper Saddle River, USA: Prentice Hall.
- [2] Fabian, A. C., Sanders, J. S., Allen, S. W., Crawford, C. S., Iwasawa, K., Johnstone, R. M., ... & Taylor, G. B. (2003). A deep Chandra observation of the Perseus cluster: shocks and ripples. Monthly Notices of the Royal Astronomical Society, 344(3), L43-L47.
- [3] Sanders, J. S., Fabian, A. C., Russell, H. R., Walker, S. A., & Blundell, K. M. (2016). Detecting edges in the X-ray surface brightness of galaxy clusters. Monthly Notices of the Royal Astronomical Society, 460(2), 1898-1911.
- [4] Misra, D., Mishra, S., & Appasani, B. (2018). Advanced image processing for astronomical images. arXiv preprint arXiv:1812.09702.
- [5] Yang, G. Z., Burger, P., Firmin, D. N., & Underwood, S. R. (1996). Structure adaptive anisotropic image filtering. Image and Vision Computing, 14(2), 135-145.
- [6] Dogra, A., & Bhalla, P. (2014). Image sharpening by gaussian and butterworth high pass filter. Biomedical and pharmacology journal, 7(2), 707-713.
- [7] Christiano, L. J., & Fitzgerald, T. J. (2003). The band pass filter. International economic review, 44(2), 435-465.
- [8] Ataman, E., Aatre, V., & Wong, K. (1981). Some statistical properties of median filters. IEEE Transactions on Acoustics, Speech, and Signal Processing, 29(5), 1073-1075.
- [9] Haddad, R. A., & Akansu, A. N. (1991). A class of fast Gaussian binomial filters for speech and image processing. IEEE Transactions on Signal Processing, 39(3), 723-727.
- [10] Kundu, A., Mitra, S., & Vaidyanathan, P. (1984). Application of two-dimensional generalized mean filtering for removal of impulse noises from images. IEEE transactions on acoustics, speech, and signal processing, 32(3), 600-609.
- [11] Haddad, R. A., & Akansu, A. N. (1991). A class of fast Gaussian binomial filters for speech and image processing. IEEE Transactions on Signal Processing, 39(3), 723-727.
- [12] Zhang, L., & Tam, W. J. (2005). Stereoscopic image generation based on depth images for 3D TV. IEEE Transactions on broadcasting, 51(2), 191-199.
- [13] Maragos, P. (1987). Tutorial on advances in morphological image processing and analysis. Optical engineering, 26(7), 623-632.
- [14] Perona, P., & Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. IEEE Transactions on pattern analysis and machine intelligence, 12(7), 629-639.
- [15] Charbonnier, P., Blanc-Feraud, L., Aubert, G., & Barlaud, M. (1994, November). Two deterministic half-quadratic regularization algorithms for computed imaging. In Proceedings of 1st international conference on image processing (Vol. 2, pp. 168-172). IEEE.

- [16] Weickert, J., Romeny, B. T. H., & Viergever, M. A. (1998). Efficient and reliable schemes for nonlinear diffusion filtering. *IEEE transactions on image processing*, 7(3), 398-410.
- [17] Weickert, J. (1998). *Anisotropic diffusion in image processing* (Vol. 1, pp. 59-60). Stuttgart: Teubner.
- [18] Tanyeri, U., & Demirci, R. (2018). Wavelet-based adaptive anisotropic diffusion filter. *Advances in Electrical and Computer Engineering*, 18(4), 99-106.
- [19] Yin, C., Zhang, F., Hao, B., Fu, Z., & Pang, X. (2024). Research on a Fast Image-Matching Algorithm Based on Nonlinear Filtering. *Algorithms*, 17(4), 165.
- [20] Zhou, Z., & Luo, H. (2024). A Method of Printmaking Image Generation Based on Convolutional Neural Network. *Journal of Circuits, Systems and Computers*, 33(08), 2450151.
- [21] Gao, Y., Zhu, H., Li, X., & Amuri, M. J. V. (2023). Trust-Based Distributed H_{∞} Diffusion Filtering for Target Tracking Under Cyber Attacks. *IEEE Access*, 11, 119388-119395.
- [22] Hu, Y., Zhang, X., Li, D., Li, W., Zhang, L., Fu, H., & Zhang, L. (2023). Anisotropic diffusion filters for flow-dependent variational data assimilation of sea surface temperature. *Ocean Modelling*, 184, 102233.
- [23] Jayaraj, A. P., Gounder, K. N., & Rajagopal, J. (2024). Optimizing signal smoothing using HERS algorithm and time fractional diffusion equation. *Expert Systems with Applications*, 238, 122250.
- [24] Wang, Z., Zhu, P., Liu, L., & Zhou, X. (2024). An accurate and robust strain field smoothing method based on polynomial fitting and anisotropic diffusion in digital image correlation. *Measurement*, 225, 113947.
- [25] Liu, Y., Zhu, T. F., Luo, Z., & Ouyang, X. P. (2024). 3D robust anisotropic diffusion filtering algorithm for sparse view neutron computed tomography 3D image reconstruction. *Nuclear Science and Techniques*, 35(3), 50.
- [26] Mukherjee, T., Neelakantan, S., Choudhary, G., & Avazmohammadi, R. (2023, April). Improved right ventricular strain estimation in rats using anisotropic diffusion filtering. In *Medical Imaging 2023: Ultrasonic Imaging and Tomography* (Vol. 12470, pp. 176-182). SPIE.
- [27] Soomro, T. A., Jandan, N. A., Ali, A., Irfan, M., Rahman, S., Aldhabaan, W. A., ... & Abuallut, I. (2023). Impact of retinal vessel image coherence on retinal blood vessel segmentation. *Electronics*, 12(2), 396.
- [28] Shams, H., Jan, T., Khalil, A. A., Ahmad, N., Munir, A., & Khalil, R. A. (2023). Fingerprint image enhancement using multiple filters. *PeerJ Computer Science*, 9, e1183.
- [29] Pregitha, R. E., Vinod Kumar, R. S., & Kumar, C. E. S. (2023). Down syndrome markers classification via dense neural network in ultrasound foetal image. *Soft Computing*, 1-13.
- [30] Gupta, H., Singh, H., Kumar, A., Vishwakarma, A., & Singh, G. K. (2024). Variational mode decomposition based image denoising using semi-adaptive conductance function inspired diffusion filtering. *Multimedia Tools and Applications*, 83(3), 7433-7456.

- [31] Chen, M., Chu, Y., Zhao, Y., Niu, F., & Sun, H. (2024). Effect of wind noise on active noise control headphones and wind noise suppression in distributed filtered-x least mean squares algorithms. *Applied Acoustics*, 220, 109951.
- [32] Vasu, G. T., & Palanisamy, P. (2023). Gradient-based multi-focus image fusion using foreground and background pattern recognition with weighted anisotropic diffusion filter. *Signal, Image and Video Processing*, 17(5), 2531-2543.
- [33] Kaur, H., Vig, R., Kumar, N., Sharma, A., Dogra, A., & Goyal, B. (2024). Fusion of Multimodal Medical Images Based on Fine-Grained Saliency and Anisotropic Diffusion Filter. *Current Medical Imaging*.
- [34] Nithya, V. P., Mohanasundaram, N., & Santhosh, R. (2023). An Early Detection and Classification of Alzheimer's Disease Framework Based on ResNet-50. *Current Medical Imaging*.
- [35] Vasu, G. T., & Palanisamy, P. (2023). CT and MRI multi-modal medical image fusion using weight-optimized anisotropic diffusion filtering. *Soft Computing*, 27(13), 9105-9117.
- [36] Kumar, M. D., Sivanarayana, G. V., Indira, D. N. V. S. L. S., & Raj, M. P. (2023). Skin cancer segmentation with the aid of multi-class dilated D-net (MD2N) framework. *Multimedia Tools and Applications*, 82(23), 35995-36018.
- [37] Kılıçaslan, M. (2024). Adaptive threshold selection of anisotropic diffusion filters using spiking neural network model. *Signal, Image and Video Processing*, 18(1), 407-416.
- [38] Alekhya, B., Sasikumar, R., Kumar, N. S., & Bharathiraja, N. (2023). Hybrid ICHO-HSDC Model For Accurate Covid-19 Detection and Classification From CT Scan And X-Ray Images. *INTERNATIONAL JOURNAL OF COMPUTERS COMMUNICATIONS & CONTROL*, 18(4).
- [39] Reddy, K. R., & Dhuli, R. (2023). Detection of brain tumors from MR images using fuzzy thresholding and texture feature descriptor. *The Journal of Supercomputing*, 79(8), 9288-9319.
- [40] Tang, G., Wei, Z., & Zhuang, L. (2024). SAR Image Registration: The Combination of Nonlinear Diffusion Filtering, Hessian Features and Edge Points. *Sensors*, 24(14), 4568.
- [41] Jasmine, J. J., Raja, S. E., Muniraj, R., & Jarin, T. (2024). An improved dung beetle optimization with recurrent convolutional neural networks for efficient detection and classification of undersea water object images. *Earth Science Informatics*, 1-21.
- [42] ČUNDERLÍK, R., KOLLÁR, M., & MIKULA, K. (2023). 1D along-track pre-processing of the GOCE gravity gradients and nonlinear filtering of the radial components V_{zz} in spatial domain. *Contributions to Geophysics and Geodesy*, 53(4), 333-351.
- [43] Xiangsuo, F., Wenlin, Q., Juliu, L., Qingnan, H., & Fan, Z. (2023). Dim and small target detection based on spatio-temporal filtering and high-order energy estimation. *IEEE Photonics Journal*, 15(2), 1-20.
- [44] Wang, Y., Huang, C., Qu, Y., Li, M., & Li, J. (2023). Velocity-adaptive irregular point spread function deconvolution imaging using X-shaped denoising diffusion filtering. *IEEE Transactions on Geoscience and Remote Sensing*.

- [45] Alqhtani, S. M., Soomro, T. A., Ali, A., Aziz, A., Irfan, M., Rahman, S., ... & Eljak, L. A. B. (2024). Improved Brain Tumor Segmentation and Classification in Brain MRI with FCM-SVM: A Diagnostic Approach. IEEE Access.
- [46] Ashwini, A., Purushothaman, K. E., Rosi, A., & Vaishnavi, T. (2023). Artificial Intelligence based real-time automatic detection and classification of skin lesion in dermoscopic samples using DenseNet-169 architecture. Journal of Intelligent & Fuzzy Systems, (Preprint), 1-16.

KARDİOVASKÜLER HASTALIKLARIN ERKEN TEŞHİSİNDE MAKİNE ÖĞRENİMİ: 2019-2024 YILLARI ARASI İNCELEME

Rukiye Uzun Arslan¹, İrem Şenyer Yapıcı²

Özet

Kardiyovasküler (kalp) hastalıklar, dünya çapında en yaygın ölüm nedenlerinden biri olarak kabul edilmektedir. Mevcut kalp hastalığı teşhis yöntemleri arasında elektrokardiyogram (EKG), en az maliyetli ve invaziv olmayan bir yöntemdir. Ancak, tıbbi uzmanların kısıtlı sayısı, EKG yorumlarının karmaşıklığı, EKG sinyallerindeki kalp hastalıklarının benzeşen gösterimleri ve hastalıkların komorbidite durumu gibi çeşitli zorluklar bulunmaktadır. Bu nedenle, kalp hastalığının teşhisi için makine öğrenimi (MÖ) algoritmaları, geleneksel teşhis yöntemlerine uygun alternatifler olarak önerilmektedir. Ancak, bu algoritmaların 'kara kutu' yapısı ve model sonuçlarının açıklanmasındaki zorluklar, tıp uzmanlarının bu modellere güven duymasına engel olmaktadır. Bu durum, doktorların güvenini sağlayacak ve kanıta dayalı tanıları sunabilecek MÖ modellerinin geliştirilmesi ihtiyacını ortaya çıkarmaktadır. Bu derleme çalışmasında, özellikle son beş yıl içerisinde kalp hastalıklarının erken evrede teşhis edebilmek amacıyla geliştirilen MÖ tabanlı karar

¹ Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, rukiyeuzun67@gmail.com, ORCID: 0000-0002-2082-8695

² Bilgisayar Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, senyerirem@gmail.com, ORCID: 0000-0003-0655-340X

destek sistemleri incelenmiştir. İncelenen çalışmalar, MÖ algoritmalarının kalp hastalığı teşhisindeki etkinliğini ortaya koymaktadır. Karar ağaçları, destek vektör makineleri, k-en yakın komşu, lojistik regresyon ve rastgele orman gibi çeşitli algoritmaların kullanıldığı çalışmalarda yüksek doğruluk oranlarına ulaşılmıştır. Bu algoritmaların kullanımı, özellikle erken teşhis ve hastalığın yönetiminde önemli avantajlar sağlamaktadır. Sonuç olarak, MÖ tabanlı karar destek sistemlerinin kalp hastalığı teşhisindeki potansiyeli büyük olup, literatürdeki çalışmalar bu alandaki önemli ilerlemeleri ve mevcut zorlukları gözler önüne sermektedir. Gelecekteki araştırmalar, tıbbi uzmanların bu teknolojilere olan güvenini artırmak ve klinik uygulamalarda daha geniş bir kabul görmesini sağlamak amacıyla model açıklanabilirliği ve güvenilirliği konularına odaklanmalıdır. Bu derleme, kalp hastalığı teşhisinde MÖ uygulamalarının mevcut durumunu ve gelecekteki araştırma yönelimlerini özetleyerek, bu alandaki bilgi birikimine katkıda bulunmaktadır.

Anahtar Kelimeler: Kardiyovasküler hastalıklar; makine öğrenmesi; karar destek sistemleri

Machine Learning in Early Diagnosis of Cardiovascular Diseases: A Review of 2019-2024 Studies

Abstract

Cardiovascular (heart) diseases are considered one of the most common causes of death worldwide. Among the current diagnostic methods for heart disease, the electrocardiogram (ECG) is the least costly and non-invasive method. However, there are several challenges, such as the limited number of medical experts, the complexity of ECG interpretations, the similar representations of heart diseases in ECG signals, and the comorbidity of diseases. Therefore, machine learning (ML) algorithms are proposed as suitable alternatives to traditional diagnostic methods for heart disease diagnosis. However, the “black box” nature of these algorithms and

the difficulty in explaining model results hinder medical professionals' trust in these models. This situation necessitates the development of ML models that can ensure doctors' trust and provide evidence-based diagnoses. This review study examines ML-based decision support systems developed over the past five years to diagnose heart diseases at an early stage. The reviewed studies demonstrate the effectiveness of ML algorithms in diagnosing heart diseases. Studies using various algorithms, such as decision trees, support vector machines, k-nearest neighbors, logistic regression, and random forest, have achieved high accuracy rates. The use of these algorithms provides significant advantages, particularly in early diagnosis and disease management. Consequently, the potential of ML-based decision support systems in heart disease diagnosis is substantial, and the literature highlights significant advancements and existing challenges in this field. Future research should focus on model explainability and reliability to increase medical professionals' trust in these technologies and ensure wider acceptance in clinical applications. This review contributes to the knowledge base in this field by summarizing the current status and future research directions of ML applications in heart disease diagnosis.

Keywords: Cardiovascular diseases; machine learning; decision support systems

1. Giriş


Kardiyovasküler hastalıklar (KVH), kalp ve damar sistemini etkileyerek genellikle ciddi komplikasyonlara yol açan rahatsızlık grubudur. Bu hastalıklar, koroner arter hastalığı, kalp yetmezliği, kardiyomiyopati, kardiyak aritmiler ve periferik damar hastalıkları gibi çeşitli kalp ve damar rahatsızlıklarını kapsamaktadır [1]. KVH'nin ortaya çıkmasında genetik yatkınlık ve bireysel alışkanlıklar gibi birçok faktör rol oynamaktadır. Özellikle sigara kullanımı, aşırı alkol ve kafein tüketimi, stres ve fiziksel hareketsizlik gibi davranışsal faktörler, KVH riskini artırmaktadır. Bunun

yanı sıra, obezite, hipertansiyon, yüksek kan kolesterolü ve mevcut kalp rahatsızlıkları gibi fizyolojik faktörler de KVH gelişiminde önemli bir rol oynamaktadır [2]. Dünya Sağlık Örgütü'ne (DSÖ) göre, her yıl yaklaşık 18 milyon insan KVH nedeniyle hayatını kaybetmektedir. Dünya genelindeki tüm ölümlerin yaklaşık %32'sini oluşturan bu kayıpların büyük bir kısmı (dörtte üçünden fazlası) düşük ve orta gelirli ülkelerde gerçekleşmektedir [3].

KVH belirtileri diğer hastalıklarla benzerlik gösterebildiği için doğru ve erken tıbbi teşhis, bu hastalıkların ölümle sonuçlanmasını önlemede hayati bir önem taşımaktadır. Günümüzde KVH teşhisinde elektrokardiyogram (EKG), ekokardiyogram, koroner bilgisayarlı tomografi anjiyogram, kardiyak manyetik rezonans görüntüleme gibi invazif olmayan yöntemlerin yanı sıra kan testleri ve koroner anjiyogram gibi invazif teknikler de kullanılmaktadır [4, 5]. Bu teknikler arasında EKG, basit uygulanabilirliği, hızlı sonuçları, düşük maliyeti ve geniş bir yelpazede kalp hastalıklarının tanısında kullanılabilir olması nedeniyle yaygın olarak tercih edilmektedir [6].

Elektrokardiyografi (EKG), kalbin elektriksel aktivitesini, cilt yüzeyine yerleştirilen elektrotlar aracılığıyla kaydeden ve bu verilerle tanı konulmasını sağlayan bir yöntemdir. Kalpte sürekli devam eden bir elektriksel sistem bulunmaktadır. EKG, bu elektriksel aktivitenin zaman içerisindeki değişimini grafiksel olarak sunmaktadır. Geleneksel EKG uygulaması, hasta sırtüstü yatar pozisyonda iken 12 derivasyonlu elektrotlar kullanılarak gerçekleştirilmektedir. Derivasyonlar, kalbin elektriksel aktivitesini farklı anatomik noktalardan kaydederek kalp fonksiyonlarının detaylı bir analizini sağlamaktadır. Vücut yüzeyine yerleştirilen elektrotlar, kalp kasının depolarizasyonu ve repolarizasyonu sırasında oluşan küçük elektriksel sinyalleri algılamaktadır. Bu sinyaller, sinoatriyal düğümde başlayarak atriyumların (kulakçıkların) depolarizasyonunu, ardından ventriküllerin (karıncıkların) depolarizasyonunu ve repolarizasyonunu içeren bir dizi

elektriksel aktiviteyi kaydetmektedir. EKG kaydında bu aktiviterler, P dalgası, QRS kompleksi ve T dalgası gibi belirli dalga formları ve aralıklarla temsil edilmektedir (Şekil 1). P dalgası kulakçıkların depolarizasyonunu, QRS kompleksi ventriküllerin depolarizasyonunu ve T dalgası ventriküllerin repolarizasyonunu göstermektedir. EKG, bu dalga formlarının analiz edilmesiyle kalp ritmi ve iletim sistemi hakkında detaylı bilgi sağlamaktadır.



Şekil 1. Tipik bir EKG dalga şekli.

EKG'nin klinik kullanımı, aritmi, miyokard enfarktüsü, iskemik kalp hastalığı ve diğer kardiyak anormalliklerin tespiti ve takibi için oldukça önem arz etmektedir. Ayrıca, EKG verileri, hastanın tedavi sürecinin izlenmesi ve ilaç tedavisinin etkinliğinin değerlendirilmesinde de kritik rol oynamaktadır. Bu nedenle, EKG'nin doğru yorumlanması ve elde edilen verilerin klinik bağlamda değerlendirilmesi, kardiyovasküler hastalıkların yönetiminde temel bir unsurdur. Ancak, farklı uzmanlık seviyelerindeki hekimlerin EKG'leri doğru bir şekilde yorumlamakta zorlandıkları bilinmektedir. Higuera ve arkadaşları tarafından yapılan çalışmada, 153 asistan ve 42 uzman doktor olmak üzere toplam 195 doktordan oluşan bir çalışma grubunda EKG yorumlama becerilerinin yeterli düzeyde olmadığı ortaya konulmuştur [7]. Diğer taraftan farklı türdeki kalp hastalıklarının varlığı, uzman bir kardiyolog için bile EKG sinyalinin yorumlanmasında zorluklara neden

olabilmektedir. Bununla birlikte, kalp hastalığı belirtilerinin EKG sinyalleri üzerindeki benzerlikleri, bunların doğru bir şekilde ayırt edilmesini daha da zorlaştırabilmektedir. Ayrıca, EKG sinyal kaydı, aynı hastalık için hastanın yaşına, etnik kökenine ve genel sağlık durumuna bağlı olarak değişkenlik gösterebilmektedir [6]. Bu durum, EKG'nin KVH'nın teşhis sürecindeki rolünü daha da karmaşık hale getirmektedir.

KVH teşhisinde karşılaşılan zorlukların üstesinden gelebilmek ve doktora yardımcı olmak amacıyla EKG kayıtları bilgisayar destekli analizi kullanılmaya başlanmıştır [8]. Ancak yapılan araştırmalar, bu analizlerin önemli ölçüde hatalı sonuçlar verdiğini ve sınırlılıklarının olduğunu göstermiştir [9]. Bu nedenle, otomatik EKG yorumlama tekniklerinin doğruluğunu artırmaya yönelik çabalarına rağmen, son EKG yorumlaması hala bir doktor tarafından tekrar gözden geçirilmeyi gerektirmektedir. Ayrıca, bilgisayar destekli EKG yorumlaması için uluslararası kabul görmüş bir standardın olmaması, bu teknolojiye güvenmenin bir zorluğunu oluşturmaktadır [8]. Bu durum, bilgisayar destekli EKG yorumlamasının güvenilirliği ve kullanılabilirliği açısından önemli bir engel teşkil etmektedir.

Son yıllarda makine öğreniminin (MÖ) gelişmesiyle birlikte üretim, pazarlama, eğitim, hava tahmini, ulaşım ve sağlık gibi birçok alanda karar destek sistemleri yararlı bir araç haline gelmiştir. Özellikle sağlık sektöründe, MÖ teknolojileri, hastalıkların tespiti ve teşhisine yönelik otomatik karar destek sistemlerinin geliştirilmesine olanak tanımıştır. Bu sistemler, hastalıklarının erken teşhisi ve tedavisi konusunda sağlık profesyonellerine önemli katkılar sağlamaktadır. Günümüzde, bu alandaki gelişmeler hız kesmeden devam etmekte, daha yenilikçi ve etkili yöntemler geliştirilmektedir. Bu derleme çalışmasında, özellikle son beş yıl içinde KVH teşhisi için geliştirilmiş çeşitli MÖ tabanlı karar destek sistemlerine dair bir inceleme sunulmaktadır.

2. KVH Teşhisinde Makine Öğrenme Algoritmaları Temelli Çalışmalar

KVH erken evrede tespiti, hem bireylerin sağlık yönetimi hem de sağlık sistemlerinin etkinliği açısından kritik bir öneme sahiptir. Bu doğrultuda, MÖ temelli karar destek sistemleri, hastalıkların tanısında ve risk değerlendirmesinde önemli bir araç olarak öne çıkmaktadır. KVH tespitinde MÖ algoritmalarının kullanımı, tıp alanında erken teşhis ve tedavi süreçlerinin iyileştirilmesine önemli katkılarda bulunmaktadır. Bu bölümde, 2000-2024 yılları arasında KVH'nın tanı ve prognozunda kullanılan MÖ algoritmalarının literatürdeki gelişimi, uygulanabilirliği ve etkinliği ele alınarak mevcut araştırmalar kapsamlı bir şekilde incelenmiştir.

Rajdhan ve arkadaşları [10], kalp hastalığı olasılığını tahmin etmek ve hastaların risk düzeylerini sınıflandırmak amacıyla Naive Bayes (NB), Karar Ağacı (KA), Lojistik Regresyon (LR) ve Rasgele Orman (RO) gibi çeşitli veri madenciliği tekniklerini kullanarak bir çalışma gerçekleştirmişlerdir. Elde edilen bulgular, RO algoritmasının %90.16 doğruluk oranı ile diğer yöntemlere kıyasla üstün bir performans sergilediğini göstermiştir. Bu sonuç, RO algoritmasının karmaşık veri setlerini işleme ve ayrıntıları gün yüzüne çıkarma konusundaki etkinliğini vurgulamaktadır. Ayrıca, RO algoritmasının yüksek doğruluk oranı, özellikle kardiyovasküler hastalıkların teşhisinde sağlık hizmetleri için güçlü bir araç olarak kullanılabilceğini ortaya koymaktadır. Sivastava ve arkadaşları [11], Cleveland Kalp Hastalığı Veri Kümesi üzerinde hastalığın teşhisi için çeşitli MÖ ve veri madenciliği algoritmalarını içeren yenilikçi bir yöntem önermişlerdir. Çalışmada, K-En Yakın Komşu (KNN), Destek Vektör Makineleri (DVM), KA ve RO algoritmaları kullanılmıştır. KA, %79 doğruluk oranı ile diğer yöntemlere kıyasla daha düşük bir performans sergilemiş, bu durumun aşırı uyum (overfitting) potansiyelinden kaynaklandığı belirtilmiştir. Buna karşın, KNN algoritması %87 doğruluk oranı ile en yüksek başarıyı sağlamıştır. DVM algoritması

ise %83 doğruluk oranı elde etmiş ve özellikle yüksek boyutlu veri kümeleri ile örnek sayısının boyutlardan fazla olduğu durumlarda etkili bulunmuştur. RO algoritması %84 doğruluk oranı ile başarılı sonuçlar vermiştir. Bu çalışma, veri ve tahmin görevine uygun algoritma seçiminde dikkatli olunmasının önemini vurgulamakta ve performans farklılıklarının gelecekteki algoritma optimizasyonları için kıymetli bir referans olabileceğini ifade etmektedir. Alm Mustafa [12] çalışmasında, KVH teşhisinde kullanılan sınıflandırma algoritmalarının yüksek performans gösterdiğini ortaya koymuştur. Ayrıca, veri setindeki tüm özelliklerin analizi yerine azaltılmış bir özellik kümesinin kullanılmasının tahmin doğruluğunu artırabileceği ve aşırı uyum riskini azaltabileceği vurgulanmıştır. Bu bulgular ışığında, sağlık hizmeti sağlayan kuruluşların, MÖ ve veri bilimi alanındaki yeniliklerle uyumlu olarak gerekli verileri toplama ve teşhis süreçlerini optimize etme konusuna odaklanmaları önem arz etmektedir. Shah ve arkadaşları [13], kalp hastalığı ile ilgili özellikleri analiz ederek, çeşitli denetimli MÖ algoritmasının performanslarını analiz etmişlerdir. Daha az sayıda özellik ile doğru tahmin yapmayı hedefleyen çalışmada 76 özellikten 14 temel özellik göz önünde bulundurularak KNN, NB, KA ve RO algoritmalarının performansları karşılaştırılmıştır. Analizler sonucunda, en yüksek doğruluk oranı KNN ($k = 7$) algoritmasında elde edilmiştir. Minou ve arkadaşları [14] 10 yıl içerisinde bireyin kalp rahatsızlığı geçirip geçirmeyeceğini belirlemek amacıyla çeşitli MÖ algoritmalarının performanslarını değerlendirmiştir. Çalışmada bireylerin demografik, davranışsal ve tıbbi risk faktörlerini içeren 14 özellikli açık erişimli bir veri seti kullanılmıştır. Veri setindeki sınıf dengesizliğini gidermek için SMOTE tekniği (Sentetik Azınlık Aşırı Örnekleme Tekniği) ve algoritmaların performanslarını değerlendirmek için çapraz doğrulama yöntemi uygulanmıştır. Algoritmaların performansları hassasiyet, duyarlılık, F1-skor, doğruluk ve AUC metriklerine göre değerlendirilmiştir. Analiz sonuçlarına

göre, en yüksek performansı RO ve KA göstermiştir. Katarya ve Meena [15], UCI veri tabanından elde ettikleri bir veri seti üzerinden kalp hastalığı ve risk faktörlerinin tespitinde 9 farklı MÖ algoritmasının karşılaştırmalı bir analizini gerçekleştirmişlerdir. Çalışmada ayrıca, bir kişinin karşılaşılabileceği farklı kalp hastalığı türleri ve olası belirtileri de ele alınmıştır. Hangi algoritmanın kalp hastalığını daha iyi ve doğru bir şekilde tahmin edebileceğini belirlemek amacıyla yapılan analizlerde, doğruluk ve diğer performans metrikleri açısından RO algoritmasının diğer algoritmalara kıyasla daha iyi sonuçlar verdiği tespit edilmiştir. Bu bulgular, kalp hastalığı riskinin ciddi bir sorun olabileceğini ve çeşitli faktörlerin kalp hastalığı riskini artırabileceğini ortaya koymuştur.

Diwakar ve arkadaşları [16], kalp hastalıklarının teşhisi ve tedavisinde MÖ algoritmaları ve görüntü birleştirme tekniklerinin kullanımını araştırmışlardır. Çalışmada DVM, KA, yapay sinir ağları (YSA) ve topluluk öğrenme algoritmalarının kalp hastalıklarının teşhisinde oldukça başarılı sonuçlar verdiği gösterilmiştir. MÖ algoritmalarına görüntü birleştirilmenin dahil edilmesi, tanısal hassasiyeti artırmada kayda değer bir yenilik olarak öne sürülmüştür. Görüntü birleştirme yöntemleri, ekokardiyogram, manyetik rezonans görüntüleme ve bilgisayarlı tomografi gibi birden fazla tıbbi görüntüden elde edilen verileri birleştirerek kalbin durumuna dair daha kapsamlı bir değerlendirme sunmaktadır. Bu entegrasyon, anomalilerin daha iyi tespit edilmesine olanak tanırken, MÖ algoritmalarının daha doğru sınıflandırma kararları vermesini mümkün kılmaktadır. Garg ve arkadaşları [17] bireylerin kalp hastalığının olup olmadığını tespitinde KNN ve RO olmak üzere iki denetimli MÖ algoritmasının başarımını analiz etmişlerdir. Çalışmada Kaggle veri tabanında yer alan açık erişimli bir veri seti kullanılmış ve analizler sonucunda KNN algoritmasıyla %86.885, RO algoritmasıyla ise %81.967 doğruluk oranları elde edilmiştir. Elde edilen bulgular, MÖ algoritmalarının kalp hastalığını tahmin etmedeki önemini ve etkinliğini ortaya koymakta,

bu algoritmaların günümüzde toplumun önde gelen sağlık sorunlarından biri olan kalp hastalığının teşhisinde kritik bir rol oynadığını göstermektedir. Gao ve arkadaşları [18], KVH tahmin etmede doğruluğu artırmak amacıyla topluluk öğrenme tekniklerinin kullanımını araştırmış ve MÖ algoritmalarının sağlık hizmetlerindeki önemini vurgulamışlardır. Doğrusal ayırıştırma analizine (LDA) ve temel bileşen analizine (TBA) göre belirlenen özellikler kullanılarak, geleneksel MÖ algoritmaları ile topluluk öğrenme algoritmalarının başarımları karşılaştırılmıştır. Yapılan analizler sonucunda temel öğrenici olarak KA kullanan bagging (torbalama) algoritmasının en yüksek başarıma sahip olduğu tespit edilmiştir. Topluluk öğrenme algoritmalarının verilerdeki karmaşık örüntüleri yönetme yeteneğini vurgulayan bu çalışma, kardiyolojide MÖ uygulamaları konusundaki anlayışı önemli ölçüde geliştirmekte ve yapay zeka (YZ) ile tanısal prosedürlerin iyileştirilmesini hedefleyen gelecekteki araştırmalar için yeni bir standart oluşturmaktadır. Sapro ve arkadaşları [19] kalp hastalıklarını düşük maliyetli, tekrarlanabilir, non-invaziv, hızlı ve kesin bir şekilde teşhis edebilmek amacıyla altı farklı MÖ algoritmasının performansını iki farklı veri seti kullanarak analiz etmişlerdir. Analiz sonuçları, gradyan artırıcı KA algoritmasının %84 doğruluk oranı ile diğer algoritmalara kıyasla en iyi başarıma sahip olduğunu göstermiştir. Ali ve arkadaşları [20], kalp hastalığını erken evrede teşhis etmek amacıyla açık erişimli bir veri seti üzerinden altı farklı MÖ algoritmasının performansını karşılaştırmıştır. Çalışmada, eksik veriler tamamlandıktan sonra aykırı ve uç değerler tespit edilmiş olup, bu değerleri ortadan kaldırmak için veri seti üç bölüme ayrılmıştır. Ön işleme adımlarının ardından, çok katmanlı algılayıcı (ÇKA), KNN, RO, KA, LR ve AdaboostM1 (ABM1) algoritmalarının doğrulukları karşılaştırılmıştır. Analizler sonucunda, KNN, KA ve RO algoritmalarının yüksek doğruluk oranları sağladığı belirlenmiştir. Bu bulgular, basit bir denetimli MÖ algoritmasının yüksek doğrulukla kalp hastalığı tahmini yapabileceğini göstermektedir. Bharti ve

arkadaşları [21], UCI veri tabanında yer alan KVH veri setini kullanarak geleneksel MÖ yöntemleri ile derin öğrenme (DÖ) algoritmalarının performanslarını karşılaştırmıştır. Çalışmada, veri setindeki 14 temel özellikten anlamsız olanlar ayıklanmış ve veriler normalize edilmiştir. Analiz sonuçlarına göre, LR, KNN, DVM, RO, KA ve DÖ algoritmaları sırasıyla %83.3, %84.8, %83.2, %80.3, %82.3 ve %94.2 doğruluk oranlarına ulaşmıştır. Elde edilen sonuçlar, DÖ algoritmasının en yüksek performansı sergilediğini ortaya koymaktadır. Ayrıca çalışmada, elde edilen bulguların mobil cihazlar gibi multimedya teknolojileri ile entegrasyonuna yönelik potansiyel uygulamalara da değinilmiştir. Jindal ve arkadaşları [22], kalp hastalığı olan hastaları tahmin etmek ve sınıflandırmak için LR, RO ve KNN algoritmalarını kullanmıştır. Çalışmada, hastaların göğüs ağrısı, şeker seviyesi, kan basıncı gibi tıbbi geçmişlerini içeren bir veri setinden ölümcül kalp hastalığına yol açan tıbbi geçmişi çıkarılarak kardiyovasküler hastalıkları tahmin eden bir model geliştirilmiştir. Çalışmanın sonucunda, kullanılan üç algoritma arasında en yüksek doğruluğun %88.52 ile KNN'de olduğu tespit edilmiştir.

Adhikari ve arkadaşları [23], kalp hastalığı riskini tahmininde farklı MÖ algoritmalarının performanslarını değerlendirmiştir. UCI veri tabanındaki yaygın olarak kullanılan kalp hastalığı veri seti üzerinde yapılan çalışmada, LR, DVM, KA, KNN ve NB algoritmalarının başarımları karşılaştırılmıştır. Analizlerde en yüksek doğruluk oranı %97.67 ile KA algoritması sağlanmıştır. Bu bulgu, klinik uygulamalarda sağlam ve yorumlanabilir modellerin etkili tanı ve hasta yönetimi için ne kadar önemli olduğunu ortaya koymuştur. Ayrıca, bazı durumlarda daha basit ve yorumlanabilir modellerin karmaşık modellerden üstün performans gösterebileceğini, bu durumun veri seti ve görev gereksinimlerine bağlı olarak değişebileceğini ileri sürmüşlerdir. Sekhar ve arkadaşları [24], kalp hastalığını erken evrede teşhisi için dört farklı MÖ (KNN, DVM, KA

ve RO) algoritmasının başarımını irdelenmişlerdir. Elde edilen bulgulara göre en iyi performansı %96 ile KNN algoritması vermiştir. Çalışmada ayrıca kalp hastalığına bağlı ölüm oranlarının azaltılmak amacıyla bir WEB uygulaması geliştirilmiştir. Chang ve arkadaşları [25], kalp hastalıklarının yüksek doğrulukla tespit edebilen MÖ temelli bir karar destek sistemi geliştirmişlerdir. Çalışmada, açık erişimli bir veri seti kullanılarak dört farklı MÖ algoritmasının başarımları karşılaştırılmıştır. Yapılan analizler sonucunda, RO sınıflandırması %83 doğruluk oranı ile en yüksek performansı göstermiştir. Bu bulgu, RO sınıflandırmasının veri okuma doğruluğu açısından en iyi sonuçları verdiğini ve algoritmaların parametrelerinin belirlenmesinde üstünlük sağladığını ortaya koymaktadır. Çil ve Güneş [26] MÖ algoritmalarının KVH tespitindeki performanslarını detaylı bir şekilde incelemişlerdir. Çalışmada, açık erişimli bir veri seti üzerinde altı farklı MÖ algoritması (LR, KA, RO, YSA, KNN ve DVM) kullanılarak performans analizi yapılmıştır. Performans analizleri; doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metrikler üzerinden gerçekleştirilmiştir. Veri toplama sürecinde anket yöntemi kullanılmış olduğundan, veriler ilk olarak ön işleme tabi tutulmuştur. Ardından, LR temelli bir özellik seçimi yöntemi kullanılarak algoritmaların performansları karşılaştırılmıştır. Elde edilen sonuçlar, YSA, LR ve DVM algoritmalarının %91 başarı oranı ile en yüksek performansı gösterdiğini ortaya koymuştur. Doppala ve arkadaşları [27], KVH yüksek doğrulukla teşhis edebilen NB, RO, DVM ve XGBoost algoritmalarını bir araya getiren güvenilir bir topluluk öğrenme modeli önermiştir. Önerilen model, çeşitli veri kaynaklarından elde edilen üç farklı veri seti üzerinde test edilmiştir. Mendeley Veri Merkezi'nden alınan veri seti üzerinde %96.75, IEEE DataPort'tan toplanan veri seti üzerinde %93.39 ve Cleveland veri seti üzerinde %88.24 doğruluk oranları elde edilmiştir. Bu sonuçlar, modelin yüksek doğruluk oranlarına ulaşabildiğini ve kardiyovasküler hastalıkların erken teşhisinde etkili bir araç

olduğunu göstermiştir. Model, bireylerin sağlık güvenliğini sağlamada önemli bir rol oynayarak hastalıkların erken aşamada tespit edilmesini ve gerekli önlemlerin alınmasını mümkün kılmaktadır. Nagavelli ve arkadaşları [28], kalp hastalığının tespitinde çeşitli MÖ algoritmalarının etkinliğini analiz etmişlerdir. Bu amaç doğrultusunda NB, DVM ve XGBoost algoritmalarının performansları karşılaştırılmıştır. Yapılan analizlerde XGBoost %95.9 doğruluk oranı ile en iyi performansı göstermiştir. Archana ve arkadaşları [29], Cleveland veri setini kullanarak kalp hastalığını belirlemede MÖ algoritmalarının performanslarını analiz etmişlerdir. Çalışmada, NB, RO ve bu iki algoritmanın kombinasyonundan oluşan hibrit bir model geliştirilmiştir. Bu modelin performansını değerlendirmek için yaş, cinsiyet, hızlı kan şekeri ve göğüs rahatsızlığı gibi 14 farklı parametre kullanılmıştır. Önerilen hibrit model, %92 doğruluk oranı ile en yüksek performansı sağlamıştır. Bu sonuçlar, hibrit modelin kalp hastalığı tahmininde etkili bir araç olduğunu göstermektedir. Harman [30] kalp hastalığı verileri üzerinde YSA, KNN, KA, NB, LR ve DVM algoritmalarını kullanarak sınıflandırma analizleri gerçekleştirmiştir. YSA, DVM ve NB algoritmalarının kalp hastalığı tespitinde en yüksek performansı gösterdiği, buna karşın KNN algoritmasının önceki çalışmalarda olduğu gibi yeterli başarıyı sağlayamadığı tespit edilmiştir. KNN algoritmasının mevcut veri seti ve öznitelik dağılımına uygun olmadığı sonucuna varılmıştır. MÖ algoritmalarının kalp hastalığının erken teşhisinde ve verimlilik kazancında önemli avantajlar sunduğu vurgulanmış olup, gelecekteki çalışmalarda egzersiz düzeyi, sigara kullanımı, beslenme alışkanlıkları gibi ek özniteliklerin dahil edilmesinin daha yüksek verim ve etkili faktörlerin belirlenmesi açısından faydalı olacağı belirtilmiştir.

Yadav ve arkadaşları [31], kalp hastalıklarını tahmin etmek amacıyla MÖ algoritmalarına dayalı bir arayüz geliştirmişlerdir. Geliştirdikleri arayüzde RO ve KA algoritmalarıyla %97.08, LR algoritması ile %80.52

başarım elde etmişlerdir. Kumar ve arkadaşları [32] KVH risk faktörlerinin tahmininde MÖ algoritmalarının kullanılmanın etkinliğini incelemişlerdir. Çalışmada tüm MÖ sınıflandırma algoritmaları için doğruluk, kesinlik, duyarlılık ve F1 skoru gibi çeşitli performans metrikleri değerlendirilmiştir. Veri setinde yer alan on dört özellik kullanılması durumunda, KNN algoritması en iyi performansı göstermiştir. Çalışmada MÖ algoritmalarının, istatistiksel yöntemlerden çok daha iyi performans gösterdiği ortaya koyulmuştur. Ayrıca elde edilen sonuçlarla, küçük bir veri tabanı ile bile MÖ modellerinin kalp hastalığını tahmin etme ve sınıflandırmada en etkili yöntem olduğunu gösteren birçok çalışmanın bulgularını desteklemiştir. Bhatt ve arkadaşları [33] KVH kaynaklı ölümleri azaltmak için bu hastalığı erken evrede öngörebilen MÖ temelli bir model geliştirmişlerdir. Bunun için RO, XGB, ÇKA ve KA gibi MÖ algoritmalarını kullanmışlardır. Ayrıca veri temizleme, özellik seçimi ve kümeleme gibi veri düzenleme işlemleri de gerçekleştirmişlerdir. Yapılan analizlere göre en yüksek başarımlar %87.23 ile ÇKA algoritmasında elde edilmiştir. Chandrasekhar ve Peddakrishna [34] KVH tespitinde etkili bir MÖ tabanlı tanı sistemi geliştirmişlerdir. Çalışmada, GridSearchCV ve beş katlı çapraz doğrulama yöntemleri ile hiperparametre optimizasyonu yapılarak altı MÖ sınıflandırıcısının (RO, KNN, LR, NB, GA ve AdaBoost) performansları iki farklı veri seti üzerinden karşılaştırılmıştır. Elde edilen sonuçlara göre her iki veri seti için de en yüksek performans %90.16 ve %89.67 doğruluk oranları ile LR ve AdaBoost sınıflandırıcılarında elde edilmiştir. Bununla birlikte algoritmalara yumuşak oylama (soft voting) topluluk sınıflandırıcısı uygulanması durumunda doğruluk oranları sırasıyla %93.44 ve %95'e yükselmiştir. Böylelikle yumuşak oylama topluluk sınıflandırıcısı yaklaşımının KVH teşhisinde başarımlarını önemli ölçüde artırdığı ortaya koyulmuştur. Sen ve Verma [35], kalp hastalığının tespitinde geleneksel MÖ modellerinin düşük doğruluk, kesinlik ve duyarlılık

sorununu gidermek amacıyla yumuşak oylama tekniğine dayanan bir meta sınıflandırıcı modeli önermişlerdir. Bu amaçla, kalp hastalığını tahmin etmedeki performansları göz önünde bulundurularak beş farklı geleneksel MÖ algoritması seçilmiştir. Açık erişimli iki veri seti birleştirilerek yapılan analizlerde, önerilen modelin geleneksel MÖ dayalı modellere kıyasla daha üstün performans sergilediği tespit edilmiştir. Ramesh ve Pathinarupothi [36] bireylerin yaşamsal parametreleri, demografik verileri ve egzersiz parametrelerini içeren açık erişimli bir veri seti kullanarak KVH teşhisinde en uygun denetimli MÖ algoritmasını belirlemek için kapsamlı bir analiz yapmışlardır. Bu amaçla dokuz farklı MÖ algoritmasının performansı doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metrikler üzerinden karşılaştırılmıştır. Analizler sonucunda, RO ve gradyan arttırma (GA) algoritmalarının kalp hastalıklarını tahmin etmede diğer modellere kıyasla daha yüksek verimliliğe sahip olduğunu tespit edilmiştir. Bu bulgular, doktorların KVH erken teşhisi için bu algoritmalarından yararlanabileceğini göstermektedir. Shukla ve arkadaşları [37], hastaların klinik özelliklerini kullanarak kalp hastalığının teşhisinde yardımcı olabilecek MÖ tabanlı bir karar destek sistemi önerilmiştir. Önerilen sistemde, eksik verilerle başa çıkmak için MICE yaklaşımı kullanılmış olup, özellik seçimi için hibrit GARFE algoritması kullanılmıştır. Ayrıca, verilerin ön işlenmesi için SMOTE ve standart ölçekleme teknikleri kullanılmıştır. Ardından sisteme DVM, NB, LR, RO ve AdaBoost gibi çeşitli sınıflandırıcıların uygulanmıştır. Yapılan analizlerde %86.60 doğruluk oranı ile en iyi performans RO algoritması tarafından elde edilmiştir. Böylelikle, MÖ temelli klinik karar destek sistemlerinin kardiyak hastalıkların erken teşhisinde önemli bir rol oynayabileceğini ortaya koyulmuştur. Naveen ve arkadaşları [38], KVH riskini tahmin etmek amacıyla LR ve RO algoritmalarının performanslarını değerlendirmiştir. En iyi doğruluğu elde etmek ve uygulamanın parametrelerini anlamak için model beş farklı bölme koşulunda eğitilmiş ve

ardından bir eğitim veri seti ile test edilmiştir. Analizlerde, LR algoritması için %85.25 ve RO algoritması için %90.16 kesinlik değerleri elde edilmiştir. Elde edilen bulgular, hastaların sağlık parametrelerini değerlendirerek KVH riskini tahmin etmek için etkili yöntemler sunduğunu göstermektedir. Çalışma, veri madenciliği yöntemlerinin KVH risk faktörlerini belirlemedeki önemini vurgulamakta ve sağlık kayıtları kullanılarak kalp hastalıklarının değerlendirilmesinin gerekliliğini ortaya koymaktadır. Gangadhar ve arkadaşları [39] çeşitli MÖ algoritmaları kullanarak bireylerin kalp rahatsızlığının olup olmadığını belirlemeye yönelik bir çalışma gerçekleştirmişlerdir. Açık erişimli veri seti üzerinde YSA, DVM, RO, KA ve KNN algoritmalarının performansları değerlendirilmiştir. Analizlerde YSA %84.44 doğruluk oranı ile en yüksek performansı göstermiştir. Diğer modellerin doğruluk oranları ise DVM için %83.33, RO için %81.67, KA için %73.33 ve KNN için %61.67 elde edilmiştir. Bu bulgular, YSA algoritmasının kalp hastalığı tahmininde diğer MÖ algoritmalarına kıyasla üstün olduğunu ortaya koymaktadır. Takcı [40] kalp hastalığı teşhisinde KNN algoritmasının doğruluğunu artırmak için iki farklı veri seti üzerinden optimizasyon yöntemlerinin etkinliğini araştırmıştır. Çalışmada, komşu sayısı, uzaklık yöntemi ve ağırlıklandırma parametreleri üzerinde odaklanılmış ve en yüksek doğruluğu sağlayan parametreler ızgara arama yöntemi ile belirlenmiştir. Optimizasyon öncesinde Statlog veri kümesinde %67.90 ve Cleveland veri kümesinde %71.42 doğruluk elde edilmiştir. Ancak, genetik algoritmalar kullanılarak yapılan optimizasyonda, bu doğruluk oranları sırasıyla %88,88 ve %90,11'e yükseltilmiştir. Bu bulgular, KNN algoritmasının doğru parametreler ve optimizasyon teknikleri ile yüksek doğruluk sağlayabileceğini, genetik algoritmaların performansı artırmada özellikle etkili olduğunu göstermiştir. Asif ve arkadaşları [41] kalp hastalığını tahmin etmek için çeşitli ön işleme adımları, hiperparametre optimizasyon teknikleri ve topluluk öğrenme algoritmaları

kullanan bir MÖ temelli bir model geliştirmişlerdir. Modelin performansını değerlendirmek amacıyla, benzer özelliklere sahip üç Kaggle veri seti birleştirilerek kapsamlı bir veri seti oluşturulmuştur. Ekstra ağaç sınıflandırıcı kullanılarak, veriler normalleştirilmiş ve hiperparametre optimizasyonu için ızgara arama çapraz doğrulama uygulanmıştır. Veri seti, eğitim ve test amaçları için 80:20 oranında ayrılmıştır. %98.15 doğruluk oranı elde edilen model, kalp hastalığının varlığını veya yokluğunu doğru bir şekilde tahmin etme potansiyeline sahip olduğu ortaya koyulmuştur.

Saha ve arkadaşları [42] KVH teşhisi için sağlık sektöründe temel model olarak kullanılabilecek MÖ temelli bir karar destek sistemi önermişlerdir. Bu amaçla, farklı özelliklere dayalı olarak veri seti ön işlemlerden geçirilmiştir. Ardından, beş farklı MÖ algoritmasının (LR, RO, KNN, KA, and XGB) başarımı farklı performans ölçütlerine göre karşılaştırılmıştır. Yapılan analizler sonucunda, en yüksek performansın Rasgele Orman (RO) algoritmasıyla elde edildiği tespit edilmiştir. Ogunpola ve arkadaşları [43], kalp hastalıklarının erken evrede teşhis edebilmek amacıyla MÖ temelli bir model önermişlerdir. Çalışmada dengesiz veri setleri sorununu ele almak amacıyla kapsamlı bir literatür taraması yapılarak etkili stratejiler belirlenmiştir. Modelin performansını değerlendirmek üzere KNN, DVM, LR, GA, XGBoost, RO ve evrimsel sinir ağı (ESA) algoritmalarının performansları kıyaslanmıştır. Sonuçlar, kardiyovasküler hastalıklar için XGBoost modelinin titizlikle ince ayar yapılmasının etkinliğini vurgulamaktadır. Talapeni ve arkadaşları [44], kalp hastalığı tahmininde doğruluğu artırmak amacıyla voting ensemble tekniğini kullanarak yeni bir model önermektedir. LR, KA ve RO algoritmalarının entegrasyonu ile oluşturulan model, doğruluk ve performans açısından ümit verici sonuçlar elde etmiştir. Gerçek bir kalp hastalığı veri seti üzerinde yapılan deneysel analizler, modelin %98 doğruluk oranına ulaştığını ve bireysel sınıflandırıcılardan daha iyi performans gösterdiğini ortaya koymuştur. Bu bulgular, tanı doğruluğunu

artırmada ensemble tekniklerinin önemini vurgulamakta ve sağlık analitiği alanında gelecekteki araştırmalara katkı sağlamaktadır. Sungur ve Bakır [45] KVH tahmininde çeşitli MÖ algoritmalarının performansını artırmak amacıyla uygulanan veri düzenleme ve hiperparametre optimizasyonu tekniklerini karşılaştırmışlardır. Çalışmanın temel hedefi, mevcut veri seti kullanılarak en etkili tahmin algoritmasını belirlemektir. İkinci hedef ise, veri dengeleme ve hiperparametre optimizasyonunun MÖ algoritmalarının performansına olan etkisini incelemektir. Veri seti temizlendikten sonra, dört farklı veri dengeleme tekniği (SMOTE, SMOTETomek, Oversample Minority Class, Undersample Majority Class) ile oluşturulan veri setlerine tahmin algoritmaları uygulanmış, ardından en iyi hiperparametrelerin belirlenmesi amacıyla optimizasyon yapılmıştır. RO algoritması, SMOTETomek veri dengeleme tekniği ve Bayesian hiperparametre optimizasyonu kullanılarak %94 tahmin başarısı elde edilirken, aynı algoritma ve Oversample Minority Class veri dengeleme tekniği ile %97 sınıflandırma doğruluğu sağlanmıştır. Elde edilen bulgulara dayanarak, MÖ algoritmalarının KVH tahmininde etkili bir şekilde kullanılabilmesi ve çeşitli iyileştirme yöntemleriyle performansın artırılabilmesi ortaya koyulmuştur. Bhuvana ve arkadaşları [46] kalp hastalıklarının erken tanısı ve tahmininde çeşitli MÖ algoritmalarının etkinliğini incelemiştir. Çalışmada KA, DVM ve SA gibi algoritmalar kullanılarak yüksek doğrulukla risk altındaki bireylerin tespit edilmesi amaçlanmıştır. Veri toplama, ön işleme ve model doğrulama süreçlerinde karşılaşılan zorluklar ele alınmış ve bu alanda daha fazla araştırma ihtiyacı vurgulanmıştır. Farklı algoritmaların titiz bir değerlendirmesi ve karşılaştırması yoluyla, en verimli tahmin yöntemlerini belirlenmiştir. Nadheer [47] kalp hastalığı tahmininde RRelief tabanlı özellik değerlendirmesi ve ÇKA tabanlı sınıflandırma ile XGBoost topluluk (ensemble) sınıflandırmasının entegrasyonunun etkinliği incelenmiştir. Cleveland veri seti üzerinde yapılan testlerde, önerilen modelle %96.67 doğruluk, %95.92 duyarlılık ve

%97.92 kesinlik oranları elde edilmiştir. Ayrıca, %96.91 F1-Skoru ile dengeli bir performans sergilemiştir. Bu bulgular, entegre edilen veri işleme ve sınıflandırma tekniklerinin kalp hastalıklarının tahmininde yüksek doğruluk ve dengeli performans sağladığını göstermektedir.

4. Sonuç ve Tartışma

Kalp hastalıklarının erken evrede teşhis edilebilmesi, hastaların yaşam kalitesini artırmak ve tedavi maliyetlerini azaltmak açısından büyük önem taşımaktadır. Bu bağlamda, MÖ tabanlı karar destek sistemleri, klinik verilerin analiz edilerek hastalıkların erken evrede tespit edilmesi için güçlü araçlar sunmaktadır. Bu derleme çalışmasında, MÖ tabanlı karar destek sistemlerinin kalp hastalıklarının erken teşhisindeki potansiyeli ve bu alandaki mevcut yaklaşımlar kapsamlı bir şekilde incelenmiştir. İncelenen literatür, son beş yılda geliştirilen MÖ tabanlı sistemlerin kardiyovasküler hastalıkların erken teşhisinde yüksek başarı oranlarına ulaştığını ortaya koymaktadır. Çeşitli MÖ algoritmalarının, özellikle RO, DVM ve KNN algortimalarının, kalp hastalıklarının teşhisinde önemli avantajlar sunduğu görülmüştür.

MÖ algoritmalarının kullanımının yaygınlaşmasının önündeki en büyük engellerden biri, bu algoritmaların sonuçlarının tıbbi uzmanlar tarafından anlaşılabilir ve açıklanabilir olmamasıdır. Bu durum, klinik uygulamalarda MÖ tabanlı sistemlerin benimsenmesini sınırlamaktadır. Literatürdeki çalışmalar, MÖ algoritmalarının performansının artırılması kadar, bu modellerin açıklanabilirliğinin de geliştirilmesi gerektiğini vurgulamaktadır. Ayrıca, veri kalitesi ve çeşitliliği MÖ algoritmalarının performansını etkileyen kritik faktörler arasındadır. Çeşitli hasta gruplarından ve farklı coğrafi bölgelerden elde edilen verilerle eğitilen modeller, daha genel ve güvenilir sonuçlar üretebilir. Sınıf dengesizliği gibi sorunların üstesinden gelmek için SMOTE gibi veri dengeleme tekniklerinin kullanılması önerilmektedir.

Sonuç olarak, MÖ tabanlı sistemler, kalp hastalıklarının erken teşhisi ve yönetiminde önemli bir potansiyele sahiptir. Literatürdeki bulgular, bu teknolojilerin klinik uygulamalarda etkin bir şekilde kullanılabileceğini ortaya koymaktadır. Ancak, bu sistemlerin klinik uygulamalarda daha geniş bir kabul görmesi için, model açıklanabilirliği, veri kalitesi ve entegrasyon süreçlerine yoğunlaşılması gerekmektedir. Bu çalışma, kalp hastalığı teşhisinde MÖ uygulamalarının mevcut durumunu ve gelecekteki araştırma yönelimlerini özetleyerek, bu alandaki bilgi birikimine katkıda bulunmaktadır.

Kaynaklar

1. Yapıcı, İ. Ş., Arslan, R. U., & Erkaymaz, O. (2024). Kalp Yetmezliği Tanılı Hastaların Hayatta Kalma Tahmininde Topluluk Makine Öğrenme Yöntemlerinin Performans Analizi. *Karaelmas Fen ve Mühendislik Dergisi*, 14(1), 59-69.
2. Subhadra, K., & Vikas, B. (2019). Neural network based intelligent system for predicting heart disease. *International Journal of Innovative Technology and Exploring Engineering*, 8(5), 484-487.
3. Fact Sheet: Cardiovascular Diseases. Available online: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (accessed on 23 July 2024).
4. Ahmed, M., & Husien, I. (2024). Heart Disease Prediction Using Hybrid Machine Learning: A Brief Review. *Journal of Robotics and Control (JRC)*, 5(3), 884-892.
5. Ayano, Y. M., Schwenker, F., Dufera, B. D., & Debelee, T. G. (2022). Interpretable machine learning techniques in ECG-based heart disease classification: a systematic review. *Diagnostics*, 13(1), 111.
6. Morris, F., Brady, W. J., & Camm, A. J. (Eds.). (2009). *ABC of clinical electrocardiography*. John Wiley & Sons.
7. Higuera, J., Gómez-Talkavera, S., Ganadas, V., Bover, R., Losas, M., Gómez-Polo, J. C., ... & Macaya, C. (2016). Expertise in interpretation of 12-lead electrocardiograms of staff and residents physician: current knowledge and comparison between two different teaching methods. *J Caridol Curr Res*, 5(3), 00160.
8. Schläpfer, J., & Wellens, H. J. (2017). Computer-interpreted electrocardiograms: benefits and limitations. *Journal of the American College of Cardiology*, 70(9), 1183-1192.
9. Martínez-Losas, P., Higuera, J., Gómez-Polo, J. C., Brabyn, P., Ferrer, J. M. F., Cañadas, V., & Villacastín, J. P. (2016). The influence of computerized interpretation of an electrocardiogram reading. *The American Journal of Emergency Medicine*, 10(34), 2031-2032.
10. Rajdhan, A., Agarwal, A., Sai, M., Ravi, D., & Ghuli, P. (2020). Heart disease prediction using machine learning. *International Journal of Engineering Research & Technology*, 9(4), 659-662.
11. Srivastava, K., & Choubey, D. K. (2020). Heart disease prediction using machine learning and data mining. *International Journal of Recent Technology and Engineering*, 9(1): 212-219.
12. Almustafa, K. M. (2020). Prediction of heart disease and classifiers' sensitivity analysis. *BMC bioinformatics*, 21, 1-18.
13. Shah, D., Patel, S., & Bharti, S. K. (2020). Heart disease prediction using machine learning techniques. *SN Computer Science*, 1(6), 345.
14. Minou, J., Mantas, J., Malamateniou, F., & Kaitelidou, D. (2020). Classification techniques for cardio-vascular diseases using supervised machine learning. *Medical Archives*, 74(1), 39.
15. Katarya, R., & Meena, S. K. (2021). Machine learning techniques for heart disease prediction: a comparative study and analysis. *Health and Technology*, 11(1), 87-97.

16. Diwakar, M., Tripathi, A., Joshi, K., Memoria, M., & Singh, P. (2021). Latest trends on heart disease prediction using machine learning and image fusion. *Materials today: proceedings*, 37, 3213-3218.
17. Garg, A., Sharma, B., & Khan, R. (2021). Heart disease prediction using machine learning techniques. In *IOP Conference series: materials science and engineering*, 1022(1), 012046.
18. Gao, X. Y., Amin Ali, A., Shaban Hassan, H., & Anwar, E. M. (2021). Improving the accuracy for analyzing heart diseases prediction based on the ensemble method. *Complexity*, 2021(1), 6663455.
19. Sapra, L., Sandhu, J. K., & Goyal, N. (2021). Intelligent method for detection of coronary artery disease with ensemble approach. In *Advances in Communication and Computational Technology: Select Proceedings of ICACCT 2019* (pp. 1033-1042). Springer Singapore.
20. Ali, M. M., Paul, B. K., Ahmed, K., Bui, F. M., Quinn, J. M., & Moni, M. A. (2021). Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison. *Computers in Biology and Medicine*, 136, 104672.
21. Bharti, R., Khamparia, A., Shabaz, M., Dhiman, G., Pande, S., & Singh, P. (2021). Prediction of heart disease using a combination of machine learning and deep learning. *Computational intelligence and neuroscience*, 2021(1), 8387680.
22. Jindal, H., Agrawal, S., Khera, R., Jain, R., & Nagrath, P. (2021). Heart disease prediction using machine learning algorithms. In *IOP conference series: materials science and engineering*, 1022(1), p. 012072.
23. Adhikari, B., & Shakya, S. (2022, February). Heart Disease Prediction Using Ensemble Model. In *Proceedings of Second International Conference on Sustainable Expert Systems: ICSES 2021* (pp. 857-868). Singapore: Springer Nature Singapore.
24. Ambika Sekhar, Amrutha Babu, Jayalekshmi V.K., and Adithya Udayan. (2022). Machine learning based heart disease prediction. In *2022 Second International Conference on Next Generation Intelligent Systems (ICNGIS)* (pp 1–5).
25. Chang, V., Bhavani, V. R., Xu, A. Q., & Hossain, M. A. (2022). An artificial intelligence model for heart disease detection using machine learning algorithms. *Healthcare Analytics*, 2, 100016.
26. Çil, E., & Güneş, A. (2022). Makine öğrenmesi algoritmalarıyla kalp hastalıklarının tespit edilmesine yönelik performans analizi. *Anadolu Bil Meslek Yüksekokulu Dergisi*, 17(65), 57-77.
27. Doppala, B. P., Bhattacharyya, D., Janarthanan, M., & Baik, N. (2022). A reliable machine intelligence model for accurate identification of cardiovascular diseases using ensemble techniques. *Journal of Healthcare Engineering*, 2022(1), 2585235.
28. Nagavelli, U., Samanta, D., & Chakraborty, P. (2022). Machine Learning Technology-Based Heart Disease Detection Models. *Journal of Healthcare Engineering*, 2022(1), 7351061.

29. Archana, K. S., Sivakumar, B., Kuppusamy, R., Teekaraman, Y., & Radhakrishnan, A. (2022). Automated cardioailment identification and prevention by hybrid machine learning models. *Computational and Mathematical Methods in Medicine*, 2022(1), 9797844.
30. Harman, G. (2022). Kalp hastalığı tespitinde sınıflandırma yöntemlerinin karşılaştırılması. *Teknolojik Gelişmeler ve Mühendislik Uygulamaları*. (ss. 6-27). Güven Plus Grup A.Ş. Yayınları.
31. Yadav, A. L., Soni, K., & Khare, S. (2023, July). Heart diseases prediction using machine learning. In *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-7). IEEE.
32. Kumar, B., Gulnar, S., Banerjee, P., & Dehury, M. K. (2023, December). A study of Cardiovascular disease Risk factors using ML techniques. In *2023 Global Conference on Information Technologies and Communications (GCITC)* (pp. 1-7). IEEE.
33. Bhatt, C. M., Patel, P., Ghetia, T., & Mazzeo, P. L. (2023). Effective heart disease prediction using machine learning techniques. *Algorithms*, 16(2), 88.
34. Chandrasekhar, N., & Peddakrishna, S. (2023). Enhancing heart disease prediction accuracy through machine learning techniques and optimization. *Processes*, 11(4), 1210.
35. Sen, K., & Verma, B. (2023, May). Heart Disease Prediction Using a Soft Voting Ensemble of Gradient Boosting Models, RandomForest, and Gaussian Naive Bayes. In *2023 4th International Conference for Emerging Technology (INCET)* (pp. 1-7). IEEE.
36. Ramesh, H. V., & Pathinarupothi, R. K. (2023, April). Performance Analysis of Machine Learning Algorithms to Predict Cardiovascular Disease. In *2023 IEEE 8th International Conference for Convergence in Technology (I2CT)* (pp. 1-8). IEEE.
37. Shukla, A., Khan, I. R., Sharma, V., Soni, M., Gupta, S., & Kumar, A. (2023, April). A Novel Prediction System to Diagnose Heart Disease. In *2023 International Conference on Inventive Computation Technologies (ICICT)* (pp. 781-786). IEEE.
38. Naveen, S., Ravindran, S. K., Shreya, G., & Ameen, S. N. (2023, May). Effective Heart disease prediction framework using Random Forest and Logistic regression. In *2023 2nd International Conference on Vision Towards Emerging Trends in Communication and Networking Technologies (ViTECoN)* (pp. 1-6). IEEE.
39. Gangadhar, M. S., Sai, K. V. S., Kumar, S. H. S., Kumar, K. A., Kavitha, M., & Aravinth, S. S. (2023, February). Machine learning and deep learning techniques on accurate risk prediction of coronary heart disease. In *2023 7th International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 227-232). IEEE.
40. Takcı, H. (2023). Optimum parametreler yardımıyla performansı artırılmış KNN algoritması tabanlı kalp hastalığı tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(1), 451-460.

41. Asif, D., Bibi, M., Arif, M. S., & Mukheimer, A. (2023). Enhancing heart disease prediction through ensemble learning techniques with hyperparameter optimization. *Algorithms*, 16(6), 308.
42. Saha, S., Rahman, M. M., Suki, T. T., Alam, M. M., Alam, M. S., & Haque, M. A. S. (2024, April). Heart Disease Prediction Using Machine Learning Algorithms: Performance Analysis. In *2024 3rd International Conference on Advancence in Electrical and Electronic Engineering (ICAEEE)* (pp. 1-6). IEEE.
43. Ogunpola, A., Saeed, F., Basurra, S., Albarrak, A. M., & Qasem, S. N. (2024). Machine learning-based predictive models for detection of cardiovascular diseases. *Diagnostics*, 14(2), 144.
44. Talapaneni, S., Kota, C. S., Yalagala, N., Nunna, R., & Mothukuri, R. (2024, May). Enhancing Heart Disease Prediction and Analysis: An Efficient Voting Ensemble model. In *2024 International Conference on Communication, Computer Sciences and Engineering (IC3SE)* (pp. 156-160). IEEE.
45. Sungur, F., & Bakır, H. (2024). Hiperparametre ayarlama ve veri dengelemenin kalp hastalığı tahmini için kullanılan makine öğrenimi algoritmaları üzerindeki etkilerinin incelenmesi. *Bilişim Teknolojileri Dergisi*, 17(1), 45-58.
46. Bhuvana, P. P. M. R. S., Rohith, B., Swathi, B. M., Nikhitha, G., Vege, H. K., & Subramanyam, M. M. (2024). Prediction Of Cardiovascular Disorders Using Machine Learning. *Educational Administration: Theory and Practice*, 30(6), 1206-1215.
47. Nadheer, I. (2024). Heart Disease Prediction System using hybrid model of Multi-layer perception and XGBoost algorithms. In *BIO Web of Conferences* (Vol. 97, p. 00047). EDP Sciences.

YOLO SERİLERİ İLE GÖRÜNTÜ SEGMENTASYONU: TEMELLER, YÖNTEMLER VE UYGULAMALAR

Mehmet Ali Şimşek¹, Ahmet Sertbaş², Hadi Sasani³

Özet

Görüntü işleme; tıbbi görüntüleme, endüstriyel denetim, savunma ve sanat gibi birçok alanda büyük bir önem taşımakta ve bu alanlarda dijital görüntülerin kalitesini artırma veya bu görüntülerden yararlı bilgiler elde etme amacıyla yapılmaktadır. Görüntü segmentasyonu, dijital görüntüleri anlamlı bölgelere ayırarak analizini kolaylaştıran bir yöntemlerdir. Derin öğrenme tabanlı segmentasyon, son yıllarda büyük bir gelişim göstermiştir ve bu yöntemler, özellikle Convolutional Neural Networks (CNN- Evrişimli Sinir Ağları) gibi mimariler kullanarak tıbbi görüntüleme ve otonom sürüş gibi alanlarda yüksek doğruluk ve verimlilik sağlar. Ancak bu yaklaşımlar yüksek kalitede açıklanmalı veri kümeleri gerektirir ve aşırı uyum gibi sorunlarla karşılaşabilir. YOLO (You Only Look Once) serisi gibi derin öğrenme tabanlı algoritmalar, nesne tespiti ve segmentasyonu bir arada sunar ve modern uygulamalarda hızlı ve doğru sonuçlar sağlar. Bu bölümde derin öğrenme temelli segmentasyon

- 1 Bilgisayar Teknolojileri Bölümü, Teknik Bilimler MYO, Tekirdağ Namık Kemal Üniversitesi, Tekirdağ, Türkiye, masimsek@nku.edu.tr, ORCID: 0000-0002-6127-2195
- 2 Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, İstanbul Üniversitesi-Cerrahpaşa, İstanbul, Türkiye, asertbas@iuc.edu.tr, ORCID: 0000-0001-8166-1211
- 3 Radyoloji Bölümü, Tıp Fakültesi, Tekirdağ Namık Kemal Üniversitesi, Tekirdağ, Türkiye, hsasani@nku.edu.tr, ORCID: 0000-0001-6236-4123

yöntemlerinin genel özellikleri hakkında bilgiler sunulmuştur ve ayrıca YOLOv8 mimarisi kullanılarak örnek segmentasyon uygulaması yapılmıştır.

Anahtar Kelimeler: Görüntü işleme, derin öğrenme, segmentasyon, YOLO.

IMAGE SEGMENTATION WITH YOLO SERIES: FUNDAMENTALS, METHODS AND APPLICATIONS

Abstract

Image processing is of great importance in many fields such as medical imaging, industrial inspection, defense and art and is performed to improve the quality of digital images or to extract useful information from these images. Image segmentation is a method that facilitates the analysis of digital images by dividing them into meaningful regions. Deep learning-based segmentation has made great progress in recent years. These methods offer high accuracy and efficiency in areas such as medical imaging and autonomous driving, especially using architectures such as Convolutional Neural Networks (CNN). However, these approaches require high-quality annotated data sets and can be confronted with problems such as overfitting. Deep learning-based algorithms, such as the YOLO (You Only Look Once) series, combine object recognition and segmentation and provide fast and accurate results in modern applications. In this chapter, we introduce the general characteristics of deep learning-based segmentation methods and present a sample segmentation application using the YOLOv8 architecture.

Keywords: Image processing, deep learning, segmentation, YOLO.

GİRİŞ

Görüntü işleme, birçok uygulama alanında önemli bir rol oynayan ve hızla gelişen bir disiplindir. Dijital görüntülerin kalitesini artırmak veya bu görüntülerden yararlı bilgiler elde etmek amacıyla yapılan manipülasyonlar; tıbbi görüntüleme,

endüstriyel denetim, savunma ve sanat gibi çeşitli alanlarda önemli faydalar sağlamaktadır. Görüntü iyileştirme, görüntü segmentasyonu, görüntü tanıma ve sınıflandırma, görüntü sıkıştırma, videolar üzerinde birtakım işlemler görüntü işleminin çalışma alanlarındandır.

Görüntü segmentasyonu, dijital görüntü işleme ve bilgisayarla görme alanında oldukça mühim uygulamadır. Bu işlem, bir görüntüyü anlamak ve yorumlamak için temel bir gereksinimdir, çünkü görüntüyü anlamlı bölgelere ayırarak bu görüntülerin analizini kolaylaştırır. Segmentasyon işlemi aşağıda belirtilen uygulama alanlarında büyük bir öneme sahiptir:

- **Nesne Tanıma:** Segmentasyon, bir görüntüdeki farklı nesnelere ayırt etmeye ve tanımaya yardımcı olur. Bu, özellikle güvenlik sistemlerinde ve otomatik etiketleme sistemlerinde kullanılır.
- **Görüntü Düzenleme:** Görüntü düzenleme uygulamalarında, belirli bölgelerin ayrılması ve düzenlenmesi işlemleri segmentasyon ile daha kolay hale gelir. Örneğin, fotoğraflarda istenmeyen bölgelerin silinmesi veya belirli bölgelerin iyileştirilmesi bu teknikle yapılabilir.
- **Tıbbi Görüntüleme:** Tıbbi görüntülerde, organlar, tümörler veya anomali gibi belirli bölgeleri segmente etmek, doktorların tanı koymasını ve tedavi planlarını oluşturmasını kolaylaştırır. Örneğin, MRI (Magnetic Resonance Imaging) veya CT (Computed Tomography) taramalarında segmentasyon, hastalıkların daha doğru bir şekilde izlenmesini sağlar.
- **Otonom Sistemler:** Otonom araçlar ve robotlarda, çevresel unsurları ve engelleri tanıma için segmentasyon kullanılır. Segmentasyon işlemi, araçların ve robotların çevrelerinde hareket edebilecekleri yerleri tespit eder ve böylece bu araçlar için güvenli bir alan oluşturur.

Segmentasyon işlemi, genellikle piksel tabanlı veya bölge tabanlı yöntemlerle gerçekleştirilir ve çeşitli algoritmalar ve teknikler kullanılarak yapılır. Bu yöntemler, görüntünün özelliklerine ve uygulama gereksinimlerine göre seçilir ve optimize edilir. Segmentasyonun etkin bir şekilde yapılması, görüntü işleme sistemlerinin başarısını doğrudan etkiler ve bu nedenle bu alan üzerinde yapılan araştırmalar ve geliştirmeler büyük bir önem taşır. Segmentasyon işlemi farklı yöntemler kullanılarak yapılmaktadır:

- Sınıflandırma Tabanlı Segmentasyon: Bu yöntem, her pikseli belirli bir sınıfa atar. Genellikle makine öğrenimi veya derin öğrenme algoritmaları kullanılarak yapılır.
- Kenar Tabanlı Segmentasyon: Bu yaklaşım, görüntüdeki kenarları veya sınırları tespit ederek segmentasyon yapar. Canny, Sobel veya Prewitt gibi kenar tespit algoritmaları kullanılır.
- Bölgesel Büyüme (Region Growing): Bu yöntemde, başlangıçta seçilen bir başlangıç pikseli çevresindeki pikseller benzerlik ölçütlerine göre birleştirilir.
- Kümeleme Tabanlı Segmentasyon: Bu yöntem, pikselleri benzer özelliklere göre kümelere ayırır. K-means, Fuzzy C-means gibi algoritmalar kullanılır.
- Kısıtlama Tabanlı Segmentasyon: Bu yöntemde, pikseller veya bölgeler belirli kurallar veya kısıtlamalar doğrultusunda segmentlere ayrılır.
- Model Tabanlı Segmentasyon: Şekil ve obje gibi belirli modeller ile uyumlu bölgelerde sıkça kullanılan bir yöntemdir. Bu yöntemde aktif konturlar (Active Contours) veya seviye set yöntemleri (Level Set Methods) gibi teknikler kullanılır.
- Hikâye ve Doku Tabanlı Segmentasyon: Görüntüdeki doku ve desenleri analiz ederek onları çeşitli gruplara ayıran bir yöntemlerdir. Bu yöntemde doku özellikleri çıkarılır ve benzer dokular gruplanır.

- Hibrid Yaklaşımlar: Bu yöntemde amaç, farklı segmentasyon tekniklerinin birleşimi ile daha doğru sonuçlar elde etmektir. Kenar tespiti ve bölgesel büyüme kombinasyonu gibi işlemlerde bu yaklaşım kullanılabilir.
- Derin Öğrenme Tabanlı Segmentasyon: CNN ve diğer derin öğrenme yaklaşımlarını kullanarak segmentasyon yapma işlemidir. U-Net, Mask R-CNN, YOLO gibi ağ yapıları bu alanda popülerdir.
- 3D Segmentasyon: 3D görüntülerde segmentasyon yapma yöntemleridir. Özellikle tıp alanında, MRI veya CT taramaları gibi 3D veri setleri üzerinde çalışılır.

Son yıllarda veriye ulaşımın artması ve donanımların güçlenmesi ile derin öğrenme algoritmalarında da gelişme sağlamıştır. Bu gelişmelerin doğal bir sonucu olarak derin öğrenme tabanlı segmentasyon, görüntü işleme alanında oldukça güçlü ve yaygın olarak kullanılan yaklaşımlardan biri olmuştur. Görüntüleri anlamlı bölgelere ayırmak için derin öğrenme tekniklerinden yararlanır. Ayrıca CNN gibi mimarilerden yararlanarak derin öğrenme yöntemlerini otomatikleştirir ve böylece tıbbi görüntüleme, otonom sürüş ve çevresel izleme dahil olmak üzere çeşitli uygulamalarda benzeri görülmemiş doğruluk ve verimlilik sağlar[1], [2].

Bu teknolojik ilerleme, derin öğrenmeyi hem akademik alanda hem de endüstri alanlarında, özellikle de hassasiyetin kritik olduğu durumlarda vazgeçilmez bir araç haline getirmiştir. Geleneksel görüntü segmentasyon teknikleri, genellikle manuel girdilere ve sezgisel yöntemlere dayanmaktayken; derin öğrenme yaklaşımlarına geçiş, bu süreçte devrim niteliğinde bir dönüşüm sağlamıştır. Eşikleme ve kenar algılama gibi yöntemler, kapsam ve etkinlik açısından sınırlıdır ve önemli ölçüde uzman bilgisine muhtaçtır[3], [4].

Biyomedikal görüntüler için U-NET tabanlı segmentasyon yöntemleri[5], V-NET, Mask R-CNN[6], son sürümlerinde You Only Look Once (YOLO) algoritmaları[7], SegNet[8],

DeepLab[9], nnDetectron gibi derin öğrenme temelli algoritmalar derin öğrenme tabanlı segmentasyon yapabilen algoritmalara örnek olarak verilebilir.

Klasik segmentasyon yöntemlerine göre derin öğrenme modelleri, büyük veri kümelerini işleyerek karmaşık desenleri belirlemede son derece etkilidir ve kapsamlı manuel özellik mühendisliğine gerek duymadan segmentasyon görevlerinde performansı ve çok yönlülüğü önemli ölçüde artırmaktadır.

Derin öğrenme, görüntü segmentasyonunda bilgisayarlı görü uygulamalarına önemli katkılar sunmaktadır. Bu teknoloji, piksel düzeyinde hassasiyet sağlayarak tüm görüntü sınıflandırmalarında detaylı analizler yapılmasını mümkün kılar. Derin öğrenme yöntemleri, elle kodlanmış kurallara ihtiyaç duymadan otomatik olarak birtakım özellikler öğrenir ve insan seviyesinin ötesinde bir doğruluk sunar. Optimize edilmiş derin ağlar sayesinde gerçek zamanlı performans elde edilir ve bu da tıbbi görüntüleme, otonom sürüş gibi çeşitli kullanım durumlarına uygulama imkânı tanır. Ayrıca, büyük açıklamalı veri kümeleri kullanılarak gerçekleştirilen ölçeklenebilir eğitim süreçleri, derin öğrenme çerçevelerinin esnek uygulamalarına olanak sağlar.

Derin öğrenme algoritmalarına dayalı segmentasyon yöntemleri her ne kadar başarımları yüksek olsa da bünyesinde bazı zorluk ve sınırlılıkları barındırmaktadır. En önemli zorluklardan biri, sağlam modeller geliştirmek için gereken yüksek kaliteli açıklamalı veri kümelerinin sınırlı miktarda bulunmasıdır. Radyologlardan veya klinisyenlerden tıbbi görüntülerin açıklanmasına ihtiyaç duyulur ki bu da zaman alıcı bir süreçtir. Bu özel bilgi, derin öğrenme uygulamaları için gerekli olan açıklamalı veri setlerinin miktarını sınırlayabilir ve genelgeçer modellerin oluşturulmasını zorlaştırabilir[4], [10]. Derin öğrenme modellerinin karşılaştığı önemli sorunlardan biri de aşırı uyum riskidir. Bu durum, modellerin eğitim verilerinde yüksek performans sergilemesine rağmen, yeni ve görülmemiş verilere doğru şekilde genelleme yapamamalarına neden olabilir[4]. Bu zorlukları hafifletmek

amacıyla arařtırmacılar, mevcut veri kümelerini genişletmek için veri artırma tekniklerinden ve yeni veri kümeleri için derin öğrenme algoritmalarında başlangıç ağırlıkları olarak kullanılan önceden eğitilmiş modellerden yararlanmayı içeren transfer öğrenme stratejilerinden faydalanabilir. Ancak tutarlı ve güvenilir segmentasyon sonuçlarına ulaşmak ve metodolojileri iyileřtirerek gerçek zamanlı ortamlarda modelin genelleřtirme yeteneğini artırmak için daha fazla arařtırmaya ihtiya duyulmaktadır.

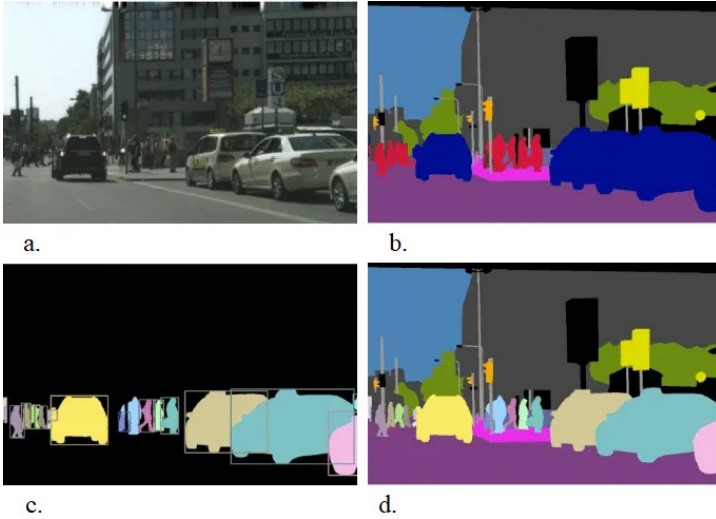
Derin öğrenme segmentasyon modellerinin eğitimi ve çıkarımı hesaplama açısından yoğun işlemler gerektirdiğinden GPU (Graphics Processing Unit) ve TPU (Tensor Processing Unit) gibi özel donanım hızlandırıcıları kullanmaya ihtiya duymaktadır[11]. Derin öğrenme modelleri genellikle “kara kutular” olarak adlandırılır ve bu da karar alma süreçlerinde yorumlanabilirlik ve açıklanabilirliğı zorlařtırır. Bu durumlarda derin öğrenme temelli segmentasyon modellerinin sınırlılıkları arasında gösterilebilir.

Derin öğrenmenin yükseliřiyle birlikte, görüntü segmentasyon yöntemleri önemli bir evrim geirmiş ve üç temel kategoriye ayrılmıştır: anlamsal segmentasyon (Semantic Segmentation), örnek segmentasyonu (Instance Segmentation) ve panoptik segmentasyon (Panoptic Segmentation). Anlamsal segmentasyon, bir görüntüdeki her pikseli belirli bir sınıfa atar, ancak aynı sınıfa ait farklı nesnelere ayırmadan çalışır. Örnek segmentasyonu, bu sınıflamayı daha ileriye taşıyarak, aynı sınıfa ait farklı nesnelere ayrı ayrı tanımlayabilir. Son olarak, panoptik segmentasyon hem anlamsal hem de örnek segmentasyon yaklaşımlarını birleřtirerek, her pikselin bir nesne veya arka plan olarak etiketlenmesini sağlar ve böylece görüntüdeki tüm unsurları detaylı bir şekilde segmentler. Derin öğrenme algoritmaları bu kategorilere göre segmentasyon işlemlerini gerekleřtirmektedir.

Anlamsal Segmentasyon: Bir görüntüdeki her pikseli bir sınıf etiketiyle etiketlemeyi içerir. Bu teknik, aynı sınıfın farklı örnekleri arasında ayrım yapmaz, bunun yerine tüm görüntüyü çeşitli sınıflara ayırmaya odaklanır. Örneğin, bir sokak görüntüsünde, arabalara karşılık gelen tüm pikseller, tek tek araçlar arasında ayrım yapmadan “araba” olarak etiketlenebilir. Anlamsal segmentasyon, genel sahne kompozisyonunun anlaşılmasının önemli olduğu uygulamalarda yaygın olarak kullanılır[12]. Şekil 1b’de örnek olarak verilmiştir.

Örnek Segmentasyon: Her pikseli etiketlemekle kalmayıp aynı zamanda her nesne örneğini ayrı ayrı tanımlayarak anlamsal segmentasyonu bir adım öteye taşır. Aynı sokak görüntüsünde, tek tek arabaların yalnızca toplu bir kategori yerine ayrı varlıklar olarak tanınacağı anlamına gelir. Bu ayrıntı düzeyi, otonom araçlar gibi belirli nesnelere etkileşimin gerekli olduğu uygulamalarda özellikle yararlıdır[13]. Şekil 1c’de örnek olarak verilmiştir.

Panoptik Segmentasyon: Hem anlamsal hem de örnek segmentasyonunu birleştirerek bir sahnenin kapsamlı bir şekilde anlaşılmasını sağlar. Aynı anda nesne sınıflarını belirler ve örnekler arasında ayrım yapar, böylece görüntü segmentasyonu görevlerine birleşik bir yaklaşım sağlar. Bu yöntem, nesnelere hem varlığının hem de benzersizliğinin önemli olduğu senaryolarda faydalıdır. Şekil 1d’de örnek olarak verilmiştir.



Şekil 1. Derin öğrenme temelli segmentasyon yöntemleri[14]. a. Orijinal resim, b. Anlamsal segmentasyon, c. Örnek segmentasyonu, d. Panoptik segmentasyon.

U-Net, V-Net, SegNet ve DeepLab modelleri anlamsal segmentasyon yöntemleri kapsamında segmentasyon işlemlerini gerçekleştirir. YOLOv8 ve YOLOv9 modelleri genellikle nesne tespiti için kullanılsa da YOLOv8-seg ve YOLOv9-seg gibi versiyonları örnek segmentasyon yetenekleri de sunar. Mask R-CNN, örnek segmentasyon için özel olarak tasarlanmış bir modeldir. Panoptic FPN ve PanopticSeg ise panoptik segmentasyon yöntemleri kapsamında hem anlamsal hem de örnek segmentasyon işlevlerini birleştirir.

Segmentasyon modellerinin etkinliğini doğru bir şekilde değerlendirmek için uygun metriklerin seçilmesi kritik öneme sahiptir. Yaygın olarak kullanılan değerlendirme metrikleri arasında Doğruluk (Accuracy), Gerçek Pozitif Oran (True Positive Rate- TPR) ve Birleşme Üzerindeki Kesişim (Intersection over Union - IoU) bulunur.

Doğruluk, tüm piksellerin ne kadarının doğru sınıflandırıldığını ölçer ve genellikle Eşitlik 1’de gösterildiği

gibi hesaplanır. TPR, doğru bir şekilde pozitif olarak sınıflandırılan piksellerin tüm gerçek pozitif piksellere oranını ifade eder ve Eşitlik 2’de gösterildiği gibi hesaplanır. IoU, tahmin edilen ve gerçek segmentasyon maskeleri arasındaki örtüşme oranını belirler. Eşitlik 3’te gösterildiği gibi hesaplanır. Bu metrik, modelin segmentasyon doğruluğunu ve örtüşme alanını değerlendirmede kullanılır. Segmentasyon modelinin performansı tespit edilirken her bir metriğin güçlü ve zayıf yönleri vardır. Bu nedenle, farklı metrikleri bir arada kullanmak, modelin genel başarısını daha kapsamlı bir şekilde anlamaya yardımcı olur.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Toplam Piksel}} \quad (1)$$

$$\text{TPR} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2)$$

$$\text{IoU} = \frac{\text{Gerçek Pozitif}}{\text{Gerçek Pozitif} + \text{Yanlış Pozitif} + \text{Yanlış Negatif}} \quad (3)$$

Görüntü segmentasyonu alanı, özellikle derin öğrenme metodolojilerinin entegrasyonu ile birlikte hızlı bir gelişim göstermektedir. Devam eden araştırmalar, mevcut algoritmaları iyileştirmeye ve segmentasyon görevlerinin performansını artıracak yeni mimarileri keşfetmeye odaklanmaktadır[15]. Gelecekteki eğilimler, kaynak kullanımını optimize ederek doğruluğu koruyacak ve hatta iyileştirecektir böylelikle de daha fazla gelişim sağlanacaktır. Buna ek olarak veri setlerinin artması ve kamuya açık hale gelmesi, bulut sistemi hesaplama araçlarının kullanımının ve erişiminin artması derin öğrenme temelli segmentasyon yöntemlerinin başarımına katkı sağlayacaktır.

Veri Etiketleme ve Hazırlama


Derin öğrenme ile segmentasyon süreci, yalnızca algoritmaların ve modellerin seçimiyle değil aynı zamanda veri hazırlığı ve etiketleme süreçleriyle de doğrudan ilişkilidir. Etiketleme, modelin öğrenmesi için kritik bir öneme

sahip olup her bir pikselin veya bölgenin doğru bir şekilde sınıflandırmasını sağlar ve buna paralel olarak algoritmanın performansını pozitif anlamda etkiler. Derin öğrenme modelleri, büyük miktarda etiketli veri gerektirir çünkü bu veriler, modelin nesne sınırlarını, yapılarının ve diğer görsel özellikleri doğru bir şekilde öğrenmesini sağlar. Etiketleme süreci, her bir görüntüdeki nesnelerin veya bölgelerin doğru bir şekilde işaretlenmesini ve sınıflandırılmasına olanak tanır, bu da modelin genel başarısı için temel bir adımdır. Bu bölümde, derin öğrenme ile segmentasyon için verilerin etiketlenmesinden, derin öğrenme uygulamalarından ve veri setinin hazırlığından bahsedilecektir.

Derin öğrenme modelleri farklı formatlarda etiketleme yöntemlerine göre çalışır. U-Net ve türevleri, özellikle tıbbi görüntüleme ve segmentasyon görevlerinde kullanılan bir derin öğrenme modelidir. U-Net'in etiketleme yöntemi, piksel tabanlı segmentasyon maskeleri kullanır. Bu yöntem, her pikselin belirli bir sınıfa atanmasını sağlar ve bu da nesnelerin hassas sınırlarını belirlemeye olanak tanır. Segmentasyon maskeleri genellikle raster formatında olur; her piksel, belirli bir nesne sınıfının veya arka planın bir parçası olarak etiketlenir. Bu, özellikle nesnelerin karmaşık sınırlarını ve ayrıntılarını tespit etmek için idealdir. U-Net anlamsal segmentasyon için geliştirilmiştir. Şekil 2a'da diz MRI görüntüsü verilmiştir. Bu görüntü üzerindeki menisküs alanlarının etiketlenmesi sonucunda oluşan maske Şekil 2b'de verilmiştir.

YOLO serileri ile segmentasyon yaparken segmentasyon yapılacak bölgenin her bir koordinat bilgisi ve segmente alanın hangi sınıfa ait olduğu bilgisi TXT dosyalarında saklanır. TXT dosyaları, her görüntü için nesne sınıfları ve sınır kutularının koordinatlarını içerir. Bu format, özellikle hızlı ve verimli nesne tespiti için uygundur. Şekil 2a'da diz MRI görüntüsü verilmiştir. Bu görüntü üzerindeki menisküs alanlarının etiketlenmesi sonucunda oluşan TXT uzantılı etiket dosyası Şekil 2c'de verilmiştir.

nnDetection gibi bazı modeller, etiketleme bilgilerini JSON (JavaScript Object Notation) dosyalarında saklar. JSON, veri yapıları ve nesnelere metin formatında temsil etmek için kullanılan hafif bir veri değişim formatıdır. JSON dosyaları, genellikle nesne tespiti ve segmentasyon görevleri için kapsamlı etiketleme bilgileri sağlar. Bu dosyalar, sınırları, segmentasyon maskeleri, nesne sınıfları ve ek metadata bilgilerini içerir. JSON formatı, verilerin yapısal olarak düzenlenmesine olanak tanır ve çeşitli veri türlerini destekleyerek esneklik sağlar. Şekil 2a'da diz MRI görüntüsü verilmiştir. Bu görüntü üzerindeki menisküs alanlarının etiketlenmesi sonucunda oluşan JSON uzantılı etiket dosyası Şekil 2d'de verilmiştir.



Şekil 2. U-Net ile veri etiketleme. a. Diz MRI görüntüsü, b. Menisküs bölge maskesi, c. TXT formatında etiketlenmiş menisküs alanı, d. JSON formatında etiketlenmiş menisküs alanı.

Her bir etiketleme yöntemi ve formatı, belirli görevler ve uygulamalar için avantajlar sunar ve projede tercih edilen derin öğrenme modeline göre seçilir. Bu farklılıklar, model performansını ve veri işleme sürecini doğrudan etkiler, bu nedenle doğru etiketleme yönteminin seçilmesi ve doğru etiketlemelerin yapılması başarılı bir derin öğrenme projesi için kritik öneme sahiptir.

Veri setlerinin etiketleme sonrası derin öğrenme modelleri ile denenmesi için bazı işlemlerin yapılması, modelin başarıyla eğitilmesi ve değerlendirilmesi önemlidir. Etiketleme tamamlandıktan sonra, veri setinin derin öğrenme projeleri için uygun hale getirilmesi için aşağıdaki işlemler yapılabilir:

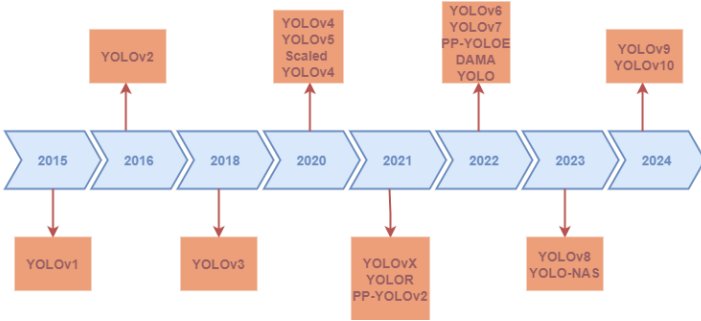
- Veri Temizleme ve Ön İşlem: Görüntülerdeki gürültü veya hatalı etiketleri temizlemek, görüntülerin kullanılacak modelin kabul ettiği boyutlara (640x640 gibi) getirmek.
- Veri Bölme: Veri seti genellikle üç ana parçaya (7:2:1) ayrılır eğitim seti (modeli eğitmek için), doğrulama seti (modelin performansını ayarlamak için) ve test seti (modelin genel performansını değerlendirmek için). Bu bölme, modelin aşırı öğrenmeyi önlemesine ve genel performansının değerlendirilmesine olanak tanır.
- Veri Artırma (Data Augmentation): Eğer görüntü sayısı yeterli değilse veri artırma yöntemleri kullanılarak bu işlem yapılması gerekir.
- Veri Dengeleme: Veri setinde bazı sınıfların daha az temsil edildiği durumlarda, bu sınıfların temsilini artırmak için veri artırma teknikleri kullanılabilir.

YOLO

Giriş bölümünde görüntü işleme, segmentasyon ve derin öğrenme temelli segmentasyon konuları detaylandırılarak bu alandaki temel kavramlar ve yöntemler incelenmiştir. Bu bölümde ise, derin öğrenmenin sağladığı bu güçlü araçların nasıl uygulandığından ve modern segmentasyon görevlerinde ne denli etkili olduğunu anlamak için YOLO serilerinden bahsedilecektir. YOLO serisi, nesne tespiti konusunda geliştirilmiş ve son sürümlerinde segmentasyon yetenekleriyle genişletilmiş CNN temelli derin öğrenme modellerinden biridir. Bu bölümde, YOLO serisinin gelişimine ve segmentasyon yeteneklerine dair bir inceleme yaparak, bu yöntemlerin gerçek dünya uygulamalarındaki potansiyelini ortaya koyacağız.

YOLO (You Only Look Once), 2015 yılında Redmon ve ark. tarafından önerilen bir nesne tanıma algoritmasıdır. Bu algoritma, bir giriş görüntüsünü $S \times S$ ızgara hücrelerine böler ve her hücre için B sınırlayıcı kutularını (bounding boxes) ve bunlara karşılık gelen sınıf olasılıklarını tahmin eder.

YOLO, nesne algılama problemini regresyon problemine dönüştürerek hızlı ve doğru nesne algılamayı hedefler[16], [17]. YOLO temelli algoritmaların en son sürümü YOLOv8 algoritmasıdır. Yıllar içinde, performansı iyileştirmeyi amaçlayan yenilikçi tekniklerle donatılmış çok sayıda YOLO sürümü yayınlanmıştır. Şekil 3'te YOLO versiyonlarının zaman çizelgesi verilmiştir.



Şekil 3. YOLO versiyonlarının zaman çizelgesi: YOLOv1'den YOLOv10'a.

İlk versiyon olan YOLOv1, nesne tespitini bir seferde tamamlamayı hedefleyen tek aşamalı bir model sunmuş, bu sayede hızlı ve verimli bir şekilde sonuç elde edilmesini sağlamıştır. YOLOv1, görüntüyü sabit bir ızgaraya bölerek her hücreye bir dizi sınıf ve koordinat tahmini yapmış ancak sınırlı çözünürlüğe sahip olması ve ayrıntılı bilgi vermemesi nedeniyle bazı zorluklarla karşılaşmıştır. Bu ilk versiyonun temel ilkeleri, nesne tespitinde hız ve verimliliği fakat çözünürlük ve hassasiyet geliştirme konusunda zayıf kalmıştır[18], [19].

YOLOv2 ve YOLOv3, ilk modelin başarısını artırmayı amaçlayan önemli evrimlerdir. YOLOv2, "YOLO9000" adıyla tanıtılmış ve çok sayıda nesne sınıfını destekleyen bir model sunarak genişletilmiş bir sınıf yelpazesi sağlamıştır. Ayrıca bu modelde önceden eğitilmiş bir ağ olan Darknet-19 kullanılarak daha derin ve etkili özellik çıkarımı yapılmıştır. YOLOv3 ise, daha derin bir ağ yapısına sahip olarak hem

küçük hem de büyük nesnelere tespit etme yeteneğini geliştirmiştir. Bu versiyon, çoklu ölçekli özellik çıkarımı ile daha yüksek doğruluk sağlamış ve daha iyi bir performans sunmuştur[18].

YOLOv4 ve sonraki versiyonlar, algoritmanın hız ve doğruluk konusundaki yeteneklerini daha da ileriye taşımıştır. YOLOv4'te çeşitli optimizasyon teknikleri ve veri artırma stratejileri kullanılarak büyük bir performans artışı sağlanmış, gerçek dünya uygulamalarında daha iyi sonuçlar elde edilmiştir. YOLOv5, topluluk tarafından geliştirilen ve daha hafif bir yapı sunan bir versiyondur ve hızlı ve verimli sonuçlar sağlayan çeşitli model varyasyonları sunmuştur. YOLOv6 ve YOLOv7, bu ilerlemeleri daha da geliştirerek özellikle derin öğrenme ve nesne tespiti alanında daha yüksek performans ve daha iyi genel özellikler sağlamıştır. En güncel sürüm olan YOLOv10 ise, önceki versiyonların tüm avantajlarını birleştirerek, en son teknolojiye sahip yapılar ve iyileştirmeler sunmuş, nesne tespiti ve görüntü analizi konusunda sektördeki en yüksek standartları belirlemiştir[19].

YOLO versiyonlarında segmentasyon, özellikle YOLOv8 ve sonraki sürümlerinde, tek tek nesne piksellerinin ayrıntılı segmentasyonunu sağlamak amacıyla özel olarak desteklenir. Hız, verimlilik, yüksek doğruluk ve sağlamlık YOLO versiyonları ile yapılan segmentasyonun avantajları arasında sayılabilir. Bu güçlü yönleri sayesinde kısa sürede YOLO serilerine dayanan modeller akademik çalışmalarda ve endüstriyel uygulamalarda kullanılmaya başlamıştır.

YOLOv8 ile Segmentasyon: Google Colab'da Uygulama Rehberi

Derin öğrenme ve bilgisayarla görü alanındaki en son yeniliklerden biri olan YOLOv8-Seg, gerçek zamanlı nesne tespiti ve segmentasyonu işlemlerini bir arada sunan güçlü bir modeldir. Bu bölümde, YOLOv8-Seg'in segmentasyon yeteneklerini Google Colab ortamında nasıl kullanabileceğinizi adım adım inceleyeceğiz. Google Colab, bulut tabanlı bir

ortam sunarak, güçlü GPU'lar ile derin öğrenme modellerinin eğitimini ve testini kolaylaştırır. YOLOv8-Seg'in sunduğu segmentasyon özellikleri, nesnelerin tam sınırlarını belirlemek ve daha detaylı analizler yapmak için idealdir. Bu bölümde, kod örnekleri ve açıklamalar aracılığıyla YOLOv8-Seg'in etkin kullanımını ve segmentasyon görevlerinde sağladığı avantajlar anlatılacaktır.

Bu uygulama için, Kaggle platformunda bulunan segmentasyon için etiketlenmiş köprü görüntülerini içeren veri seti[20] ve Ultralytics firmasına ait YOLOv8 segmentasyon kodları[21] kullanılmıştır. 249 görüntüden oluşan veri seti; eğitim, doğrulama ve test işlemleri için 7:2:1 oranında bölünmüştür. Şekil 4'te kullanılan veri setine ait etiketlenmiş bir köprü görünmektedir. Ön işlem olarak tüm görüntüler 640X640 boyutuna getirilmiştir.



Şekil 4. Etiketlenmiş bir köprü görüntüsü.

Şekil 5’te gösterilen kodu kullanarak Google Drive’ımızı Google Colab’a bağlanması gerçekleştirilir. Kod çalıştırıldığında bir bağlantı ve onay kodu ile karşılaşacaksınız. Bu bağlantıya tıklayıp Google hesabınızla oturum açarak gerekli izinler verilir.

```
from google.colab import drive
drive.mount('/content/drive')
```

Şekil 5. Google Colab üzerinden Google Drive’e bağlanma kod parçası.

Eğitim, doğrulama ve test işlemleri için bölünmüş veri seti zip uzantı haline getirilir, Colab çalışma alanına ya da Google Drive’de ilgili alana yüklenir. Yüklenen veri setini zip uzantısından açmak için Şekil 6’da gösterilen kod satırı kullanılır.

```
!unzip /content/kopru_veri_seti.zip
```

Şekil 6. Yüklenen veri setini zip uzantısından açmak.

Şekil 7’de gösterilen kod satırları Google Colab üzerinde ultralytics kütüphanesini kurmak ve ilgili GitHub deposunu klonlamak için kullanılır.

```
!pip install ultralytics
!git clone https://github.com/ultralytics/ultralytics.git
%cd /content/ultralytics
!yolo mode=checks
from ultralytics import YOLO
from IPython.display import display, Image
%cd /content/ultralytics
```

Şekil 7. Gerekli kütüphanelerin indirilmesi ve kurulması.

Şekil 8’de gösterilen kod satırı YOLOv8 modelinin bir ağırlık dosyasıdır ve segmentasyon (seg) yeteneklerine sahip bir model içermektedir ve başlangıç ağırlıklarına ait ‘yolov8x-seg.pt’ adlı dosyayı indirir.

```
!wget https://github.com/ultralytics/assets/releases/download/v0.0.0/yolov8x-seg.pt
!wget https://github.com/yasarniyazoglu/Yolov8-SEG-Custom-Dataset/blob/main/custom.yaml
```

Şekil 8. Ağırlıkların indirilmesi.

Eğitim Şekil 9’da gösterilen kod parçası ile başlamaktadır. Bu satır üzerinde bazı hiperparametre seçimler ve birtakım ayarlamalar yapılır. Bu komut, YOLOv8 modelini segmentasyon görevini yerine getirmek üzere eğitim modunda çalıştırır. İlk olarak, task=segment parametresi, modelin segmentasyon görevi için yapılandırıldığını belirtir ve mode=train parametresi, modelin eğitim modunda olduğunu ifade eder. Eğitimde kullanılacak model dosyası yolov8x-seg.pt olarak belirtilmiştir; bu dosya, YOLOv8’in segmentasyon yeteneklerine sahip önceden eğitilmiş bir versiyonunu içerir. Eğitim veri kümesinin tanımlandığı yapılandırma dosyasının yolu /content/kopru_veri_seti/data.yaml olarak verilmiştir. Bu dosya, veri kümesinin yollarını, sınıf etiketlerini ve diğer önemli bilgileri içerir. Modelin eğitim süreci 100 epoch boyunca gerçekleşecek şekilde ayarlanmıştır. Eğitim sırasında modelin giriş görüntüleri 640x640 piksel boyutunda olacaktır. Her eğitim adımında işlenecek batch boyutu ise 2 olarak belirlenmiştir. Ayrıca, eğitim sürecinde kullanılacak optimizasyon algoritması olarak SGD (Stokastik Gradyan İnişi) seçilmiştir ve öğrenme oranı 0.01 olarak ayarlanmıştır. Hiperparametrelerin seçimi denemeler sonucunda en optimum hale getirilebilir.

```
!yolo task=segment mode=train model=yolov8x-seg.pt data=/content/kopru_veri_seti/data.yaml epochs=100 imgsz=640 batch=2 optimizer =SGD lr0=0.01
```

Şekil 9. Segmentasyon için eğitimin başlatılması.

Modelin eğitimini değerlendirmek için kullanılan metriklerin eğitim süresince değişimlerini değerlendirmek amacıyla Şekil 10’da gösterilen kod satırları kullanılabilir. Bu kod parçasığı, Jupyter notebook veya Google Colab gibi bir ortamda TensorBoard’u yükleyip başlatmak için kullanılır. İlk olarak, %load_ext tensorboard komutu, TensorBoard uzantısını Jupyter veya Colab ortamına yükler, bu sayede TensorBoard’un özelliklerini kullanabilirsiniz. Ardından, %tensorboard --logdir runs/segment/train

komutu, TensorBoard arayüzünü başlatır ve runs/segment/train dizinindeki log dosyalarını kullanarak eğitim sürecinin görselleştirmelerini oluşturur. Bu dizin, modelin eğitim sürecindeki detayları ve metrikleri içeren log dosyalarını barındırır. TensorBoard, bu verileri okuyarak eğitim kayıpları, doğruluk oranları, öğrenme eğrileri ve model yapısı gibi bilgileri grafiksel olarak sunar ve böylece modelin performansını daha iyi analiz edebilir ve değerlendirilebilir.


```
%load_ext tensorboard
%tensorboard --logdir runs/segment/train
```

Şekil 10. Tensorboard kurulumu.

YOLOv8 modelini segmentasyon görevinde test verileri üzerinden tahmin yapmak üzere Şekil 11’de bulunan kod satırı kullanılır. task=segment parametresi, modelin segmentasyon görevini gerçekleştireceğini belirtirken, mode=predict parametresi modelin tahmin modunda çalışacağını ifade eder. model=runs/segment/train/weights/last.pt parametresi, tahminlerde kullanılacak model dosyasının yolunu gösterir; burada last.pt dosyası, modelin eğitim sürecinde elde edilen en son ağırlıklarını içerir. conf=0.50 parametresi, tahminlerin yalnızca güven skorunun 0.50 veya daha yüksek olduğu durumlarda kabul edileceğini belirler, bu da tahminlerin daha yüksek güvenilirlikte olmasını sağlar. Son olarak, source=”test/images” parametresi, tahminlerin yapılacağı veri kaynağının yolunu belirtir; bu durumda tahminler, test/images adlı klasörde bulunan görüntüler üzerinde gerçekleştirilecektir. Bu komut, belirtilen model dosyasını kullanarak belirtilen klasördeki görüntüler üzerinde segmentasyon tahminleri yapar ve sonuçları, modelin performansını değerlendirmek için kullanır.

```
!yolo task=segment mode=predict model=/content/ultralytics/runs/segment/train/weights/last.pt conf=0.50 source="/test/images"
```

Şekil 11. Test verileri üzerinden eğitilen modelin test edilmesi.



Şekil 12. Test veri setinde bulunan görseller üzerinde tahmin işlemi.

SONUÇ

Görüntü işleme ve segmentasyon alanında derin öğrenme temelli segmentasyon yöntemleri, yüksek doğruluk ve hassasiyet sağlama yetenekleriyle dikkat çekmektedir. Bu yöntemler, özellikle CNN ve daha karmaşık ağ yapıları sayesinde, görüntülerin piksel seviyesinde detaylı analizini yapabilme kapasitesine sahiptir. Derin öğrenme tabanlı segmentasyon yöntemlerinin en büyük avantajı, büyük veri setlerinden öğrenme ve modelin otomatik olarak özellikleri çıkartma yeteneğidir, bu da geleneksel yöntemlere göre daha yüksek doğruluk ve esneklik sağlar. Ayrıca, bu yöntemler, karmaşık nesne tespiti ve sınıflandırma görevlerini daha iyi yönetebilir, böylece segmentasyon sonuçlarının kalitesi artar. Ancak, bu yöntemlerin bazı dezavantajları da vardır. Bunlar arasında yüksek hesaplama gücü ve büyük veri setleri gerektirmesi, eğitim sürecinin zaman alıcı olması ve aşırı uyum riskleri yer almaktadır. Ayrıca, derin öğrenme tabanlı modeller genellikle yüksek donanım maliyetleri ile ilişkilidir ve modelin eğitilmesi için önemli miktarda etiketlenmiş veriye ihtiyaç duyulur. Sonuç olarak, derin öğrenme temelli segmentasyon yöntemleri, yüksek performans ve doğruluk sağlarken, hesaplama kaynakları ve veri gereksinimleri açısından dikkatli planlama ve optimizasyon gerektirmektedir.

Kaynaklar

- [1] H. Zhang and Y. Qie, "Applying Deep Learning to Medical Imaging: A Review," *Applied Sciences*, vol. 13, no. 18, p. 10521, Sep. 2023, doi: 10.3390/app131810521.
- [2] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, "Image Segmentation Using Deep Learning: A Survey," Jan. 2020.
- [3] Venkatkumar R., "Segmentation: Traditional & Deep learning Approaches," https://medium.com/@VK_Venatkumar/segmentation-traditional-deep-learning-approaches-edd50a3308b3.
- [4] M. Li, Y. Jiang, Y. Zhang, and H. Zhu, "Medical image analysis using deep learning algorithms," *Front Public Health*, vol. 11, Nov. 2023, doi: 10.3389/fpubh.2023.1273253.
- [5] G. Du, X. Cao, J. Liang, X. Chen, and Y. Zhan, "Medical Image Segmentation based on U-Net: A Review," *Journal of Imaging Science and Technology*, vol. 64, no. 2, pp. 020508-1-020508-12, Mar. 2020, doi: 10.2352/J.ImagingSci.Technol.2020.64.2.020508.
- [6] C. Yu *et al.*, "Segmentation and density statistics of mariculture cages from remote sensing images using mask R-CNN," *Information Processing in Agriculture*, vol. 9, no. 3, pp. 417-430, Sep. 2022, doi: 10.1016/j.inpa.2021.04.013.
- [7] C. H. Kang and S. Y. Kim, "Real-time object detection and segmentation technology: an analysis of the YOLO algorithm," *JMST Advances*, vol. 5, no. 2-3, pp. 69-76, Sep. 2023, doi: 10.1007/s42791-023-00049-7.
- [8] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 12, pp. 2481-2495, Dec. 2017, doi: 10.1109/TPAMI.2016.2644615.
- [9] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," *IEEE Trans Pattern Anal Mach Intell*, vol. 40, no. 4, pp. 834-848, Apr. 2018, doi: 10.1109/TPAMI.2017.2699184.
- [10] S. Gunasekaran, P. S. Mercy Bai, S. K. Mathivanan, H. Rajadurai, B. D. Shivahare, and M. A. Shah, "Automated brain tumor diagnostics: Empowering neuro-oncology with deep learning-based MRI image analysis," *PLoS One*, vol. 19, no. 8, p. e0306493, Aug. 2024, doi: 10.1371/journal.pone.0306493.
- [11] F. Wahid, Y. Ma, D. Khan, M. Aamir, and S. U. K. Bukhari, "Biomedical Image Segmentation: A Systematic Literature Review of Deep Learning Based Object Detection Methods," Aug. 2024.
- [12] K. Pal, P. Yadav, and N. Katal, "RoadSegNet: a deep learning framework for autonomous urban road detection," *Journal of Engineering and Applied Science*, vol. 69, no. 1, p. 110, Dec. 2022, doi: 10.1186/s44147-022-00162-9.

- [13]A. M. Hafiz and G. M. Bhat, “A survey on instance segmentation: state of the art,” *Int J Multimed Inf Retr*, vol. 9, no. 3, pp. 171–189, Sep. 2020, doi: 10.1007/s13735-020-00195-x.
- [14]yentur, “Görüntü Segmentasyonu,” <https://medium.com/move-on-ai/görüntü-segmentasyonu-ba193b168a1b>.
- [15]F. Ergin, I. B. Parlak, M. Adel, Ö. M. Gül, and K. Karpouzis, “Noise Resilience in Dermoscopic Image Segmentation: Comparing Deep Learning Architectures for Enhanced Accuracy,” *Electronics (Basel)*, vol. 13, no. 17, p. 3414, Aug. 2024, doi: 10.3390/electronics13173414.
- [16]Y. Su, B. Cheng, Y. C.-2023 I. 6th I. Conference, and undefined 2023, “Detection and Recognition of Traditional Chinese Medicine Slice Based on YOLOv8,” *ieeexplore.ieee.org Y Su, B Cheng, Y Cai2023 IEEE 6th International Conference on Electronic Information, 2023•ieeexplore.ieee.org*, Accessed: Oct. 30, 2023. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10245026/>
- [17]J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [18]C.-Y. Wang and H.-Y. M. Liao, “YOLOv1 to YOLOv10: The fastest and most accurate real-time object detection systems,” Aug. 2024.
- [19]M. A. R. Alif and M. Hussain, “YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain,” Jun. 2024.
- [20]Sarah HADDAD, “Annotated (Yolov8) Bridge images for Segmentation,” <https://www.kaggle.com/datasets/pfem2sarah/annotated-yolov8-bridge-images-for-segmentation>.
- [21]<https://colab.research.google.com/github/ultralytics/ultralytics/blob/main/examples/tutorial.ipynb>, “YOLOv8 Tutorial,” <https://colab.research.google.com/github/ultralytics/ultralytics/blob/main/examples/tutorial.ipynb>.

ANNE SAĞLIĞI RİSK GRUPLARININ BELİRLENMESİNDE MAKİNE ÖĞRENMESİ YAKLAŞIMLARI

Rukiye Uzun Arslan¹, İrem Şenyar Yapıcı²

Özet

Anne sağlığı, hem annelerin hem de bebeklerin sağlığını doğrudan etkileyen kritik bir halk sağlığı sorunu olarak öne çıkmaktadır. Son yıllarda makine öğrenmesi (MÖ) uygulamalarındaki ilerlemeler, çeşitli tıbbi verilerin kullanılmasıyla anne sağlığı risklerinin erken aşamada tespit edilebileceğini ortaya koymuştur. Bu derleme çalışmasında, 2020-2024 yılları arasında anne sağlığı risklerinin belirlenmesine yönelik literatürde yer alan 16 çalışma sistematik olarak incelenmiş ve bu çalışmaların etkinlikleri karşılaştırılmıştır. Bu çalışmanın sonuçları, anne sağlığı alanında MÖ dayalı teknolojilerin potansiyelini ortaya koyarak, gelecekteki araştırmalara ışık tutmakta ve sağlık hizmetlerinin iyileştirilmesine yönelik önemli bilgiler sunmaktadır.

Anahtar Kelimeler: Anne sağlığı; makine öğrenmesi; karar destek sistemleri; risk tespiti

1 Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, rukiyeuzun67@gmail.com, ORCID: 0000-0002-2082-8695
2 Bilgisayar Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, senyerirem@gmail.com, ORCID: 0000-0003-0655-340X

Machine Learning Approaches for Identifying Maternal Health Risk Groups: A Literature Review

Abstract: Maternal health emerges as a critical public health issue that directly affects the health of both mothers and infants. In recent years, advancements in machine learning (ML) applications have demonstrated the potential to detect maternal health risks at an early stage through the use of various medical data. This review systematically examines 16 studies from the literature published between 2020 and 2024, focusing on the identification of maternal health risks and comparing the effectiveness of these studies. The findings of this review highlight the potential of ML-based technologies in the field of maternal health, shedding light on future research directions and providing valuable insights for the improvement of healthcare services.

Keywords: Maternal health; machine learning; decision support systems; risk detection

GİRİŞ

Anne sağlığı, hamilelik, doğum ve lohusalık dönemlerinde annenin fiziksel, zihinsel ve sosyal refahını koruma ve geliştirmeyi amaçlayan önemli bir sağlık alanıdır. Bu alan, annenin hayatta kalmasının ötesine geçerek; anne ve fetus için sağlıklı bir hamilelik süreci, anne için güvenli bir doğum ve her ikisi için de doğum sonrasında sağlıklarının korunmasını sağlamayı hedeflemektedir. Anne sağlığı hizmetleri, anne adaylarının bilinçlendirilmesi, prenatal bakımın iyileştirilmesi, doğum komplikasyonlarının azaltılması ve postpartum (doğum sonrası) dönemde annelerin sağlıklarının izlenmesi gibi birçok önemli unsur içerir. Bu süreç, hamilelik öncesi danışmanlıktan doğum sonrası desteğe kadar uzanan kapsamlı hizmetleri içermekte olup, toplumsal refahı artırma potansiyeline sahiptir. Sağlık otoriteleri ve ilgili kurumlar, anne sağlığı hizmetlerinin etkinliğini artırmak için kapsamlı stratejiler geliştirmiş ve bu stratejilerin uygulanmasına yönelik politikalar oluşturmuşlardır. Bu

yaklaşımlarda, prenatal bakımın önemi vurgulanmakta ve bu dönemde anne adaylarına sunulan hizmetlerin kalitesinin artırılması hedeflenmektedir [1].

Anne sağlığı hizmetlerinin merkezinde yer alan prenatal bakım, bu süreçlerin başarısında belirleyici bir rol oynamaktadır. Prenatal bakım, gebelik sürecinde anne ve fetüs sağlığının izlenmesi, beslenme ve egzersiz önerileri, enfeksiyonların önlenmesi ve yönetimi gibi önemli unsurları içermektedir [2]. Araştırmalar, düzenli prenatal bakım alan annelerde doğum komplikasyonlarının azaldığını ve bebeklerinin daha sağlıklı olduğunu göstermektedir [3]. Bu veriler, prenatal bakımın sağlık sistemleri içinde güçlendirilmesi gerektiğine işaret etmektedir.

Prenatal bakımın sağladığı avantajlar, doğum sürecinin güvenli ve sağlıklı bir şekilde tamamlanmasını desteklemektedir. Ancak anne sağlığı hizmetlerinin başarısı sadece gebelik dönemine değil, aynı zamanda doğum sürecinde sunulan tıbbi hizmetlerin kalitesine de bağlıdır. Güvenli doğum ortamlarının sağlanması, deneyimli sağlık personeli tarafından gerçekleştirilen doğumların teşvik edilmesi ve acil durumlar için uygun müdahale olanaklarının bulunması, anne ölümlerinin azaltılmasında kritik bir rol oynamaktadır [4]. Bu bağlamda, düşük ve orta gelirli ülkelerde doğum esnasında sunulan hizmetlerin iyileştirilmesi, küresel sağlık hedeflerine ulaşmada önemli bir adım olarak değerlendirilmektedir [5]. Dolayısıyla, doğum öncesi ve doğum esnasında sağlanan bakımın kalitesi, anne sağlığı sonuçları üzerinde belirleyici bir etkiye sahiptir. Ancak bu süreç, doğum sonrası dönemde sunulan sağlık hizmetlerinin kalitesiyle tamamlanmalıdır.

Doğum sonrası bakım, anne sağlığı hizmetlerinin tamamlayıcı ve kritik bir bileşeni olarak ortaya çıkmaktadır. Postpartum dönemde annelerin fiziksel ve zihinsel sağlıklarının korunması, bebek bakımı konusunda eğitim ve destek sağlanması, doğum sonrası komplikasyonların erken tespiti ve tedavi edilmesi, anne sağlığının devamlılığı

açısından büyük önem taşımaktadır [6]. Bu dönemde sunulan hizmetlerin kalitesi, yalnızca annelerin kısa vadeli sağlık durumlarını değil, aynı zamanda uzun vadeli sağlık sonuçlarını da önemli ölçüde etkileyebilmektedir.

Genel olarak değerlendirildiğinde prenatal bakım, güvenli doğum ve doğum sonrası hizmetlerin kalitesi, anne sağlığı üzerinde önemli bir etkiye sahiptir. Bu süreçlerin her bir aşamasında sağlanan hizmetlerin kalitesinin artırılması, anne ve bebek sağlığını olumlu yönde etkileyerek toplumun genel sağlık düzeyini yükseltmektedir. Dünya Sağlık Örgütü (DSÖ) verilerine göre, her gün yaklaşık 6.700 bebek ve 810 hamile kadın yaşamını yitirmektedir [7, 8]. Bu ölümlerin %94'ü düşük ve orta gelirli ülkelerde meydana gelmektedir. Sağlık hizmetlerine erişimde yaşanan kısıtlılıklar, bu ülkelerde hamilelik ve doğum sürecinde komplikasyonların ciddiyetini artırmakta ve anne ölümlerinin yüksek oranlarda seyretmesine yol açmaktadır. Dolayısıyla, hamilelik süresince annenin ve fetüsün sağlığını güvence altına almak, sağlık hizmetlerine erişimin sınırlı olduğu bu ülkelerde hayati bir önem taşımaktadır. [9, 10]. Bu bağlamda, erken doğum veya ölüm gibi hamilelik sırasında oluşabilecek komplikasyonlardan kaçınılmasında ve uygun tedavi planlamalarının yapılmasında gebelikle ilgili risklerin erken evrede tespit edilmesi gerekmektedir.

Öte yandan, son yıllarda tıp alanında makine öğrenmesine (MÖ) dayalı karar destek sistemlerinin (KDS) yaygınlaşması, sağlık hizmetlerinde önemli ilerlemelere olanak tanımıştır. Bu sistemler, büyük veri setlerini analiz ederek sağlık profesyonellerine tanı ve tedavi süreçlerinde rehberlik etmektedir. Karmaşık sağlık sorunlarının çözümünde önemli bir rol oynayan bu sistemler, sağlık hizmetlerinin kişiselleştirilmesine ve hasta bakımının iyileştirilmesine katkı sağlamaktadır. Anne sağlığı alanında, KDS uygulamaları, gebelik süreci ve doğum sonrası dönemde karşılaşılan komplikasyonların erken tespit edilmesine ve önlenmesine

yardımcı olmaktadır. Bu teknolojiler, hamilelik takibinin kişiselleştirilmesini sağlayarak, anne ve bebek sağlığının iyileştirilmesine katkı sağlamaktadır. Özellikle riskli gebeliklerin yönetiminde, anne sağlığı uzmanlarına doğru ve zamanında bilgi sunarak müdahalelerin etkinliğini artırmaktadır. Bu sistemler, preeklampsi, gestasyonel diyabet ve erken doğum gibi komplikasyonların olasılığını erken safhalarda belirleyerek sağlık profesyonellerinin daha etkili müdahale stratejileri geliştirmelerine olanak tanımaktadır. Kişiselleştirilmiş bakım planlarının oluşturulmasını destekleyen bu teknolojiler, her annenin bireysel ihtiyaçlarına uygun sağlık hizmetlerinin sunulmasına katkıda bulunmaktadır. Ayrıca, uzaktan izleme ve tele-tıp uygulamaları ile entegre edilebilen bu sistemler, düşük ve orta gelirli ülkelerde sağlık hizmetlerine erişimi kolaylaştırarak bu bölgelerdeki annelere yüksek kaliteli bakım ulaştırma imkanı sağlamaktadır. Böylelikle, erken müdahale ve sürekli izleme sayesinde anne ve fetüs sağlığının korunması sağlanmakta, sağlık hizmetlerinin genel etkinliği artırılmaktadır. Bu teknolojiler, sağlık hizmetlerinin kalitesini ve erişilebilirliğini artırarak küresel sağlık hedeflerine ulaşmada önemli bir rol oynamaktadır.

Özetle, MÖ dayalı karar destek sistemleri, sağlık hizmetlerinde devrim niteliğinde değişiklikler getirmekte ve özellikle anne sağlığında önemli iyileşmeler sağlamaktadır. Literatürdeki çalışmalar, bu sistemlerin anne sağlığı üzerindeki potansiyel etkilerini anlamak açısından kritik bir öneme sahiptir. Bu derlemede, 2020 ve 2024 yılları arasında yapılan on altı çalışma kapsamlı bir şekilde ele alınmış ve MÖ algoritmalarının anne sağlığı üzerindeki etkileri değerlendirilmiştir. Bulgular, MÖ algoritmalarının gebelik sırasında ortaya çıkabilecek risklerin erken tespiti ve yönetiminde etkin bir araç olduğunu göstermektedir. Ayrıca, literatür taraması mevcut yaklaşımların etkinliğini ortaya koyarak, gelecekteki araştırma yönelimlerini belirlemiş ve sağlık hizmetlerinin iyileştirilmesine yönelik önemli

bilgiler sunmuştur. Bu bağlamda, MÖ dayalı teknolojilerin anne sağlığı alanında sağladığı katkılar, sağlık hizmetlerinin kişiselleştirilmesi ve geliştirilmesi için yeni ufuklar açmaktadır.

2. İlgili Çalışmalar ve Literatür Özeti

Bu bölümde, 2020-2024 yılları arasında anne sağlığı risk gruplarının tespitinde MÖ algoritmalarını kullanan çalışmalar kapsamlı bir şekilde incelenmiştir. İlgili dönemdeki çalışmalar, kullanılan algoritmalar, veri setleri ve elde edilen sonuçlar açısından özetlenmiş, literatürdeki genel eğilimler değerlendirilmiştir. Özellikle, MÖ dayalı yöntemlerin anne sağlığı risk gruplarını belirlemedeki etkinliği ve bu yöntemlerin sunduğu yenilikçi çözümler alınmıştır. Örneğin, Ahmed ve arkadaşları [11], gelişmekte olan bir ülkenin kırsal kesiminde hamile kadınların sağlık durumlarını izlemek amacıyla giyilebilir sensör teknolojisi kullanarak bir çalışma gerçekleştirmişlerdir. Bu çalışmada, hamilelik sırasında ortaya çıkabilecek risk faktörleri göz önünde bulundurularak farklı MÖ algoritmalarının başarımları karşılaştırılmıştır. Yapılan analizlerde, açık erişimli Pima-Hint diyabet veri seti kullanılmış ve Lojistik Model Ağacı (LMT) algoritmasının %98 doğruluk oranıyla sınıflandırma ve risk seviyesi tahmininde en yüksek başarıyı sağladığı belirlenmiştir. Benzer şekilde, IoT (nesnelerin interneti) destekli cihazlarla toplanan gerçek zamanlı veriler üzerinde yapılan analizlerde de LMT algoritmasının anne sağlığı risk seviyelerini tahmin etmede üstün performans gösterdiği görülmüştür. Bu bulgular, MÖ tabanlı yöntemlerin anne sağlığı alanında etkili ve yenilikçi çözümler sunduğunu ortaya koymaktadır.

Macrohon ve arkadaşları [12], yüksek riskli gebelikleri tahmin etmek amacıyla altı farklı makine öğrenimi algoritmasını değerlendirmiş ve bir model geliştirmişlerdir. Çalışmada, gerçek bir veri seti üzerinde Python programlama dili kullanılarak yapılan analizlerde, bu modellerin performansı 10 kat çapraz doğrulama yöntemiyle karşılaştırılmıştır. Analiz

sonuçlarına göre, entropi kriteri ve belirli hiperparametre ayarları ile modifiye edilmiş Karar Ağacı (KA) algoritması, %93.70 doğruluk oranı ile en başarılı sonuçları elde etmiştir. Bunun yanı sıra, bu algoritma, kendi kendine eğitim (self-training) modeli için temel tahmin edici olarak kullanıldığında, %30 etiketsiz test verisi üzerinde %97.01 doğruluk oranı sağlamıştır. Elde edilen bulgular, modifiye edilmiş KA algoritmasının, yüksek riskli gebeliklerin tahmin edilmesinde etkili bir çözüm sunduğunu göstermektedir. Pawar ve arkadaşları [13] geleneksel MÖ algoritmalarının anne sağlığı risk tahmini için sunduğu performansın yeterli olmadığı durumları göz önünde bulundurarak, farklı senaryolar (en kötü, ortalama ve en iyi) altında tutarlı ve güvenilir sonuçlar üretebilecek daha dayanıklı bir model geliştirmişlerdir. Model geliştirme süreci, veri ön işleme, özellik seçimi, k-katlamalı çapraz doğrulama ve geleneksel modeller ile önerilen modelin performanslarının karşılaştırılması olmak üzere dört aşamadan oluşmaktadır. Modelin dayanıklılığı, en kötü, en iyi ve ortalama senaryolardaki performansların ortalamalarının alınması suretiyle değerlendirilmiştir. Çalışmada, UCI Machine Learning Repository'den alınan bir veri seti kullanılarak sekiz farklı MÖ algoritmasının performansı analiz edilmiştir. Veri seti, %70:30 ve %60:40 oranlarında bölünmüş, ardından k-katlamalı çapraz doğrulama yöntemi ile her bir algoritma için 10 farklı deneme üzerinden yeniden örnekleme yapılmıştır. Performans ölçütleri olarak doğruluk, hata oranı, ROC eğrisi, hassasiyet, geri çağırma, gerçek pozitif oran ve yanlış pozitif oranı kullanılmıştır. Analiz sonuçları, önerilen modelin %70.21 doğruluk oranı ile geleneksel modellere kıyasla daha dayanıklı ve güvenilir olduğunu ortaya koymuş; farklı veri setleri üzerinde de tutarlı performans göstererek modelin sağlamlığını kanıtlamıştır. Bu bulgular, önerilen modelin anne sağlığı risk tahmininde daha güvenilir bir alternatif sunduğunu göstermektedir. Kambli ve Nirvana [14], Bangladeş'te gebe kadınların risk seviyelerini etkili bir şekilde izlemek ve tahmin etmek amacıyla

geliştirilen bir sistemin etkinliğini incelemiştir. Bu çalışmada, UCI veri tabanından alınan, 1014 örnek ve 7 özellik içeren bir veri seti kullanılmıştır. Gebelik risk seviyeleri düşük, orta ve yüksek olmak üzere üç kategoriye ayrılmıştır. Özellikler arasındaki ilişkiler, Pearson korelasyon analizi ile incelenmiş ve bu özelliklerin sıralaması yapılmıştır. Analizler sonucunda, gebelikte yaş, kan şekeri ve kan basıncı gibi özelliklerin belirleyici faktörler olduğu saptanmıştır. Sonrasında, bu belirleyici özelliklerin yanı sıra tüm özelliklerin kullanıldığı durumlarda, AdaBoost, Rasgele Orman (RO), K En Yakın Komşu (kNN) ve Yapay Sinir Ağları (YSA) gibi MÖ algoritmalarının anne sağlığı risk seviyesini tespit etmedeki performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, tüm özelliklerin kullanıldığı durumda AdaBoost algoritması, %96 AUC değeri ve %86 doğruluk oranı ile en yüksek performansı göstermiştir. Bu bulgular, maternal sağlıkta risk faktörlerinin analizinde MÖ algoritmalarının etkinliğini net bir şekilde ortaya koymaktadır. Ramdhani ve arkadaşları [15], anne sağlığı risk gruplarının erken evrede tespitini hedefleyen yenilikçi bir yaklaşım önermişlerdir. Bu yaklaşım, RO ve Genetik Algoritma (GA) yöntemlerinin bir kombinasyonunu kullanarak, optimum özellik ağırlık kümesini ve sınıflandırma yapılandırmasını belirlemeyi amaçlamaktadır. UCI veri tabanında yer alan “Anne Sağlığı Riski” veri seti üzerinde gerçekleştirilen analizlerde, RO algoritması kullanılarak %73.37 doğruluk elde edilmiştir. GA ile özellikler optimize edildikten sonra, doğruluk oranı %90.20’ye çıkmıştır. Yapılan t-testi sonuçları, GA’nın sınıflandırma performansını anlamlı bir şekilde artırdığını ortaya koymuştur. Bu bulgular, gebelik risk seviyelerinin erken evrede tespitinde kullanılan yöntemlerin etkinliğini vurgulamakta ve tıbbi uygulamalarda bu yöntemlerin kullanılabilirliğini desteklemektedir. Kumari [16], UCI veri tabanında yer alan ve Bangladeş’in kırsal bölgelerindeki klinikler ve hastanelerden toplanan 1014 örnek içeren veri seti üzerinden bir kadının maternal sağlık risk seviyesini MÖ algoritmaları yardımıyla tahmin eden

bir çalışma gerçekleştirmiştir. Çalışmada; yaş, kan basıncı değerleri, vücut sıcaklığı, dinlenme kalp atış hızı ve kan glikoz seviyeleri gibi risk faktörlerinin önem dereceleri belirlenerek çeşitli MÖ algoritmalarının performansları karşılaştırılmıştır. Analizler sonucunda, YSA algoritması diğer algoritmalara kıyasla üstün performans göstererek %99 doğruluk elde etmiştir. Önerilen model hamilelik sürecindeki maternal riskleri yüksek doğrulukla tahmin etme kapasitesine sahip olup, maternal sağlık risklerinin erken tespiti açısından etkin bir araç olarak değerlendirilmektedir.

Şahin ve arkadaşları [17] hamilelik sırasında karşılaşılabilecek risklerin, basit tıbbi testler ve MÖ algoritmaları yardımıyla erken aşamada tahmini üzerine bir çalışma gerçekleştirmişlerdir. Çalışma kapsamında, çeşitli MÖ algoritmalarının (Lineer Regresyon (LR), Destek Vektör Makineleri (DVM), KA, RO, KNN Çok Katmanlı Algılayıcı (ÇKA), Naive Bayes (NB), Aşırı Gradyan Arttırma (XGBoost)) performansları, veri dönüşüm teknikleri olan algoritmalara Temel Bileşenler Analizi (TBA) ve Lineer Diskriminant Analizi (LDA) ile birlikte değerlendirilmiştir. Elde edilen sonuçlar, özellikle LDA dönüşümünün, modellerin doğruluk oranlarını arttırmada etkili olduğunu göstermiştir. En yüksek doğruluk oranı, LDA dönüşümü ile KA ve KNN algoritmalarında %85 olarak elde edilmiştir. Bu bulgular, LDA dönüşümünün hamilelik risklerini tahmin etmede önemli bir katkı sağlayabileceğini ortaya koymaktadır. Mutlu ve arkadaşları [18], hamilelik sürecinde anne adayının karşılaşılabileceği hipertansiyon, kalp, akciğer ve böbrek hastalıkları gibi risk faktörlerini erken evrede tespit etmek amacıyla MÖ temelli bir model önermişlerdir. Yaş, doğum sayısı, sosyo-ekonomik düzey gibi çeşitli parametrelere bağlı olarak gelişebilecek risk faktörleri tıbbi uzmanların desteğiyle belirlenmiş ve kategorize edilmiştir. Çalışmada, bu risk faktörlerine bağlı semptomların erken tespiti için Kaggle’da yer alan “ Anne Sağlığı Riski “ veri seti kullanılarak altı farklı MÖ algoritmasının performansı karşılaştırılmıştır.

Analizlerde KA algoritmasının %89.16 doğruluk oranı ile diğer algoritmalara kıyasla en yüksek başarıyı gösterdiği tespit edilmiştir. Bu sonuçlar, önerilen modelin anne sağlığı risklerinin erken tespiti açısından etkili bir araç olduğunu ortaya koymaktadır. Wongso ve arkadaşları [19], bir annenin hamilelik sırasında düşük, orta veya yüksek risk altında olup olmadığını tespit etmek amacıyla sıralı kümeleme ve sınıflandırma tekniklerine dayalı bir hamilelik risk seviyesi tahmin modeli önermişlerdir. Önerilen modelde, K-Means kümeleme algoritması ile veriler gruplandırıldıktan sonra NB, DVM ve KNN sınıflandırma algoritmalarının performansları karşılaştırılmıştır. Analizlerde kümeleme algoritmasının eklenmesiyle özellikle KNN algoritması %79.53 doğruluk oranı ve 0.8 F1 skoru ile diğer algoritmalarından daha yüksek performans sergilemiştir. Ayrıca, kümeleme algoritmasının eklenmesi, DVM ve NB algoritmalarının doğruluk oranlarında da belirgin iyileşmeler sağlamıştır. Bunun yanı sıra, önerilen model Flask tabanlı bir web uygulamasına entegre edilerek, sağlık profesyonellerinin hamilelik risklerini gerçek zamanlı olarak tahmin etmeleri ve hasta bakımını iyileştirmeleri sağlanmıştır. Bu bulgular, sınıflandırma öncesinde yapılan kümeleme işleminin doğruluk oranlarını ve modelin genel performansını artırabileceğini göstermektedir. Togunwa ve arkadaşları [20] gebelik sırasında anne sağlığı risklerini sınıflandırmak için geleneksel MÖ ve derin öğrenme (DÖ) algoritmalarının öngörü yeteneklerini birleştiren hibrit bir model geliştirmişlerdir. Çalışmada, RO sınıflandırıcısı ve YSA tabanlı geliştirilen modelin anne sağlığı risklerini sınıflandırmadaki başarımı maksimum olasılık oylama sistemiyle değerlendirilmiştir. %75 eğitim ve %25 test oranıyla bölünmüş bir veri seti üzerinde yapılan değerlendirmede, model %95 doğruluk, %97 kesinlik ve %97 geri çağırma ile yüksek performans sergilemiştir. Bu bulgular, önerilen hibrit modelin anne sağlığı risk sınıflandırmasında doğruluk ve verimliliği artırma potansiyeline sahip olduğu göstermektedir. Tokmak [21], gebelikte anne sağlığı risk düzeyinin tahmininde

MÖ algoritmalarının performansını kapsamlı bir şekilde değerlendirmiştir. Çalışmada, UCI veri tabanındaki “Maternal Health Risk” başlıklı veri seti kullanılarak NB, KNN, KA, RO, XGBoost ve Derin Sınır Ağları (DSA) algoritmalarının performansları karşılaştırılmıştır. Farklı performans metriklerinin dikkate alındığı analizler sonucunda, en yüksek doğruluk oranı %96.88 ile KNN algoritması tarafından elde edilmiştir. Bu sonuçlar, MÖ algoritmalarının anne sağlık durumu riskinin belirlenmesinde etkili bir karar destek sistemi olarak kullanılabilceğini ortaya koymaktadır.

Thakkar ve arkadaşları [22], özellikle kırsal bölgelerde gebelik risklerini tahmininde RO, XGBoost, DVM, KA ve Çok Sınıflı LR gibi MÖ algoritmalarının performanslarını değerlendirmiştir. Çalışmanın temel amacı, çeşitli faktörler (yaş, kan şekeri, risk seviyesi, kan basıncı ve kalp atış hızı) üzerinden en doğru tahmin yöntemini belirlemek ve maternal sağlık risklerini daha hassas bir şekilde değerlendirmektir. Bu amaç doğrultusunda UCI veri tabanında yer alan anne sağlığı veri seti kullanılarak yapılan değerlendirmelerde, RO algoritması, hiperparametre optimizasyonu ile %94.26 doğruluk oranına ulaşarak en etkili model olarak belirlenmiştir. Bu yüksek doğruluk oranı, gebelikte zamanında müdahale ve kişiselleştirilmiş tedavi için önemli bir potansiyel sunmaktadır. Şenyer Yapıcı ve Uzun Arslan [23], gebelik sırasında ortaya çıkabilecek risklerin sınıflandırılması amacıyla MÖ tabanlı bir karar destek sistemi geliştirmişlerdir. Çalışmanın temel hedefi, yüksek riskli gebelikleri tespit etmek amacıyla MÖ algoritmalarının etkinliğini değerlendirerek en uygun modeli belirlemektir. Bu doğrultuda, Ki-Kare testi ve SelectKBest yöntemleri kullanılarak yaş, sistolik ve diyastolik kan basıncı gibi önemli özellikler belirlenmiş ve bu özellikler altı farklı MÖ algoritmasıyla test edilmiştir. Ayrıca, veri dengesizliklerini gidermek ve model performansını artırmak için sentetik azınlık aşırı örnekleme tekniği (SMOTE) uygulanmıştır. Analizler sonucunda, XGBoost algoritmasının %97 başarı oranı ile en yüksek performansı sağladığı tespit edilmiştir.

Elde edilen bulgular, hem özellik seçiminin hem de SMOTE tekniklerinin sınıflandırıcı performansını anlamlı ölçüde artırdığını ortaya koymaktadır. Ralhen ve Akter [24], anne sağlığıyla ilgili risklerin yoğunluk seviyesinin tahmininde MÖ algoritmalarının performanslarını değerlendirmişlerdir. Bu amaçla, UCI veri tabanında açık erişimli olarak sunulan bir veri seti kullanılarak yedi farklı MÖ algoritmasının performansı, on kat çapraz doğrulama tekniğiyle incelenmiştir. Değerlendirme sonuçlarına göre, en yüksek doğruluk %86.13 ile DVM tarafından sağlanmış ve önerilen modelin doğruluk ve verimlilik açısından diğer yöntemlerin önüne geçtiği tespit edilmiştir. Elde edilen bulgular, hamilelikle ilgili komplikasyonların önlenmesi, anne ve bebek sağlığının iyileştirilmesi ve sağlık kaynaklarının daha etkin kullanılması konusunda önemli katkılar sağlamıştır. Kaur ve Singh [25] hamilelik sırasında maternal sağlık risklerini öngörmeye yönelik yenilikçi bir yaklaşım geliştirmiştir. Kaggle'dan elde edilen veri seti üzerinde gerçekleştirilen analizler, yaş, diyastolik ve sistolik kan basıncı ile kalp atış hızının yüksek risk seviyeleri ile ilişkili olduğunu ortaya koymuştur. Çeşitli veri işleme tekniklerinin uygulandığı modellemede, %98 doğruluk oranıyla en yüksek performans DVM algoritması ile elde edilmiştir. Bu bulgular, hamile kadınların sağlık risklerinin erken tespiti ve yönetiminde veri işleme teknikleri ile güçlü sınıflandırma algoritmalarının kritik önemini bir kez daha teyit etmektedir. Rahmen ve arkadaşları [26] gebelerde sağlık risk düzeylerini doğru bir şekilde tahmin etmek amacıyla DVM algoritmasını kullanarak kapsamlı bir nicel yaklaşım sunmuşlardır. Çalışmada, verilerin dengesizliğini gidermek amacıyla uygulanan ön işleme adımlarının ardından, öngörücü modelin doğruluğunda %19'luk bir artış elde edilmiştir. Analizler glikoz seviyesi, kalp atış hızı, sistolik ve diyastolik kan basıncı gibi çeşitli değişkenleri içeren UCI veri tabanındaki bir veri seti üzerinde gerçekleştirilmiştir. Elde edilen bulgular, hamile kadınların sağlık risk düzeylerinin

tahmin edilmesinde DVM algoritmalarının önemli bir rol oynadığını ortaya koymaktadır.

Genel olarak literatürde hamilelik döneminde risk gruplarının tahminine yönelik gerçekleştirilen MÖ temelli çalışmaların sonuçlarını incelemek, mevcut araştırmanın bulgularını daha geniş bir perspektife oturtmak açısından önemlidir. Bu bağlamda Tablo 1’de 2020-2024 yılları arasında anne sağlığı üzerine yapılan çalışmalar özetlenmiştir.

Tablo 1. Gebelik Riskinin Tahmininde Kullanılan Makine Öğrenmesi Algoritmalarına Dair Literatür İncelemeleri

Çalışmalar	Veri Seti	
Ahmed ve arkadaşları [11]	Pima-Hint-Diyabet veri seti	%98 (LMT)
Macrohon ve arkadaşları [12]	Daraga belediyesi	%97.01 (KA)
Pawar ve arkadaşları [13]	UCI - Anne Sağlığı Risk Veri Seti	%70.21 (RO)
Kambli ve Nirmala [14]	UCI - Anne Sağlığı Risk Veri Seti	%86 (AdaBoost)
Ramdhani ve arkadaşları [15]	UCI - Anne Sağlığı Risk Veri Seti	%90.20 (RO ve GA)
Kumari [16]	UCI - Anne Sağlığı Risk Veri Seti	%99 (YSA)
Şahin ve arkadaşları [17]	UCI - Anne Sağlığı Risk Veri Seti	%84 (RO)
Mutlu ve arkadaşları [18]	Kaggle- Anne Sağlığı Risk Veri Seti	%89.16 (KA)
Wongso ve arkadaşları [19]	UCI - Anne Sağlığı Risk Veri Seti	%79.53 (KNN)
Togunwa ve arkadaşları [20]	UCI - Anne Sağlığı Risk Veri Seti	%95 (RO)
Tokmak [21]	UCI - Anne Sağlığı Risk Veri Seti	%96.88 (KA)
Thakkar ve arkadaşları [22]	UCI - Anne Sağlığı Risk Veri Seti	%94.26 (RO)
Yapıcı ve Uzun [23]	UCI - Anne Sağlığı Risk Veri Seti	%97 (XGBoost)
Ralhen ve Akter [24]	UCI - Anne Sağlığı Risk Veri Seti	%86.13 (DVM)
Kaur ve Singh [25]	UCI - Anne Sağlığı Risk Veri Seti	%98 (DVM)
Rahmen ve arkadaşları [26]	UCI - Anne Sağlığı Risk Veri Seti	%79 (DVM)

4. Sonuç ve Tartışma

Bu çalışma, anne sağlığı risk gruplarının belirlenmesinde MÖ algoritmalarının etkinliğini ele alan 2020-2024 yılları arasındaki literatürün kapsamlı bir incelemesini sunmaktadır. İncelenen çalışmalar, MÖ algoritmalarının hamilelik sürecinde karşılaşılabilecek risklerin erken tespiti ve yönetiminde kritik bir rol oynadığını açıkça göstermektedir. Farklı veri işleme tekniklerinin kullanımı, veri dengesizliklerinin giderilmesi ve güçlü sınıflandırma algoritmalarının uygulanması, elde edilen model performanslarını anlamlı ölçüde artırmıştır. Özellikle DVM, XGBoost ve KA gibi algoritmaların yüksek doğruluk oranlarına ulaşması, bu yöntemlerin gebelik sırasında karşılaşılan komplikasyonların erken teşhisinde ve yönetiminde kritik bir rol oynayabileceğini ortaya koymaktadır.

Elde edilen bulgular, MÖ tabanlı karar destek sistemlerinin, anne sağlığını iyileştirme, gebelik ile ilgili komplikasyonları önleme ve sağlık hizmetlerinin genel etkinliğini artırma potansiyelini güçlü bir şekilde desteklemektedir. Ancak, daha geniş veri setleri ve farklı popülasyonlarda yapılacak gelecekteki çalışmalar, bu algoritmaların genel geçerliliğini ve klinik uygulamalardaki etkinliğini artıracaktır. Bu bağlamda, MÖ tabanlı teknolojilerin anne sağlığı hizmetlerine entegrasyonu, hem yerel hem de küresel sağlık hedeflerine ulaşılmasında önemli bir adım olarak değerlendirilmektedir.

Sonuç olarak, MÖ algoritmalarının anne sağlığı risk gruplarının belirlenmesinde sağladığı faydalar, bu teknolojilerin sağlık hizmetlerinde devrim niteliğinde bir değişim yarattığını ve bu alandaki araştırmaların önemini bir kez daha teyit etmektedir. Bu derleme, MÖ tabanlı yöntemlerin etkinliğini ortaya koyarak, gelecekteki araştırmalar ve klinik uygulamalar için önemli bir referans noktası sunmaktadır.

Kaynaklar

1. Ünal, S. Y., & Deniz, Ü. (2023). Anne çocuk sağlığı ve önemi, In: *Çocuk Sağlığı ve İlk Yardım*, Deniz, Ü. Editör, Akademisyen Kitapevi A.Ş., Ankara, Türkiye, pp: 8.
2. Başar, F., & Çiçek, S. (2018). Annelerin yeterli prenatal bakım alma durumları ve etkileyen faktörler. *OPUS International Journal of Society Researches*, 9(16), 2574-2596.
3. Turan, T., Ceylan, S. S., & Teyikçi, S. (2008). Annelerin düzenli prenatal bakım alma durumları ve etkileyen faktörler. *Fırat Sağlık Hizmetleri Dergisi*, 3(9), 157-172.
4. Reyhan, F. A., & Sayiner, F. Doğum Ortamının Önemi ve İdeal Doğum Ünitesi Üzerine Bir Derleme Çalışması. *Ebelik ve Sağlık Bilimleri Dergisi*, 7(1), 176-186.
5. Yıldırım, A. D., & Şahin, N. H. (2022). Anne ölümlerinin önlenmesi: uluslararası bakım ve izlem modelleri. *Jinekoloji-Obstetrik ve Neonatoloji Tıp Dergisi*, 19(1), 1184-1191.
6. Çankaya, S., Yılmaz, S. D., Can, R., & Kodaz, N. D. (2017). Postpartum depresyonun maternal bağlanma üzerine etkisi. *ACU Sağlık Bilimleri Dergisi*, 2017(4), 232-240
7. WHO. (2019). Maternal Mortality, World Health Organization.
8. World Health Organization. (2020). Newborns: improving survival and well-being.
9. World Health Organization. (2023). *Trends in maternal mortality 2000 to 2020: estimates by WHO, UNICEF, UNFPA, World Bank Group and UNDESA/Population Division*. World Health Organization.
10. Raihen, M. N., & Akter, S. (2024). Comparative Assessment of Several Effective Machine Learning Classification Methods for Maternal Health Risk. *Computational Journal of Mathematical and Statistical Sciences*, 3(1), 161-176.
11. Ahmed, M., Kashem, M. A., Rahman, M., & Khatun, S. (2020). Review and analysis of risk factor of maternal health in remote area using the Internet of Things (IoT). In *InECCE2019: Proceedings of the 5th International Conference on Electrical, Control & Computer Engineering, Kuantan, Pahang, Malaysia, 29th July 2019* (pp. 357-365). Springer Singapore.
12. Macrohon, J. J. E., Villavicencio, C. N., Inbaraj, X. A., & Jeng, J. H. (2022). A semi-supervised machine learning approach in predicting high-risk pregnancies in the Philippines. *Diagnostics*, 12(11), 2782.
13. Pawar, L., Malhotra, J., Sharma, A., Arora, D., & Vaidya, D. (2022, August). A robust machine learning predictive model for maternal health risk. In *2022 3rd international conference on electronics and sustainable communication systems (ICESC)* (pp. 882-888). IEEE.
14. Kambli, R. S. (2022). Nirmala, "Model for Predicting Risk Levels in Maternal Healthcare." *Int. J. Adv. Res. Innov. Ideas Educ*, 8(6), 1633-1637.

15. Ramdhani, Y., Maulidia, D., Setiadi, A., & Alamsyah, D. P. (2022, November). Feature Weighting Optimization: Genetic Algorithms and Random Forest for Classification of Pregnant Potential Risk. In *2022 International Conference on Information Technology Research and Innovation (ICITRI)* (pp. 95-100). IEEE.
16. Kumari, D. Maternal Health Risk Prediction Model Using Artificial Neural Network. In *Soft Computing Techniques in Connected Healthcare Systems* (pp. 277-289). CRC Press.
17. Şahin, F., Tulum, G., & Karaca, Ş. (2023). Anne Sağlığı Riski İçin Makine Öğrenmesi Modellerinin Performans Karşılaştırması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 14(4), 547-553.
18. Mutlu, H. B., Durmaz, F., Yücel, N., Cengil, E., & Yıldırım, M. (2023). Prediction of maternal health risk with traditional machine learning methods. *Naturengs*, 4(1), 16-23.
19. Wongso, B. P., Johan, M. E., & Fianty, M. I. (2023). Empowering Pregnancy Risk Assessment: A Web-Based Classification Framework with K-Means Clustering Enhanced Models. *Journal of Information Systems and Informatics*, 5(4), 1221-1239.
20. Togunwa, T. O., Babatunde, A. O., & Abdullah, K. U. R. (2023). Deep hybrid model for maternal health risk classification in pregnancy: synergy of ANN and random forest. *Frontiers in Artificial Intelligence*, 6, 1213436.
21. Tokmak M. 2023. Anne sağlık durumu riskinin makine öğrenmesi yöntemleri ile belirlenmesi, In: *Müh Alanında Akademik Analiz ve Tartışmalar*, Bozdemir M., Arslan R. U. Editörler, Özgür Yayınları, Gaziantep, Türkiye, pp: 75.
22. Thakkar, D., Gandhi, V. C., & Trivedi, D. (2024, April). Forecasting Maternal Women's Health Risks using Random Forest Classifier. In *2024 International Conference on Inventive Computation Technologies (ICICT)* (pp. 961-965). IEEE.
23. Yapıcı, İ. Ş., & Arslan, R. U. Gebelikte Anne Sağlığı Risk Gruplarının Tahminine Yönelik Makine Öğrenmesi Tabanlı Bir Karar Destek Sistem Tasarımı. *Black Sea Journal of Engineering and Science*, 7(3), 33-34.
24. Raihen, M. N., & Akter, S. (2024). Comparative Assessment of Several Effective Machine Learning Classification Methods for Maternal Health Risk. *Computational Journal of Mathematical and Statistical Sciences*, 3(1), 161-176.
25. Kaur, N., & Singh, N. (2024, July). Maternal health analysis using ensemble learning techniques. In *AIP Conference Proceedings* (Vol. 3168, No. 1). AIP Publishing.
26. Rahman, M. A., Noor, R. M., Mallik, S., Santa, N. K., Deb, S., & Pathak, A. Classification of Health Risk Levels For Pregnant Women Using Support Vector Machine (SVM) Algorithm. *IOSR Journal of Computer Engineering (IOSR-JCE)*, 26 (3), 07-17.