



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 08.08.2024
Kabul Tarihi : 07.11.2024

Received Date : 08.08.2024
Accepted Date : 07.11.2024

RADYOMİK ÖZELLİKLER VE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE MEME TÜMÖRLERİNİN SINIFLANDIRILMASI

CLASSIFICATION OF BREAST TUMORS USING RADIOMIC FEATURES AND MACHINE LEARNING TECHNIQUES

*Asuman KAPLAN*¹ (ORCID: 0009-0004-9357-1773)
*Esra KAVADAR*² (ORCID: 0009-0005-9548-7548)
Mehmet Ali ALTUNCU^{3*} (ORCID: 0000-0002-2948-3937)

^{1,2,3} Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet Ali ALTUNCU, mehmetali.altuncu@kocaeli.edu.tr

ÖZET

Meme kanseri, dünya genelinde kadınlar arasında en sık görülen kanser türüdür ve erken teşhis, tedavi başarısını önemli ölçüde artırmaktadır. Bu çalışmada, meme ultrason görüntülerinden iyi huylu ve kötü huylu tümörleri sınıflandırmak amacıyla radyomik özellikler ve makine öğrenmesi teknikleri kullanılmıştır. Çalışmada, halka açık BUSI veri seti kullanılmıştır. Sadece iyi huylu ve kötü huylu olarak etiketlenmiş görüntüler sınıflandırmada kullanılmış olup, normal etiketli görüntüler çalışmaya dahil edilmemiştir. Bu yaklaşım, modelin iki sınıf arasındaki ayrımı en yüksek doğrulukla yapmasına odaklanmıştır. Veri setindeki dengesizlik, kötü huylu tümörlerin görüntülerinin y ekseninde aynalanarak artırılmasıyla giderilmiştir. PyRadiomics kütüphanesi ile çıkarılan 123 radyomik özellik arasından, özellik önem skoru ve korelasyon matrisi kullanılarak en önemli 40 özellik seçilmiştir. Sınıflandırma aşamasında XGBoost, Gradient Boosting, AdaBoost, SVM, Random Forest ve Decision Tree algoritmaları uygulanmış, en yüksek doğruluk oranı (%98,13) Gradient Boosting algoritması ile elde edilmiştir.

Anahtar Kelimeler: Makine öğrenmesi, meme kanseri, radyomik özellikler, tümör sınıflandırma.

ABSTRACT

Breast cancer is the most common type of cancer among women worldwide, and early diagnosis significantly increases the success of treatment. In this study, radiomic features and machine learning techniques were used to classify benign and malignant tumors from breast ultrasound images. The publicly available BUSI dataset was used in the study. Only images labeled as benign and malignant were used in the classification, and normal labeled images were not included in the study. This approach focused on the model distinguishing between the two classes with the highest accuracy. The imbalance in the dataset was eliminated by mirroring and augmenting the images of malignant tumors in the y-axis. Among the 123 radiomic features extracted with the PyRadiomics library, the most important 40 features were selected using feature importance scores and correlation matrix. XGBoost, Gradient Boosting, AdaBoost, SVM, Random Forest and Decision Tree algorithms were applied in the classification phase, and the highest accuracy rate (98.13%) was obtained with the Gradient Boosting algorithm.

Keywords: Machine learning, breast cancer, radiomics, tumor classification.

GİRİŞ

Meme kanseri, genellikle meme dokusunda başlar ve zamanla vücudun diğer bölgelerine yayılabilir. Kadınlarda en yaygın görülen kanser türlerinden biri meme kanseridir. Dünya genelinde ise akciğer tümörlerinden sonra, en sık teşhis edilen ikinci tümör türü olarak kabul edilmektedir (Jabeen vd., 2022). 2022 yılında, dünya genelinde yaklaşık

ToCite: KAPLAN, A., KAVADAR, E., & ALTUNCU, M. A. (2025). RADYOMİK ÖZELLİKLER VE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE MEME TÜMÖRLERİNİN SINIFLANDIRILMASI.

Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 28(1), 38-50.

2.3 milyon kadına meme kanseri tespiti koyulmuş ve 670 bin kişinin ölümüne neden olmuştur (WHO, 2024). Bu rakamlar, meme kanserinin ne kadar yaygın bir sağlık sorunu olduğunu ve erken teşhisin önemini vurgulamaktadır.

Meme kanseri tümörleri, iyi ve kötü huylu olmak üzere iki ana kategoriye ayrılır. İyi huylu tümörler genellikle sağlığa ciddi bir tehdit oluşturmaz ve nadiren insanlarda ölüme yol açar. Bu tür tümörler sınırlı bir büyüme kapasitesine sahiptir ve sadece vücudun belirli bir bölgesinde gelişir. Genellikle yavaş büyürler ve çevre dokulara yayılmazlar, bu da onları tedavi edilmesi daha kolay ve genellikle daha az tehlikeli kılar. Öte yandan, kötü huylu tümörler çok daha tehlikelidir ve uygun tedavi edilmezse bir kişinin hayatını tehdit edebilir. Bu tür tümörlerdeki hücreler, kontrolsüz ve anormal bir şekilde hızla çoğalır. Kötü huylu tümörler, çevre dokulara yayılabilir ve metastaz yaparak vücudun diğer bölgelerine sıçrayabilir, bu da hastalığın tedavisini daha zor ve karmaşık hale getirir. Bu nedenle, kötü huylu tümörlerin erken teşhis ve tedavisi, hastanın hayatta kalma şansını önemli ölçüde artırır (Assiri vd., 2020).

Meme kanserinin taranmasında genellikle mamografi, ultrasonografi ve manyetik rezonans görüntüleme (MRI) yöntemleri tercih edilmektedir. Mamografi, düşük dozda X-ışını kullanarak meme dokusunun görüntülenmesini sağlar ve erken evre kanserlerin tespitinde oldukça etkili bir tarama yöntemidir. Ancak, genç kadınlarda sıkça görülen yoğun meme dokusu, mamografinin duyarlılığını azaltabilir ve bu durum tanıların atlanmasına yol açabilir. Bu durumda, ultrasonografi, ses dalgaları kullanarak meme dokusunu detaylı bir şekilde görüntüleyerek, mamografide belirsiz kalan kitleleri netleştirebilir ve tümör tespitinde daha yüksek bir duyarlılık sağlar. MRI ise, yüksek çözünürlükte ve ayrıntılı görüntüler sunarak, özellikle yoğun meme dokusu ve yüksek riskli hastalarda etkili bir tarama seçeneği sunar. Ancak, MRI'nın yüksek maliyeti ve zaman alıcı olması, genellikle birincil tarama aracı olarak tercih edilmemesine yol açmaktadır (Sun vd., 2018, Aristokli vd., 2022).

Radyomik, tıbbi görüntülerden özelliklerin otomatik olarak çıkarılması ve analiz edilmesi yöntemidir. Bu özellikler, hastalıkların tanısında, prognozda ve tedavi yanıtının tahmininde önemli bir rol oynamaktadır. Görüntülerde gözle fark edilemeyen ayrıntıları ve örüntüleri ortaya çıkaran radyomik, kişiselleştirilmiş tıp ve tedavi planlamasında değerli bir araç olarak kabul edilmektedir. Özellikle onkoloji alanında, makine öğrenimi ve yapay zeka gibi ileri analiz yöntemleriyle birleştirildiğinde, radyomik çok daha kapsamlı ve faydalı bilgiler sağlayabilir (Kumar vd., 2012).

Radyomik özellik çıkarımı, LIFEx (LIFEx, n.d.), MITK (Medical Imaging Interaction Toolkit, n.d.), CERR (CERR, n.d.) ve PyRadiomics (Van Griethuysen vd., 2017) gibi açık kaynaklı yazılım araçları kullanılarak gerçekleştirilir. Bu yazılımlar, görüntülerden sayısal özelliklerin otomatik olarak çıkarılmasını sağlar. Kullanılan yazılım aracılığıyla, segment edilmiş tümör bölgesinden şekil, yoğunluk, doku ve türetilmiş özellikler gibi veriler elde edilir. Çıkarılan özellikler, çeşitli algoritmalar tarafından analiz edilerek görüntülerdeki yeni örüntüler ve ilişkiler ortaya konur. Bu süreç, tanı ve prognoz için önemli olabilecek yeni bilgilerin elde edilmesini sağlar (Zhang vd., 2023).

Geleneksel meme kanseri değerlendirme yöntemleri genellikle niteliksel olup subjektif değerlendirmelere dayanır, bu da bazı durumlarda tümörlerin doğru şekilde tespit edilmesini zorlaştırabilir. Radyomik analizler ise, görüntülerden detaylı özellikler çıkararak tümörlerin mikroskobik özelliklerini daha hassas bir şekilde değerlendirme imkanı sunar. Bu sayısal veriler, makine öğrenmesi veya derin öğrenme algoritmalarıyla birleştirilerek, iyi ve kötü huylu tümörlerin sınıflandırılmasında kullanılabilir (Pesapane vd., 2023).

Literatürdeki çalışmaların büyük çoğunluğu, meme tümörlerinin varlığının belirlenmesi ve sonrasında iyi veya kötü huylu olarak sınıflandırılmasını bir arada ele almaktadır. Bu çalışmada ise yalnızca mevcut tümörlerin iyi veya kötü huylu olarak doğru bir şekilde sınıflandırılmasına odaklanılmıştır. Bu yaklaşım ile tanı sürecinin daha hassas bir şekilde gerçekleştirilmesi sağlanarak, tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesi hedeflenmektedir. Ayrıca, veri setindeki sınıf dengesizliği veri artırma teknikleri ile giderilmiş ve dengelenmiş veri seti kullanılarak model performansının optimize edilmesi amaçlanmıştır. Bu doğrultuda, radyomik özelliklerin meme tümörleri sınıflandırmasında daha verimli kullanımı sağlanmıştır. Elde edilen sonuçların, etkili tedavi stratejilerinin geliştirilmesinde kritik bir rol oynayacağı öngörülmektedir.

Makalenin geri kalanı şu şekilde yapılandırılmıştır: İlk bölümde, meme kanseri tespiti için son dönemde yapılan çalışmalar hakkında bilgi verilmiştir. İkinci bölümde, kullanılan veri seti ve önerilen yöntemler açıklanmıştır. Üçüncü bölümde, deneysel çalışma sonuçları detaylandırılmıştır. Sonuçlar ve tartışma bölümünde ise, elde edilen bulgular değerlendirilmiş ve gelecekteki araştırmalar için potansiyel yönler üzerinde durulmuştur.

İLGİLİ ÇALIŞMALAR

Literatürdeki çalışmalar incelendiğinde, meme kanserinin tespiti için klasik makine öğrenmesi, derin öğrenme ve bu iki yöntemin birlikte kullanıldığı hibrit yöntemlerin önerildiği görülmektedir.

Mishra vd. (2021), meme kanserlerinin malignitesini tahmin etmek amacıyla ultrason görüntülerini kullanarak etkili bir makine öğrenmesi (ML) ve radyomik tabanlı sınıflandırma yöntemi önermişlerdir. BUSI veri setindeki veri dengesizliği sorununu ele almak için SMOTE tekniği uygulanmıştır. Görüntülerden çeşitli bölgesel özellikler çıkarılarak radyomik özellikler elde edilmiştir ve sınıflandırma sürecinde en yüksek doğruluk oranı %97,4 ile AdaBoost algoritması kullanılarak sağlanmıştır. Çapkan vd. (2022), meme kanseri tespiti için K-Nearest Neighbors (KNN), Decision Tree (DT), Support Vector Machine (SVM) ve hibrit yöntemlerden oluşan bir mimari kullanmışlardır. Çalışmada, iyi huylu ve kötü huylu sınıflarına ait toplam 647 ultrason görüntüsü ve 133 normal ultrason görüntüsünden oluşan bir veri seti kullanmışlardır. Fisher Score algoritması ile özellik seçimi yapılmış ve toplam 25 özellik elde edilmiştir. Deneysel sonuçlar, önerilen yöntemin %99.24 doğruluk oranı ile sınıflandırma işlemini gerçekleştirdiğini göstermektedir. Ghabrim vd. (2023), meme ultrason görüntülerini segmentlere ayırarak iyi huylu veya kötü huylu olarak sınıflandırmayı hedeflemiştir. Görüntü ön işleme aşamasında, görüntülerin kalitesini artırmak için parlaklık ve kontrast ayarları, gürültü azaltma ve kenar keskinleştirme yöntemleri kullanılmıştır. Ayrıca, Canny, Laplacian ve Sobel gibi kenar belirleme filtreleri de uygulanmıştır. Veriler bu ön işlem aşamalarından geçirildikten sonra, U-Net modeli yardımıyla meme kanseri ultrason görüntüleri segmentlere ayrılmıştır. Meme lezyonlarını iyi ve kötü huylu olarak sınıflandırmak için ise KNN, Random Forest (RF), DT ve SVM gibi geleneksel yöntemler kullanılmıştır. Bu yöntemler arasında en yüksek doğruluk oranı %86 ile KNN yöntemi kullanılarak elde edilmiştir. Şenol & Kaya (2024), meme kanseri sınıflandırmasında gürültülü verilerdeki aykırı değerleri tespit etmek için kümeleme tabanlı iki aşamalı bir yöntem önermişlerdir. İlk aşamada, veri ön işleme sürecinde beş farklı kümeleme algoritması karşılaştırılmış ve bu algoritmalarından en yüksek performans, sınıflama aşamasında kullanılan KNN algoritması ile %98.34 doğruluk değeri elde edilmiştir. Ara vd. (2021), iyi ve kötü huylu tümörlerin tespitinde beş farklı klasik makine öğrenmesi yönteminin etkinliğini değerlendirmiştir. Çalışmada, halka açık Wisconsin Meme Kanseri veri seti kullanılmıştır. Elde edilen bulgular, RF ve SVM yöntemlerinin, %96.5 doğruluk oranı ile diğer yöntemlerden daha üstün performans sergilediğini göstermiştir.

Badawy vd. (2021), meme ultrason görüntülerinden meme kanseri tespiti için on adet tanınmış önceden eğitilmiş CNN (Convolutional Neural Network) sınıflandırma modelleri arasında karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Çalışma sonucunda, giriş görüntülerinin net ve kontrastı yüksek olduğunda ResNet101 modelinin %96.27 ile en iyi doğruluk oranına sahip olduğu belirtilmiştir. Bota vd. (2024), meme ultrason görüntülerinden meme kitlelerini sınıflandırmak için transfer öğrenme yöntemlerini kullanarak çok örnekli sınıflandırma gerçekleştirmeyi amaçlamıştır. Çalışmada özellik çıkarımı için InceptionResNetV2, MobileNetV2, InceptionV3 ve ResNet50 gibi çeşitli CNN mimarileri kullanılmıştır. Verilerdeki dengesizlikleri gidermek için alt örnekleme yöntemleri uygulanmış ve önceden eğitilmiş mimarilerle ince ayar yapılmıştır. Araştırma sonuçlarına göre, MobileNetV2 ile çıkarılan özellikler ile %84 doğruluk oranına ulaşıldığı belirtilmiştir. Liu vd. (2022), meme kanseri teşhisi amacıyla 600 kadın hastanın görüntülerini içeren açık kaynak bir veri seti üzerinde çalışmışlardır. Veri setinde özellik çıkarımı için ızgara (grid) tabanlı derin özellik oluşturuç kullanılmıştır. Özellik çıkarma işleminin karmaşıklığını azaltmak için ultrasonik görüntüler satır ve sütunlara bölünmüştür ve bunun sonucunda özellik çıkarılması için 10 adet ızgara elde edilmiştir. Özellik seçimi aşamasında ise 16 önceden eğitilmiş CNN mimarileri kullanılarak 9000 özellik çıkarılmış, Neighborhood Component Analysis (NCA) kullanılarak bu özelliklerden en iyileri seçilmiştir. Model seçimi aşamasında, SVM ile hesaplanan hata değerleri kullanılarak en uygun modeller seçilmiştir. Bu modellerle oluşturulan özellik vektörleri, derin sinir ağı (DNN) kullanılarak sınıflandırılmıştır. Deneysel sonuçlara göre, ResNet101, MobileNetV2 ve EfficientNetb0 modellerinden elde edilen özelliklerin, %97.18 doğruluk oranıyla diğer modellere kıyasla daha yüksek doğruluk sağladığı belirtilmiştir.

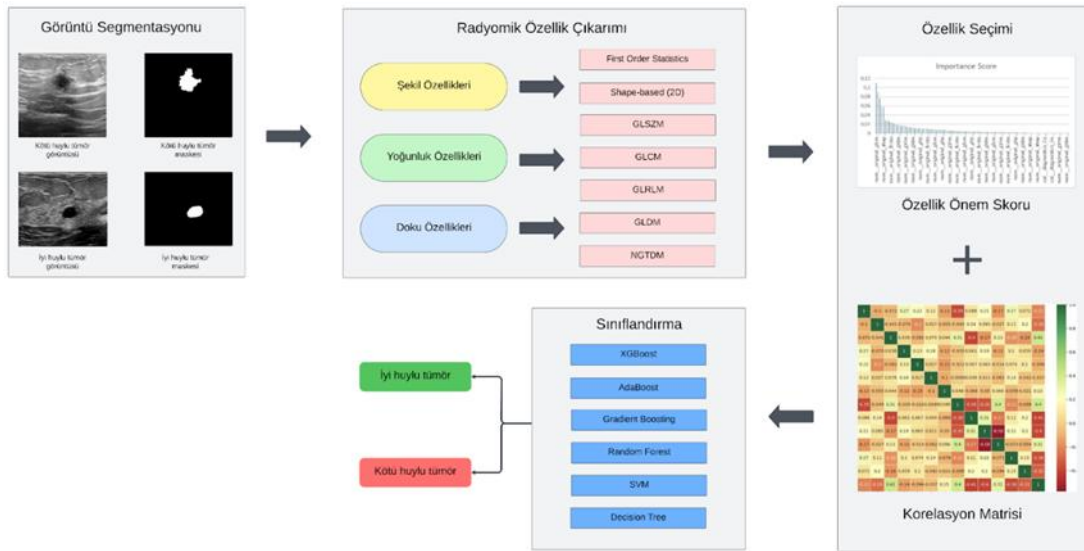
Eroğlu vd. (2021), meme kanseri kitlelerinin iyi huylu, kötü huylu ve normal olarak sınıflandırılması için hibrit tabanlı bir CNN sistemi geliştirmiştir. Bu çalışmada, özneliklerin birleştirilmesi için AlexNet, ResNet50 ve MobileNetV2 olmak üzere üç farklı CNN modeli kullanılmıştır. Sınıflandırma aşamasında, en yüksek doğruluk oranı %95.6 ile SVM yöntemi kullanılarak elde edilmiştir. Paurasad vd. (2021), ultrason görüntülerinden meme tümörlerini tespit etmek için geleneksel makine öğrenmesi ve özgün bir CNN mimarisinden oluşan altı farklı yöntemi karşılaştırmışlardır. Ayrıca, önerilen CNN modeli, eğitim ve deneysel setlerde %99.7 doğruluk oranı sağlamıştır. Deneysel sonuçlar, meme tümörlerinin teşhisinde yüksek potansiyele sahip bir CNN algoritmasının kullanılabilirliğini ortaya koymuştur. Khanna vd. (2021), derin öğrenme, optimizasyon ve makine öğrenmesi

tekniklerini birleştiren bir hibrit yaklaşım önermişlerdir. Çalışmada tümörlerin iyi huylu, kötü huylu ve normal olarak sınıflandırılması amaçlanmıştır. Özellik çıkarımı adımı için bir CNN modeli olan ResNet-50, özellik seçimi adımı için BGWO (Binary Gray Wolf Optimization) algoritması, sınıflandırma için ise SVM yöntemi kullanılmıştır. Özellik seçimi algoritmasının kullanımı ile önerilen modelde %84.9 sınıflama doğruluğu sağlanmış ve işlem süresinde yaklaşık dört kat iyileşme elde edilmiştir. Lanjewar vd. (2024), transfer öğrenme ve derin öğrenme modellerinin meme kanseri teşhisindeki etkinliğini değerlendirmeyi amaçlamışlardır. Çalışmada önerilen model, MobileNetV2, ResNet50 ve VGG16 gibi transfer öğrenme yöntemleri ile Long Short-Term Memory (LSTM) yöntemini birleştiren hibrit bir yaklaşıma dayanmaktadır. Çalışmada ayrıca, sentetik azınlık aşırı örnekleme (SMOTE) ve Tomek yöntemi (SMOTETomek) kullanılarak az sayıdaki veri noktasına sahip olan özelliklerin oranları artırılmıştır. Sonuçlar incelendiğinde, VGG16 yöntemi ile %96 F1 skoru elde edildiği gözlemlenmiştir. Rashid vd. (2022), meme tümörü sınıflandırmasında radyomik özellikler ve derin öğrenme yöntemlerinin karşılaştırılması için iki farklı yaklaşım önermişlerdir. İlk yöntemde, 111 tümör lezyonundan türetilen 74 radyomik özellik, SVM algoritmasının çeşitli kernel'leri kullanılarak sınıflandırılmış ve maksimum %97.06 doğruluk elde edilmiştir. İkinci yöntemde ise, CNN ve SVM yöntemlerinin birleşiminden oluşan hibrit bir yaklaşım uygulanmış ve %95.28 doğruluk sağlanmıştır.

Literatürdeki birçok çalışma, tümör tespiti ve sınıflandırmasını bir arada ele alırken, bu çalışmada yalnızca tümör olduğu bilinen örneklerin iyi huylu veya kötü huylu olarak doğru şekilde ayrılması hedeflenmiştir. Bu yaklaşım, teşhis sürecine odaklanarak tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesini amaçlamaktadır.

ÖNERİLEN YÖNTEM

Çalışma kapsamında önerilen meme tümörü sınıflandırılması modelinin genel mimarisi Şekil 1'de gösterilmektedir. Önerilen model dört temel aşamadan oluşmaktadır. İlk aşamada, veri setindeki sınıflar arasındaki dengesizliğin üstesinden gelebilmek için maskelenmiş görüntüler üzerinde aynalama tekniği uygulanmıştır. İkinci aşamada, maskelenmiş görüntülerden, açık kaynaklı bir Python kütüphanesi olan PyRadiomics aracılığıyla 123 adet radyomik özellik çıkarılmıştır. Üçüncü aşamada, elde edilen 123 özelliğten en önemlilerinin belirlenmesi için önemlilik skoru ve korelasyon analizi yöntemleri uygulanarak sınıflandırma işlemi öncesi 40 özellik belirlenmiştir. Son aşamada ise tümörün iyi veya kötü huylu olarak sınıflandırılması için 6 makine öğrenmesi yönteminin (XGBoost, Gradient Boosting, AdaBoost, SVM, RF ve DT) performansları karşılaştırılmıştır.

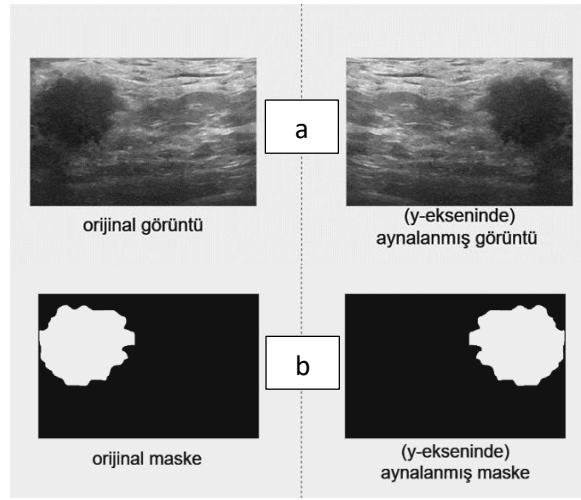


Şekil 1. Genel Sistem Mimarisi

Veri Seti

Çalışma kapsamında Kaggle'da bulunan, meme kanseri teşhisi ve tümör sınıflandırması için kullanılan ultrason görüntüleri içeren BUSI veri seti (Al-Dhabyani vd., 2020) kullanılmıştır. 2018 yılında Baheya hastanesinde 25-75 yaş arası 600 kadından toplanan ve 780 meme ultrason görüntüsünden oluşan veri seti, normal, iyi huylu ve kötü huylu olarak üç sınıfa ayrılmıştır. Bu çalışmanın amacı, meme ultrason görüntülerinden iyi huylu ve kötü huylu tümörleri sınıflandırmak olduğundan, veri setindeki normal etiketli görüntüler eğitim ve test aşamalarında

kullanılmamıştır. Başlangıçta DICOM formatında olan görüntüler, DICOM dönüştürücü kullanılarak PNG formatına çevrilmiş ve ortalama 500×500 piksel boyutundadır. BUSI veri setinin en önemli özelliği, her görüntüye ait maskelerin de dahil edilmesidir. Bu maskeler, kötü huylu vakalarda tümör bölgelerini hassas bir şekilde belirler. Maskelerin varlığı, bilgisayarlı destekli tarama sistemlerinin eğitilmesi için oldukça değerlidir. Bu sayede sistemler, ultrason görüntülerindeki belirli bölgelere odaklanabilir ve bu sayede kanser teşhis doğruluğu potansiyel olarak artırılabilir. Veri setinde iyi huylu tümör sınıfında 437 adet ve kötü huylu tümör sınıfında 210 adet görüntü bulunduğundan, görüntüler üzerinden veri dengesizliği sorununu çözmek için Şekil 2.a ve Şekil 2.b'deki gibi, kötü huylu tümör sınıfına y-ekseninde aynalama tekniği uygulanmıştır. Y-ekseni boyunca aynalama yöntemi, tıbbi görüntülerin özel niteliklerini korumak açısından kritik bir öneme sahiptir. Bu yöntem, tıbbi görüntülerde dikey yansıma değişmezliğini sağlayarak modelin performansını artırır. Ayrıca, doğal görüntülerde genellikle tercih edilen yatay aynalamanın ötesinde, gerçekçi kitle görüntüleri elde edilmesine yardımcı olur (Hussain vd., 2018). Aynalama işlemi sonrasında veri setindeki toplam görüntü sayısı 857'ye ulaşmıştır.



Şekil 2. a. Orijinal Görüntüye Aynalama Tekniği Uygulanması b. Maskelenmiş Görüntüye Aynalama Tekniği Uygulanması

Özellik Çıkarma

Radyomik özellikler, MR ve bilgisayarlı tomografi gibi tıbbi görüntülerden otomatik olarak çıkarılan ve tümörlerin biyolojik yapısını nicel olarak tanımlayan verilerdir. Bu özellikler, tümörlerin şekil, doku yapısı ve yoğunluk dağılımı gibi mikroskobik düzeydeki detaylarını ortaya çıkararak, hastalıkların teşhisi, tedavi yanıtının tahmini ve prognoz belirlemesi gibi klinik karar verme süreçlerinde önemli bir katkı sağlar (Zhang vd., 2022). Radyomik özellikler, şekil, yoğunluk ve doku özellikleri gibi ana kategorilere ayrılmakta olup, bu kategorilerin altında ikinci ve daha yüksek dereceden özellikler de yer almaktadır.

Şekil özellikleri, tümörün geometrik yapısını (boyut, hacim, şekil) tanımlar ve maksimum çap, yüzey-hacim oranı gibi çeşitli parametreleri içerir. Yoğunluk özellikleri, piksel veya voxel değerlerinin istatistiksel dağılımını ölçer ve histogram analizi kullanılarak ortalama, maksimum, minimum, standart sapma gibi parametreler hesaplanır. Doku özellikleri ise piksellerin veya voxel'lerin düzenlenme biçimlerini ve bu düzenlemelerin istatistiksel özelliklerini içerir (Rizzo vd., 2018). İkinci ve daha yüksek dereceden özellikler, voxeller arasındaki mekansal ilişkileri değerlendirir ve enerji, entropi, homojenlik gibi dokusal parametreleri hesaplayarak doku paternlerinin karmaşıklığını belirler. Bu özellikler, özellikle tümörlerin heterojenliğini değerlendirmede önemli bir rol oynar (Zhang vd., 2022).

Bu çalışmada, meme ultrason görüntülerinden radyomik özelliklerin çıkarılması için açık kaynaklı bir Python kütüphanesi olan PyRadiomics kullanılmıştır. PyRadiomics, kullanıcıların özelleştirilebilir parametrelerle birçok farklı radyomik özelliği çıkarmasına olanak tanır (Van Griethuysen vd., 2017). Hem açık kaynaklı olması hem de istatistiksel güvenilirlik sağlaması nedeniyle tercih edilmiştir (Fornacon-Wood vd., 2020). Çalışmamızda, görüntülerle birlikte her bir görüntüye ait maske dosyaları kullanılarak toplamda 123 radyomik özellik çıkarılmıştır. Bu özellikler, tümörlerin doku yapısını, şekil bozukluklarını ve yoğunluk farklılıklarını daha hassas bir şekilde tanımlayarak, meme kanseri sınıflandırmasında kullanılan makine öğrenmesi algoritmalarına zengin veri sağlamıştır.

Çıkarılan bu özellikler, daha sonra analiz ve modelleme süreçlerinde kullanılmak üzere bir .csv dosyasına kaydedilmiştir.

Özellik Seçimi

Bu çalışmada, özellik seçimi için iki aşamalı bir yaklaşım benimsenmiştir: önemlilik skoru ve korelasyon matrisi. İlk aşamada, Scikit-learn kütüphanesi kullanılarak farklı sınıflandırıcılar için feature_importances_ veya coef_ öznelikleri aracılığıyla özelliklerin önem düzeyleri hesaplanmıştır. Bu sınıflandırıcılardan elde edilen önem skorları birleştirilerek her bir özellik için ortalama bir önemlilik skoru oluşturulmuştur. İkinci aşamada ise, Pandas kütüphanesi kullanılarak her bir özelliğin diğer özelliklerle olan ortalama korelasyonu hesaplanmış, bu da özellikler arasındaki bağımsızlık derecesini yansıtmıştır. Üçüncü aşamada, ilk iki aşamada elde edilen ortalama önemlilik skoru ve ortalama korelasyon değerleri matematiksel olarak birleştirilerek her bir özellik için bileşik bir puan hesaplanmıştır. Özelliklerin önemlilik skorları incelendiğinde, 0.02 değerinin üzerindeki ve altındaki özellikler arasında diğerlerine göre belirgin bir fark olduğu gözlemlenmiş ve bu nedenle eşik değer olarak 0.02 belirlenmiştir. Bu eşik değere göre özellikler sıralanmış ve bileşik puanı 0.02'nin üzerinde olan 40 özellik, 123 radyomik özellik arasından sınıflandırma işleminde kullanılmak üzere seçilmiştir. Böylece, daha az ancak etkili özelliklerle model eğitimi yapılarak hem hesaplama maliyeti hem de eğitim süresi önemli ölçüde azaltılmış ve daha verimli bir model elde edilmiştir. Tablo 1'de seçilen özelliklerin bir kısmı ve bu özelliklere karşılık gelen bileşik puan değerleri verilmiştir.

Tablo 1. Özellik Seçimi Aşamasından Sonra Seçilen Radyomik Özellikler ve Birleşik Puan Değerleri

| Sıra | Radyomik Özellik Adı | Birleşik Puan Değeri | Sıra | Radyomik Özellik Adı | Birleşik Puan Değeri |
|------|---|----------------------|------|---|----------------------|
| 1 | original_shape2D_PixelSurface | 0,109 | 6 | original_glrIm_GrayLevelNon Uniformity | 0,052 |
| 2 | original_gldm_DependenceEntropy | 0,082 | . | | |
| 3 | original_glrIm_ShortRunHighGrayLevel Emphasis | 0,069 | . | | |
| 4 | original_glrIm_RunEntropy | 0,065 | 39 | original_firstorder_MeanAbsolute Deviation | 0,0207 |
| 5 | original_glcM_Idn | 0,053 | 40 | original_glszm_LargeAreaLowGray LevelEmphasis | 0,0205 |
| | | | 41 | original_glszm_SmallAreaEmphasis | 0,0188 |

Makine Öğrenmesi

Bu çalışmada, veri setindeki radyomik özellikler kullanılarak iyi ve kötü huylu tümörlerin sınıflandırılmasında XGBoost, Gradient Boosting, AdaBoost, SVM, DT ve RF algoritmalarından yararlanılmıştır. Scikit-learn kütüphanesi kullanılarak veriler, %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Modellerin performansını optimize etmek amacıyla, hiperparametreler GridSearch yöntemi ile belirlenmiştir. GridSearch, belirtilen hiperparametrelerin çeşitli kombinasyonlarını deneyerek çapraz doğrulama yöntemi ile en iyi parametre kombinasyonunu seçer. Bu yöntem, aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) risklerini azaltır ve modelin genelleme yeteneğini artırarak daha doğru tahminler yapmasını sağlar (Adnan vd., 2022).

XGBoost Algoritması

Tianqi Chen tarafından geliştirilen XGBoost (Extreme Gradient Boosting), gradient boosting framework'üne dayanan yüksek performanslı bir açık kaynak makine öğrenimi algoritmasıdır (Chen & Guestrin, 2016). XGBoost'un temel amacı, mevcut modelin hatalarını minimize edecek yeni modeller oluşturmaktır. İlk aşamada basit bir modelle tahmin yapılır ve bu modelin hataları (rezidüel) hesaplanır. Daha sonra, bu hataları azaltmaya yönelik olarak yeni karar ağaçları eklenir. Her eklenen karar ağacı, önceki modelin hatalarını öğrenir ve bu hataları gidermeye çalışır. Bu işlem, hatalar belirli bir seviyeye düşene veya belirli sayıda karar ağacı eklenene kadar devam eder. XGBoost, L1 ve L2 düzenleme teknikleriyle aşırı öğrenmeyi engeller ve paralel işleme, bellek optimizasyonları ile donanım hızlandırmaları sayesinde hızlı ve verimli çalışır. Algoritma, regresyon, sınıflandırma ve sıralama gibi çeşitli görevlerde üstün performans gösterir ve eksik veri noktalarını etkili bir şekilde işleyebilir. Özellikle yapılandırılmış veri setlerinde yüksek doğruluk sağlanmasıyla öne çıkar (Nielsen, 2016).

Gradient Boosting (GB) Algoritması

Tıpkı XGBoost'ta olduğu gibi, GB algoritması da gözetimli öğrenme kapsamında tahmin doğruluğunu artırmak için ardışık olarak zayıf öğrenicileri birleştirir (Friedman, 2001). Bu yöntem, başlangıçta basit bir modelle tahmin yapar, ardından modelin hataları hesaplanır ve bu hataları düzeltmek için yeni bir model eğitilerek eklenir. Her yeni model, önceki modelin hatalarını öğrenir ve gidermeye çalışır. Süreç boyunca kayıp fonksiyonunun gradyanı kullanılarak hatalar minimize edilir. Gradient Boosting, öğrenme oranı ve düzenleme (regularization) parametreleri ile aşırı öğrenmeyi önler. Bu algoritma, özellikle karmaşık sınıflandırma ve regresyon problemlerinde yüksek doğruluk ve esneklik sağlar (Natekin & Knoll, 2013).

SVM Algoritması

SVM, hem sınıflandırma hem de regresyon problemlerinde kullanılan güçlü bir denetimli öğrenme algoritmasıdır. SVM'nin temel prensibi, iki sınıfı en iyi şekilde ayıran bir hiper düzlem bulmaktır. Bu hiper düzlem, sınıflar arasındaki mesafeyi (margin) maksimize ederek, modelin genelleme yeteneğini artırır ve farklı veri kümelerinde daha iyi performans göstermesine olanak tanır. Hiper düzleme en yakın veri noktaları, destek vektörleri olarak adlandırılır ve modelin oluşturulmasında kritik bir rol oynarlar. Karmaşık veri kümeleri için SVM, çekirdek (kernel) fonksiyonlarını kullanarak veriyi daha yüksek boyutlu uzaylara projeler. Yaygın olarak kullanılan çekirdek fonksiyonları arasında lineer, polinomial, RBF (Radial Basis Function) ve sigmoid fonksiyonları bulunur. Bu fonksiyonlar, SVM'nin karmaşık yapıları tanımasına ve sınıflar arasındaki ayrımı daha esnek bir şekilde gerçekleştirmesine olanak sağlar (Pisner & Schnyer, 2020).

AdaBoost Algoritması

AdaBoost (Adaptive Boosting), sınıflandırma problemleri için geliştirilmiş bir topluluk öğrenme (ensemble learning) algoritmasıdır ve temel amacı, bir dizi zayıf öğreniciyi birleştirerek güçlü bir sınıflandırıcı oluşturmaktır (Schapire, 2013). AdaBoost, iteratif bir süreçle zayıf öğrenicileri eğitir ve her iterasyonda, önceki modellerin yanlış sınıflandırdığı örnekler daha fazla ağırlık verir. Böylece her yeni model, önceki modellerin hatalarını öğrenerek bunları minimize etmeye çalışır. Bu yaklaşım, zayıf öğrenicilerin bir araya getirilmesiyle güçlü bir sınıflandırıcı elde edilmesini sağlar. AdaBoost, genellikle az sayıda hiperparametre gerektirmesi ve aşırı öğrenmeye karşı dirençli olmasıyla öne çıkar. Ancak, dengesiz veri kümelerinde performansında düşüş gözlemlenebilir (Luo vd., 2024).

DT Algoritması

Karar Ağacı (DT), gözetimli öğrenme problemlerinde sınıflandırma ve regresyon görevleri için yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. GB, XGBoost, RF gibi ağaç tabanlı algoritmaların temelini oluşturur. Karar ağacı, veri kümesindeki özelliklerin değerlerine göre bir dizi karar düğümü ve yaprak düğümü aracılığıyla verileri bölerek tahminler yapar. Bu algoritma, veri kümesinin yapısını basit ve sezgisel bir şekilde temsil ederken, aynı zamanda yüksek derecede yorumlanabilir sonuçlar sağlar. Karar ağacı oluşturulurken, her bir özellik değeriyle ilişkilendirilen bir karar düğümü oluşturulur. Veri kümesindeki her bir özellik, karar ağacının bir düğümünü oluşturacak şekilde sırayla değerlendirilir. Bu değerlendirme, veri kümesini en iyi şekilde bölmek amacıyla bir bölme kriteri kullanılarak yapılır (Myles vd., 2004). Genellikle, bölme kriteri olarak bilgi kazancı (information gain) veya gini index (gini impurity) gibi ölçütler tercih edilir. Karar ağacı oluşturma süreci, veri kümesi tamamen bölünene kadar veya belirli bir ağaç derinliğine ulaşılan kadar devam eder. Bu süreç sonucunda, ağaç yapısı ortaya çıkar ve her yaprak düğümü bir sınıf etiketi veya regresyon değeri tahmin eder (Quinlan, 1996). Modelin eğitimi tamamlandığında, karar ağacı tahmin yapmak için kullanılabilir.

RF Algoritması

RF, gözetimli öğrenme alanında sıkça kullanılan bir topluluk (ensemble) öğrenme tekniğidir. Bu yöntem, birden fazla karar ağacının birleşiminden oluşan bir model kullanarak tahminler yapar. Her bir karar ağacı, veri kümesinin rastgele örneklemeleri ve rastgele seçilmiş özellik alt kümeleri üzerinde eğitilir. Bu rastgelelik, her ağacın farklı bir alt küme üzerinde eğitilmesini sağlar ve genellikle aşırı öğrenmeyi (overfitting) önler. Karar ağaçları genellikle tamamen büyütülmez; yani her bir ağaç, tüm veriyi değil, sadece bir alt küme veriyi ve bir alt küme özellikleri kullanarak eğitilir. Tahmin yaparken, her bir karar ağacının tahminleri birleştirilir. Bu genellikle sınıflar arasında oylama veya regresyon problemlerinde ortalama alma yoluyla gerçekleştirilir. Böylece, her bir ağacın hataları telafi edilerek topluluk olarak daha güçlü ve istikrarlı bir tahmin elde edilir (Ali vd., 2012, Oshiro vd., 2012).

DENEYSEL SONUÇLAR VE BULGULAR

Önerilen sınıflandırma algoritmalarının performansları, Doğruluk, Duyarlılık, Özgüllük, Kesinlik, F1-Score ve Matthews Correlation Coefficient (MCC) olmak üzere altı farklı metrikle değerlendirilmektedir. Bu metrikler, Eşitlik (1-6)'da verilen formüllerle hesaplanmaktadır. Bu metriklerin hesaplanmasında TP, TN, FP ve FN parametreleri kullanılır. TP, modelin gerçekten iyi huylu olarak sınıflandırdığı tümörlerin sayısını ifade eder. TN, modelin gerçekten kötü huylu olarak sınıflandırdığı tümörlerin sayısını belirtir. FP, modelin gerçekten iyi huylu olan ancak yanlış olarak kötü huylu olarak sınıflandırdığı tümörlerin sayısını gösterir. FN ise, modelin gerçekten kötü huylu olan ancak yanlış olarak iyi huylu olarak sınıflandırdığı tümörlerin sayısını belirtir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{F1 - Score} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

$$\text{MCC} = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (6)$$

Eşitlik 6'daki MCC değeri denge ve doğruluğu tek bir sayı ile özetleyip, +1 mükemmel sınıflandırmayı, 0 rastgele tahminlemeyi ve -1 tamamen hatalı sınıflandırmayı göstermektedir.

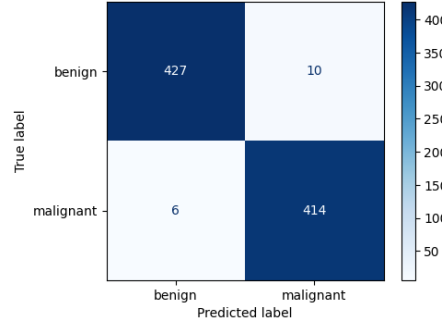
Tablo 2'de, XGBoost, GB, SVM, Adaboost, DT ve RF algoritmalarının sınıflandırma performansları karşılaştırılmaktadır. En yüksek doğruluk %98.13 ile GB algoritması tarafından elde edilirken, XGBoost ve RF algoritmaları %98.02, SVM %97.90, DT %96.27 ve Adaboost %95.68 doğruluk değerlerine ulaşmıştır. GB algoritması, %98.61 duyarlılık ve 0.9627 MCC (Matthew's Correlation Coefficient) değeri ile sınıflar arasında güçlü bir denge kurarak yüksek performans sergilemiştir. Özgüllük değeri ve kesinlik açısından GB, XGBoost ve SVM benzer sonuçlar verirken, Adaboost'un özgüllük değerinde düşük performans sergilediği dikkat çekmektedir. F1-Score ve MCC gibi metriklerde elde edilen yüksek değerler, GB algoritmasının genel performansa önemli katkı sağladığını göstermektedir.

Tablo 2. Sınıflandırma Sonuçları

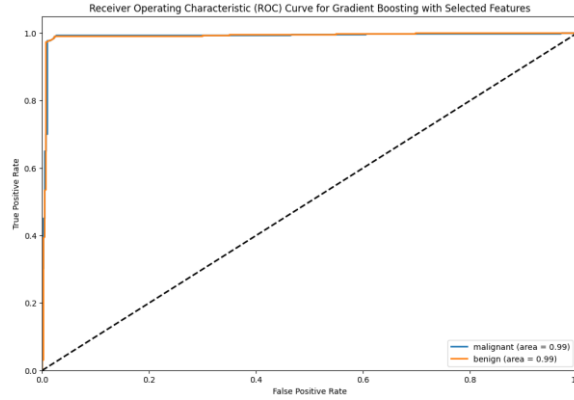
| Model | Doğruluk (%) | Duyarlılık (%) | Özgüllük (%) | Kesinlik (%) | F1-Score (%) | MCC |
|-----------|--------------|----------------|--------------|--------------|--------------|---------------|
| XGBoost | 98,02 | 98,39 | 97,64 | 97,71 | 98,05 | 0,9603 |
| GB | 98,13 | 98,61 | 97,64 | 97,71 | 98,16 | 0,9627 |
| SVM | 97,90 | 98,38 | 97,41 | 97,48 | 97,93 | 0,9580 |
| Adaboost | 95,68 | 98,08 | 93,42 | 93,36 | 95,66 | 0,9148 |
| DT | 96,27 | 95,71 | 96,86 | 97,03 | 96,36 | 0,9254 |
| RF | 98,02 | 98,08 | 96,97 | 97,03 | 98,03 | 0,9605 |

Şekil 3'te yer alan karmaşıklık matrisi, en yüksek doğruluğa sahip GB algoritmasının sınıflandırma performansını detaylandırmaktadır. Yanlış pozitif ve yanlış negatif oranlarının oldukça düşük olduğu matriste, modelin tümör tiplerini ayırt etmede başarılı olduğu görülmektedir. Özellikle düşük yanlış negatif oranı, kötü huylu tümörlerin doğru şekilde tespit edildiğini ve modelin güvenilirliğini göstermektedir. Bu sonuç, GB algoritmasının duyarlılık ve özgüllük metriklerindeki yüksek performansı ile uyumludur.

GB algoritmasına ait ROC eğrisi Şekil 4'te verilmiştir. AUC değerinin 0.99 olması, modelin doğru pozitif ve doğru negatif tespitlerde başarılı olduğunu göstermektedir. Ayrıca, bu yüksek AUC değeri, GB algoritmasının sınıflandırma işlemlerinde doğru ve tutarlı sonuçlar sağladığını da ortaya koymaktadır.



Şekil 3. GB Algoritmasına Ait Karmaşıklık Matrisi



Şekil 4. GB Algoritmasına Ait ROC Eğrisi Grafiği

Tablo 3, önerilen yöntemin literatürde aynı veri setini kullanan çalışmalarla karşılaştırmasını sunmaktadır. Tabloya göre, önerilen çalışma, Mishra vd. (2021) ve Zhang vd. (2021) BUSI veri setinde iki sınıf (iyi huylu tümör ve kötü huylu tümör) üzerinden sınıflandırma gerçekleştirmektedir. Diğer yandan, Liu vd. (2022), Badawy vd. (2021) ve Eroğlu vd. (2021) çalışmalarında normal sınıfı da içeren üç sınıf üzerinden sınıflandırma yapılmıştır. İki sınıflı çalışmalarda, Mishra vd. (2021) %97.4 ve Zhang vd. (2021) %94.12 doğruluk oranı elde etmiştir. Üç sınıflı çalışmalarda ise Liu vd. (2022) %97.18, Badawy vd. (2021) %96.27 ve Eroğlu vd. (2021) %95.6 doğruluk oranlarına ulaşmıştır. Önerilen yöntem, iki sınıf (iyi huylu tümör ve kötü huylu tümör) kullanarak %98.13 doğruluk oranı elde etmiştir. Bu sonuç, önerilen yönteminin hem iki sınıflı hem de üç sınıflı çalışmalara kıyasla daha yüksek doğruluk değerine ulaştığını ve böylece klinik uygulamalar için geçerliliğini artırdığını göstermektedir. AUC değerleri incelendiğinde, önerilen yöntemin Eroğlu vd. (2021) çalışmasıyla aynı AUC değerine (0.99) ulaştığı görülmektedir. Diğer çalışmalara kıyasla elde edilen yüksek AUC değeri, önerilen yöntemin sınıf sayısının ikiye indirilmesi ve tümör tiplerine odaklanması sayesinde sağlanmıştır; böylece sınıflandırmada yanlış pozitif oranı azaltılmıştır. Bu durum, doğru teşhis ve tedavi planlaması açısından önemli bir avantaj sunmaktadır.

SONUÇLAR VE TARTIŞMA

Meme kanseri, dünya genelinde kadınlar arasında en sık rastlanan kanser türlerinden biri olup, erken teşhis yaşam süresi ve yaşam kalitesini önemli ölçüde artırmaktadır. Ancak, meme kanserinin erken evrelerde tespiti, belirtilerin genellikle belirgin olmaması ve yanlış pozitif ya da yanlış negatif sonuçların yaygınlığı nedeniyle zorlu bir süreçtir.

Bu çalışmada, literatürdeki birçok çalışmadan farklı olarak, yalnızca meme ultrason görüntülerinde yer alan iyi huylu ve kötü huylu tümörlerin sınıflandırılmasına odaklanılmıştır. Bu sayede tanı sürecinin hassasiyeti artırılarak, tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesi amaçlanmaktadır. Çalışmada kullanılan BUSI veri setindeki sınıf dengesizliğini gidermek için aynalama tekniği uygulanmıştır. Her bir görüntüden 123 radyomik özellik çıkarılmış ve bu özelliklerin sınıflama üzerindeki etkilerini değerlendirmek için önem skoru ve korelasyon analizi gibi yöntemler kullanılmıştır. Analiz sonucunda, 123 özellik arasından en anlamlı 40 özellik seçilmiştir. Sınıflandırma aşamasında, 6 farklı makine öğrenmesi algoritması değerlendirilmiş ve GB algoritması en yüksek doğruluk oranı olan %98.13'ü sağlamıştır. Bu bulgular, radyomik özelliklerin ve makine öğrenimi tekniklerinin meme kanseri teşhis ve sınıflandırma süreçlerinde önemli bir potansiyele sahip olduğunu ortaya koymaktadır.

Tablo 3. Önerilen Yöntemin Literatürdeki Bazı Çalışmalarla Karşılaştırılması

| Çalışma | Veri Seti | Sınıf Sayısı | Önerilen Yöntem | Doğruluk (%) | AUC |
|-------------------|-------------|---|---|--------------|-------------|
| Mishra vd. (2021) | BUSI | 2 (iyi huylu tümör, kötü huylu tümör) | Radyomik Özellik Seçimi + Adaboost | 97,4 | 0,962 |
| Liu vd. (2022) | BUSI | 3 (iyi huylu tümör, kötü huylu tümör, normal) | İteratif komşuluk bileşeni analizi (INCA) + CNN | 97,18 | - |
| Badawy vd. (2021) | BUSI | 3 (iyi huylu tümör, kötü huylu tümör, normal) | Resnet101 | 96,27 | - |
| Eroğlu vd. (2021) | BUSI | 3 (iyi huylu tümör, kötü huylu tümör, normal) | CNN + SVM | 95,6 | 0,99 |
| Zhang vd. (2021) | BUSI | 2 (iyi huylu tümör, kötü huylu tümör) | Yumuşak ve sert dikkat çoklu görev öğrenme modeli | 94,12 | 0,9628 |
| Bu çalışma | BUSI | 2 (iyi huylu tümör, kötü huylu tümör) | Radyomik Özellik Seçimi + GB | 98,13 | 0,99 |

Gelecekteki araştırmalarda, daha büyük ve çeşitli veri setlerinin kullanımı, modelin farklı tümör tiplerini daha etkili bir şekilde sınıflandırmasını ve genel performansını artırmasını sağlayabilir. Ayrıca, gelişmiş özellik seçimi ve boyut indirgeme yöntemlerinin uygulanması, modelin doğruluğunu ve hesaplama verimliliğini iyileştirebilir. Diğer makine öğrenmesi yöntemlerinin ve hibrit yaklaşımların değerlendirilmesi de mevcut sonuçların daha da geliştirilmesine katkıda bulunabilir. Y-ekseni boyunca aynalama tekniği, veri dengesizliğini gidermede etkili bir yöntem olmasına rağmen, yalnızca mevcut görüntülerin simetrik versiyonlarını ürettiği için veri çeşitliliğini artırma kapasitesi kısıtlıdır. Bu sınırlamaları aşmak ve modelin genelleme yeteneğini artırmak amacıyla, dengesiz veri setlerinde daha etkili çözümler sunabilen gelişmiş veri artırma teknikleri, örneğin Generative Adversarial Networks (GAN), kullanılabilir.

KAYNAKLAR

- Adnan, M., Alarood, A. a. S., Uddin, M. I., & Rehman, I. U. (2022). Utilizing grid search cross-validation with adaptive boosting for augmenting performance of machine learning models. *PeerJ. Computer Science*, 8, e803. <https://doi.org/10.7717/peerj-cs.803>
- Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A. (2020). Dataset of breast ultrasound images. *Data in Brief*, 28, 104863. <https://doi.org/10.1016/j.dib.2019.104863>
- Ali, J., Khan, R., Ahmad, N., & Maqsood, I. (2012). Random forests and decision trees. *International Journal of Computer Science Issues*, 9(5), 272–278. <http://ijcsi.org/papers/IJCSI-9-5-3-272-278.pdf>
- Ara, S., Das, A., & Dey, A. (2021, April). Malignant and benign breast cancer classification using machine learning algorithms. In 2021 International Conference on Artificial Intelligence (ICAI) (pp. 97-101). IEEE.
- Ardakani, A. A., Bureau, N. J., Ciaccio, E. J., & Acharya, U. R. (2022). Interpretation of radiomics features—A pictorial review. *Computer Methods and Programs in Biomedicine*, 215, 106609. <https://doi.org/10.1016/j.cmpb.2021.106609>
- Aristokli, N., Polycarpou, I., Themistocleous, S. C., Sophocleous, D., & Mamais, I. (2022). Comparison of the diagnostic performance of Magnetic Resonance Imaging (MRI), ultrasound and mammography for detection of

- breast cancer based on tumor type, breast density and patient's history: A review. *Radiography*, 28(3), 848–856. <https://doi.org/10.1016/j.radi.2022.01.006>
- Assiri, A. S., Nazir, S., & Velastin, S. A. (2020). Breast tumor classification using an ensemble machine learning method. *Journal of Imaging*, 6(6), 39. <https://doi.org/10.3390/jimaging6060039>
- Badawy, S. M., Mohamed, A. E. N. A., Hefnawy, A. A., Zidan, H. E., GadAllah, M. T., & El-Banby, G. M. (2021, July). Classification of Breast Ultrasound Images Based on Convolutional Neural Networks-A Comparative Study. In 2021 International Telecommunications Conference (ITC-Egypt) (pp. 1-8). IEEE.
- Bota, M. A., Gota, D. I., Bota, P., Stan, O. P., Pop, A., Fanca, A., ... & Miclea, L. (2024, February). Utilizing Transfer Learning-Based Algorithms for Breast Ultrasound Data in Multi-Instance Classification. In 2024 International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA) (pp. 1-6). IEEE.
- CERR. (n.d.). CERR: Computational Environment for Radiotherapy Research. Retrieved September 4, 2024, from <https://cerr.github.io/CERR/>
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794).
- Çapkan, H., Dönmez, B., Kalkan, G. M., Kaya, M. Z., Gürel, S., Akdağlı, E., ... & Uçar, M. K. (2022). Diagnosis of Breast Cancer with Hybrid Artificial Intelligence Method. *Avrupa Bilim ve Teknoloji Dergisi*, (42), 14-19.
- Eroğlu, Y., Yildirim, M., & Çınar, A. (2021). Convolutional Neural Networks based classification of breast ultrasonography images by hybrid method with respect to benign, malignant, and normal using mRMR. *Computers in Biology and Medicine*, 133, 104407. <https://doi.org/10.1016/j.combiomed.2021.104407>
- Fornacon-Wood, I., Mistry, H., Ackermann, C. J., Blackhall, F., McPartlin, A., Faivre-Finn, C., ... & O'Connor, J. P. (2020). Reliability and prognostic value of radiomic features are highly dependent on choice of feature extraction platform. *European Radiology*, 30(12), 6241-6250. <https://doi.org/10.1007/s00330-020-06957-9>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5). <https://doi.org/10.1214/aos/1013203451>
- Ghabrim, H., Essid, C., & Sakli, H. (2023, February). A diagnostic system for classifying and segmenting breast cancer based on ultrasound images. In 2023 20th International Multi-Conference on Systems, Signals & Devices (SSD) (pp. 919-924). IEEE.
- Gupta, S., Panwar, A., Yadav, R., Aeri, M., & Manwal, M. (2022, February). Employing Deep Learning Feature Extraction Models with Learning Classifiers to Diagnose Breast Cancer in Medical Images. In 2022 IEEE Delhi Section Conference (DELCON) (pp. 1-6). IEEE.
- Hussain, Z., Gimenez, F., Yi, D., & Rubin, D. (2017). Differential data augmentation techniques for medical imaging classification tasks. *AMIA annual symposium proceedings*, 2017, 979-984.
- Jabeen, K., Khan, M. A., Alhaisoni, M., Tariq, U., Zhang, Y. D., Hamza, A., Khalid, A., Kumar, S., Awais, M., Ali, M., & Damaševičius, R. (2022). Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion. *Sensors*, 22(3), 807. <https://doi.org/10.3390/s22030807>
- Khanna, P., Sahu, M., & Singh, B. K. (2021, December). Improving the classification performance of breast ultrasound image using deep learning and optimization algorithm. In 2021 IEEE International Conference on Technology, Research, and Innovation for Betterment of Society (TRIBES) (pp. 1-6). IEEE.
- Kumar, V., Gu, Y., Basu, S., Berglund, A., Eschrich, S. A., Schabath, M. B., Patil, D. C., Little, R. B., Tsien, C. I., & Gillies, R. J. (2012). Radiomics: The process and the challenges. *Magnetic Resonance Imaging*, 30(9), 1234-1248. <https://doi.org/10.1016/j.mri.2012.06.010>
- Lanjewar, M. G., Panchbhai, K. G., & Patle, L. B. (2024). Fusion of transfer learning models with LSTM for detection of breast cancer using ultrasound images. *Computers in Biology and Medicine*, 169, 107914. <https://doi.org/10.1016/j.combiomed.2023.107914>
- LIFEx. (n.d.). LIFEx: Lesion imaging feature extraction. Retrieved September 4, 2024, from <https://www.lifexsoft.org/>

- Liu, H., Cui, G., Luo, Y., Guo, Y., Zhao, L., Wang, Y., . . . Tuncer, T. (2022). Artificial Intelligence-Based breast cancer diagnosis using ultrasound images and Grid-Based Deep Feature Generator. *International Journal of General Medicine, Volume 15*, 2271–2282. <https://doi.org/10.2147/ijgm.s347491>
- Luo, J., Quan, Y., & Xu, S. (2024). Robust-GBDT: GBDT with nonconvex loss for tabular classification in the presence of label noise and class imbalance. arXiv. <https://arxiv.org/abs/2310.05067>
- Medical Imaging Interaction Toolkit. (n.d.). The Medical Imaging Interaction Toolkit (MITK). Retrieved September 4, 2024, from [https://www.mitk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_\(MITK\)](https://www.mitk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_(MITK))
- Mishra, A. K., Roy, P., Bandyopadhyay, S., & Das, S. K. (2021). Breast ultrasound tumour classification: A Machine Learning—Radiomics based approach. *Expert Systems, 38*(7). <https://doi.org/10.1111/exsy.12713>
- Myles, A. J., Feudale, R. N., Liu, Y., Woody, N. A., & Brown, S. D. (2004). An introduction to decision tree modeling. *Journal of Chemometrics, 18*(6), 275–285. <https://doi.org/10.1002/cem.873>
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics, 7*, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Nielsen, D. (2016). Tree Boosting With XGBoost. Master's thesis. Norwegian University of Science and Technology, Trondheim 98s.
- Oshiro, T. M., Perez, P. S., & Baranauskas, J. A. (2012). How many trees in a random forest?. In Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin, Germany, July 13-20, 2012. Proceedings 8 (pp. 154-168). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-31537-4_13
- Pesapane, F., De Marco, P., Rapino, A., Lombardo, E., Nicosia, L., Tantrige, P., Sardanelli, F., Manfredi, R., Bertelli, E., Castello, R., & Cassano, E. (2023). How radiomics can improve breast cancer diagnosis and treatment. *Journal of Clinical Medicine, 12*(4), 1372. <https://doi.org/10.3390/jcm12041372>
- Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. In *Machine learning* (pp. 101-121). Academic Press. <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>
- Podda, A. S., Balia, R., Barra, S., Carta, S., Fenu, G., & Piano, L. (2022). Fully-automated deep learning pipeline for segmentation and classification of breast ultrasound images. *Journal of Computational Science, 63*, 101816. <https://doi.org/10.1016/j.jocs.2022.101816>
- Pourasad, Y., Zarouri, E., Parizi, M. S., & Mohammed, A. S. (2021). Presentation of novel architecture for diagnosis and identifying breast cancer location based on ultrasound images using Machine learning. *Diagnostics, 11*(10), 1870. <https://doi.org/10.3390/diagnostics11101870>
- Quinlan, J. R. (1996). Learning decision tree classifiers. *ACM Computing Surveys (CSUR), 28*(1), 71-72.
- Rashid, H. U., Ibrikci, T., Paydaş, S., Binokay, F., & Çevik, U. (2022). Analysis of breast cancer classification robustness with radiomics feature extraction and deep learning techniques. *Expert Systems, 39*(8), e13018. <https://doi.org/10.1111/exsy.13018>
- Rizzo, S., Botta, F., Raimondi, S., Origgi, D., Fanciullo, C., Morganti, A. G., & Bellomi, M. (2018). Radiomics: the facts and the challenges of image analysis. *European Radiology Experimental, 2*(1). <https://doi.org/10.1186/s41747-018-0068-z>
- Şenol, A., & Kaya, M. (2024). An investigation on the use of clustering algorithms for data preprocessing in breast cancer diagnosis. *Türk Doğa ve Fen Dergisi, 13*(1), 70-77. <https://doi.org/10.46810/tdfd.1364397>
- Schapire, R. E. (2013). Explaining AdaBoost. In Springer eBooks (pp. 37–52). https://doi.org/10.1007/978-3-642-41136-6_5
- Sun, H., Li, H., Si, S., Qi, S., Zhang, W., Ma, H., Chen, X., Liu, Y., Yang, J., Zhang, X., & Qian, W. (2018). Performance evaluation of breast cancer diagnosis with mammography, ultrasonography, and magnetic resonance imaging. *Journal of X-ray Science and Technology, 26*(5), 805-813. doi: <https://doi.org/10.3233/xst-18388>
- Van Griethuysen, J. J., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., . . . Aerts, H. J. (2017). Computational Radiomics system to decode the radiographic phenotype. *Cancer Research, 77*(21), e104–e107. <https://doi.org/10.1158/0008-5472.can-17-0339>

World Health Organization (WHO). (2024, Eylül 4). Breast cancer. <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>

Zhang, G., Zhao, K., Hong, Y., Qiu, X., Zhang, K., & Wei, B. (2021). SHA-MTL: Soft and hard attention multi-task learning for automated breast cancer ultrasound image segmentation and classification. *International Journal of Computer Assisted Radiology and Surgery*, 16(12), 1719-1725. <https://doi.org/10.1007/s11548-021-02445-7>

Zhang, W., Guo, Y., & Jin, Q. (2023). Radiomics and its feature selection: A review. *Symmetry*, 15(10), 1834. <https://doi.org/10.3390/sym15101834>

Zhang, X., Zhang, Y., Zhang, G., Qiu, X., Tan, W., Yin, X., & Liao, L. (2022). Deep learning with radiomics for disease diagnosis and treatment: Challenges and potential. *Frontiers in Oncology*, 12, 773840. <https://doi.org/10.3389/fonc.2022.773840>