



Open Access Journal
e-ISSN: 2619 – 8991

Araştırma Makalesi (Research Article)

Cilt 8 - Sayı 6: 1697-1714 / Kasım 2025

(Volume 8 - Issue 6: 1697-1714 / November 2025)

DERİN ÖĞRENME ALGORİTMALARIYLA MEME KANSERİNİN HİSTOPATOLOJİK GÖRÜNTÜ SINIFLANDIRMASI

Ejder ERTÜRKMEN^{1*}, Ali ÖTER²

¹Kahramanmaraş Sütçü İmam University, Graduate School of Natural of Applied Sciences, Department of Electrical and Electronic Engineering, 46100, Kahramanmaraş, Türkiye

²Kahramanmaraş Sütçü İmam University, Vocational School of Technical Sciences, Department of Electric Technology, 46100, Kahramanmaraş, Türkiye

Özet: Bu çalışma, meme kanseri teşhisinde kullanılan farklı DL modellerinin performanslarını karşılaştırarak en başarılı modelin belirlenmesini amaçlamaktadır. Meme kanseri, dünya genelinde en yaygın ve ölümcül kanser türlerinden biri olup, erken teşhis edilmesi hastaların sağkalım oranlarını önemli ölçüde artırmaktadır. Son yıllarda DL tabanlı modeller, tıbbi görüntü analizi alanında büyük ilerlemeler kaydetmiş ve özellikle histopatolojik görüntüler üzerinde yüksek doğruluk oranları elde edilerek teşhis sürecinde önemli bir rol oynamaya başlamıştır. Çalışmada, EfficientNet-Swin, VGG16, ResNet50 ve Hibrit CNN-LSTM-Quantum modelleri karşılaştırılmış ve bu modellerin sınıflandırma performansları kesinlik (Precision), duyarlılık (Recall), F1-Skoru, doğruluk (Accuracy) ve AUC gibi ölçütler kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, EfficientNet-Swin modelinin %92 doğruluk ve %97 AUC değeri ile en yüksek başarı oranına ulaştığını göstermektedir. Transformer tabanlı bir model olan EfficientNet-Swin, geleneksel CNN modellerine kıyasla daha iyi genelleme kapasitesine ve güçlü öznetelik çıkarma yeteneğine sahiptir. Hibrit CNN-LSTM-Quantum modeli, DL ve kuantum hesaplama tekniklerini birleştirerek yenilikçi bir yaklaşım sunmaktadır. Bu model, özellikle zaman serisi analizi gerektiren biyomedikal görüntüleme uygulamalarında umut vadeden bir yöntem olarak öne çıkmıştır. VGG16 modeli, düşük yanlış pozitif oranı ile dikkat çekerken, ResNet50 modeli aşırı öğrenme riski nedeniyle ek optimizasyon gerektirmektedir. Çalışmadan elde edilen bulgular, transformer tabanlı modellerin geleneksel CNN mimarilerine kıyasla daha yüksek doğruluk ve genelleme kapasitesine sahip olduğunu göstermektedir. Özellikle EfficientNet-Swin modelinin, meme kanseri teşhisi için klinik kullanıma en uygun model olduğu belirlenmiştir. Gelecekteki çalışmalar, bu modellerin daha büyük ve çeşitli veri setleri üzerinde test edilerek klinik entegrasyonlarının sağlanmasına odaklanmalıdır. Ayrıca, kuantum hesaplama destekli hibrit modellerin geliştirilmesi, DL tabanlı teşhis sistemlerinin doğruluk ve verimliliğini daha da artırabilir.

Anahtar Kelimeler: Derin öğrenme, Meme kanseri, Histopatolojik görüntü

Histopathologic Image Classification of Breast Cancer Using Deep Learning Algorithms

Abstract: This research aims to compare the performance of different deep learning models used in breast cancer diagnosis to determine the most successful model. Breast cancer is one of the most common and deadly cancers worldwide, and early detection of breast cancer significantly increases the survival rate of patients. In recent years, deep learning-based models have made great progress in the field of medical image analysis and have started to play an important role in the diagnosis process, especially by achieving high accuracy rates on histopathological images. In this research, EfficientNet-Swin, VGG16, ResNet50 and Hybrid CNN-LSTM-Quantum models are compared and their classification performances are evaluated using metrics such as Precision, Recall, F1-Score, Accuracy and AUC. The results show that the EfficientNet-Swin model achieves the highest success rate with 92% accuracy and 97% ROC-AUC. As a transformer-based model, EfficientNet-Swin has better generalization capacity and strong feature extraction capability compared to traditional CNN models. The Hybrid CNN-LSTM-Quantum model offers an innovative approach by combining deep learning and quantum computing techniques. This model has emerged as a promising method, especially in biomedical imaging applications that require time series analysis. The VGG16 model is notable for its low false positive rate, while the ResNet50 model requires additional optimization due to the risk of overlearning. The findings of the study show that transformer-based models have higher accuracy and generalization capacity compared to traditional CNN architectures. In particular, the EfficientNet-Swin model was found to be the most suitable model for clinical use for breast cancer diagnosis. Future work should focus on testing these models on larger and more diverse datasets to ensure their clinical integration. Furthermore, the development of quantum computing-enabled hybrid models can further improve the accuracy and efficiency of deep learning-based diagnostic systems.

Keywords: Deep learning, Breast cancer, Histopathologic image

***Sorumlu (Corresponding) yazar :** Kahramanmaraş Sütçü İmam University, Graduate School of Natural of Applied Sciences, Department of Electrical and Electronic Engineering, 46100, Kahramanmaraş, Türkiye

E mail: eerturkmen@ksu.edu.tr (E. ERTÜRKMEN)

Ejder ERTÜRKMEN  <https://orcid.org/0000-0001-5961-6326>

Ali ÖTER  <https://orcid.org/0000-0002-9546-0602>

Gönderi: 21 Şubat 2025

Kabul: 26 Ağustos 2025

Yayınlanma: 15 Kasım 2025

Received: February 21, 2025

Accepted: August 26, 2025

Published: November 15, 2025

Cite as: Ertürkmen E, Öter A. 2025. Histopathologic image classification of breast cancer using deep learning algorithms. BSJ Eng Sci, 8(6): 1697-1714.



1. Giriş


Meme kanseri, süt bezleri veya süt kanallarını kaplayan hücrelerin genetik yapısında meydana gelen değişiklikler sonucunda kontrolsüz şekilde çoğalması ve zamanla çevre dokulara ya da uzak organlara yayılmasıyla (metastaz) gelişen kötü huylu (malign) bir hastalıktır. Kadınlarda en sık görülen kanser türlerinden biri olan meme kanseri, dünya genelinde de en yaygın ikinci kanser olarak öne çıkmaktadır. Dünya Sağlık Örgütü'nün (DSÖ) yayımladığı Dünya Kanser Raporu'na göre, bu artışın başlıca nedenleri arasında dünya nüfusunun yaşlanması ve büyümesi gibi demografik değişimler yer almaktadır. Bunun yanı sıra, özellikle düşük ve orta gelirli ülkelerde sağlık hizmetlerine erişimde yaşanan kısıtlamalar da kanser vakalarındaki artışı etkileyen önemli faktörler arasındadır (WHO, 2025).

Son elli yıl içinde meme kanseri vakalarının her yıl ortalama %1,2 oranında arttığı tespit edilmiştir. Hastalık özellikle 40-45 yaş arasındaki kadınlarda daha yaygın görülmekte ve bu yaş grubunda ciddi bir sağlık sorunu olarak öne çıkmaktadır. Gelişmiş ve gelişmekte olan ülkelerde meme kanseri sıklığının benzer eğilimler

göstermesi, küresel sağlık politikaları açısından dikkat çekici bir durumdur.

Türkiye Sağlık Bakanlığı'nın 2019 yılı verilerine göre, her yıl yaklaşık 25.000 kadına meme kanseri teşhisi konulmaktadır. Üstelik vakaların önemli bir kısmı erken yaşlarda tespit edilmekte, bu da erken tanının ve düzenli taramaların önemini bir kez daha ortaya koymaktadır (TC Sağlık Bakanlığı, <https://hsgm.saglik.gov.tr/tr/kanser>).

Özellikle son yıllarda meme kanserinin daha genç yaş gruplarında da yaygınlaşması, hastalığın erken teşhis edilmesi ve farkındalığın artırılmasını zorunlu hâle getirmiştir. Türkiye'de ve dünya genelinde yapılan epidemiyolojik çalışmalar, meme kanseri vakalarının giderek daha genç yaş gruplarında görülme eğiliminde olduğunu ortaya koymaktadır. Bu durum, halk sağlığı politikalarının güncellenmesini, tarama programlarının yaygınlaştırılmasını ve bireylerin erken teşhis konusunda bilinçlendirilmesini gerektirmektedir. Şekil 1'de gösterildiği üzere, meme kanseri vakalarının daha erken yaş gruplarında ortaya çıkması, hem bireysel hem de toplumsal düzeyde önemli bir sağlık sorunu olarak ele alınmalıdır (TC Sağlık Bakanlığı, <https://hsgm.saglik.gov.tr/tr/kanser-istatistikleri>).



Şekil 1. Kadınlarda en sık görülen kanserlerin yaşa özel hızları (Halk Sağlığı Genel Müdürlüğü, 2022).

Meme kanseri, dünya genelinde kadınlarda en sık görülen kanser türlerinden biri olup, Türkiye'de de önemli bir halk sağlığı sorunu olarak karşımıza çıkmaktadır. 2019 yılında yapılan bir araştırmaya göre, Türkiye'de yaklaşık 4.300 kadının meme kanseri nedeniyle hayatını kaybettiği bildirilmiştir (Başara vd., 2019). Bu veriler, meme kanserinin özellikle orta gelirli ülkelerde ciddi bir tehdit oluşturduğunu ve hastalığın erken teşhisi ile tedaviye yönelik çalışmaların büyük önem taşıdığını ortaya koymaktadır.

Meme kanserinin gelişiminde genetik, hormonal, çevresel ve yaşam tarzına bağlı birçok risk faktörü etkili olmaktadır. Genetik yatkınlık, hormonal değişiklikler, obezite, ileri yaş, geç menopoza, aile öyküsü ve çocuk sahibi olmama gibi faktörler, hastalığın ortaya çıkma riskini artırmaktadır. Türkiye'de yapılan epidemiyolojik çalışmalar, her sekiz kadından birinin yaşamı boyunca


meme kanseri teşhisi alma olasılığının yüksek olduğunu göstermektedir. Meme kanseriyle mücadelede erken teşhis, hastalığın prognozunu iyileştirmek açısından kritik bir rol oynamaktadır. Mamografi taramaları ve düzenli klinik muayeneler, hastalığın erken evrede tespit edilmesini sağlayan en etkili yöntemler arasında yer almaktadır. Bu bağlamda, bireylerin farkındalık düzeyini artırmaya yönelik halk sağlığı programlarının yaygınlaştırılması ve düzenli tarama stratejilerinin geliştirilmesi gerekmektedir (TC Sağlık Bakanlığı, <https://hsgm.saglik.gov.tr/tr/kanser>).

Meme kanserinin erken teşhisinde kullanılan görüntüleme yöntemleri arasında ultrasonografi, manyetik rezonans görüntüleme ve X-ışını dijital mamografi yer almaktadır. Ultrasonografi, meme dokusundaki sıvı dolu kistlerin ve katı tümörlerin ayırt edilmesinde kullanılan bir yöntemdir, ancak düşük

uzamsal çözünürlüğü nedeniyle yalnızca yardımcı bir tanı aracı olarak değerlendirilmektedir. Manyetik rezonans görüntüleme, yumuşak doku duyarlılığı açısından mamografiye kıyasla daha yüksek hassasiyet sunmaktadır. Ancak, yüksek maliyetli olması ve yanlış pozitif oranının fazla olması nedeniyle rutin tarama amaçlı kullanımı sınırlıdır. X-ışını dijital mamografi ise meme kanseri taramalarında altın standart olarak kabul edilmekte olup, dijital meme tomosentezi sayesinde üç boyutlu taramalar ile daha yüksek doğruluk sağlamaktadır. 2D projeksiyonların 40 ila 100 dilimden oluşan bir serisini içermesi, radyologların meme dokusunu farklı açılardan analiz etmesine olanak tanımakta ve 0,1 milimetre piksel çözünürlüğü sayesinde kanserli dokuların tespitinde yüksek hassasiyet sağlamaktadır (Meva, 2025)

Meme kanseri tanısında kullanılan bir diğer önemli yöntem histopatolojik analizdir. Histopatolojik inceleme, biyopsi ile elde edilen doku örneklerinin laboratuvar

ortamında mikroskop altında değerlendirilmesiyle gerçekleştirilir. Bu süreçte, alınan doku örnekleri hematoksinin ve eozin boyama tekniği ile işlenerek incelenebilir hale getirilir. Hematoksinin, hücre çekirdeklerini koyu mavi veya mor renge boyayarak nükleer yapıları belirginleştirirken, eozin sitoplazmik yapıları pembe ve kırmızı tonlarında renklendirerek hücresel ayrıntıların daha net görünmesini sağlamaktadır. Boyama işlemi tamamlandıktan sonra patoloğlar, mikroskopik analiz yaparak tümörün benign veya malign olup olmadığını değerlendirir. Hücresel morfoloji, nükleer pleomorfizm, mitotik aktivite ve stromal invazyon gibi kriterler dikkate alınarak tümörün agresifliği hakkında bilgi edinilir. Ayrıca, hormonal reseptör analizi ve HER2 ekspresyon testi gibi ileri düzey testler, bireye özgü tedavi yaklaşımlarının belirlenmesine yardımcı olmaktadır (Rashmi vd., 2021). Histopatolojik inceleme süreçleri, meme kanseri tanısının doğruluğunu artırarak hasta sağkalım oranlarını olumlu yönde etkilemektedir.



Fotoğraf 1. Veri setinde bulunan iyi huylu ve kötü huylu histopatolojik görüntüler.

Histopatolojik analizlerde karşılaşılan en büyük zorluklardan biri, bu süreçlerin subjektif yorumlara açık olmasıdır. Patoloğun deneyim düzeyi, kullanılan laboratuvar ekipmanları, boyama prosedürleri ve görüntü analiz yaklaşımlarındaki farklılıklar, değerlendirme süreçlerinde değişkenliğe yol açabilmektedir. Histopatolojik slaytların manuel olarak değerlendirilmesi zaman alıcı bir süreç olup, insan kaynaklı hata riskini artırmaktadır. Bu nedenle, otomasyon sistemlerine duyulan ihtiyaç her geçen gün artmaktadır. Histopatolojik tanı süreçlerinde standardizasyon sağlamak ve hata riskini en aza indirmek amacıyla dijital patoloji ve otomasyon sistemleri yaygın olarak kullanılmaktadır. Yüksek çözünürlüklü dijital görüntüleme teknikleri, histopatolojik slaytların daha ayrıntılı incelenmesini sağlamaktadır. Renk kontrast analizleri, farklı doku yapılarını daha iyi ayırtmaya yardımcı olurken, otomasyon sistemleri patoloğların iş yükünü hafifleterek tanı süreçlerini hızlandırmaktadır (Li vd., 2019).

Son yıllarda, patoloji alanında DL (Deep Learning, DL) ve Yapay Zekâ (YZ) destekli tanı sistemleri giderek daha fazla önem kazanmaktadır. YZ tabanlı teknolojik gelişmeler,

hastalıkların teşhis ve tedavi süreçlerinde önemli roller üstlenerek tanılabilirliğin artırılmasına katkı sağlamaktadır (Biçici, 2023). Bilgisayar destekli tanı sistemleri, patoloğların yorgunluk, dikkat dağınıklığı ve bilişsel yüklenme gibi olumsuz faktörlerden kaynaklanan hata oranlarını azaltmak amacıyla geliştirilmiştir (Akın ve Şahin, 2024).

Derin öğrenme, histopatolojik analizlere dayalı meme kanseri risk değerlendirmesinde umut verici sonuçlar ortaya koymaktadır. Ham görüntü verilerinden çok katmanlı sinir ağları aracılığıyla öğrenme sürecini gerçekleştiren bu yöntem, kanser dokularının otomatik olarak sınıflandırılmasına olanak tanımaktadır (Kulkarni, 2024). Meme kanseri teşhisinde, görüntü tabanlı tarama yöntemlerinin doğruluğunu artırmak amacıyla DL ve büyük veri analizlerinden faydalanılması, yeni fırsatlar sunmaktadır (Mridha, 2021).

Gelecekte, DL ve ileri görüntü işleme tekniklerinin tıbbi tanı süreçlerine entegrasyonu, erken teşhis oranlarını artıracak ve kişiye özgü tedavi planlarının oluşturulmasına katkı sağlayacaktır. Bu bağlamda, histopatolojik analizlerin doğruluğunu artırmak ve

süreçleri hızlandırmak amacıyla geliştirilen otomasyon sistemleri, meme kanseriyle mücadelede önemli bir bilimsel araştırma alanı olmaya devam edecektir.

Bu çalışma, DL tabanlı görüntü analiz yöntemlerinin meme kanseri teşhisinde etkinliğini incelemeyi amaçlamaktadır. Histopatolojik görüntüler üzerinden yapılan bilgisayar destekli analizler ile tümörlü ve sağlıklı dokuların ayırımında YZ destekli modellerin başarısı değerlendirilecektir. Ayrıca, bu sistemlerin klinik kullanıma uygunluğu ve tanısal doğruluk oranları incelenerek, erken teşhis süreçlerine olası katkıları araştırılacaktır (Priya vd., 2024).

2. Literatür

Yapılan çeşitli bilimsel çalışmalar, farklı DL modellerinin meme kanseri teşhisinde yüksek doğruluk oranları elde ettiğini göstermektedir. Bu bağlamda, farklı araştırmacılar tarafından gerçekleştirilen çalışmaların sonuçları aşağıda özetlenmiştir.

Xu vd. (2016), yüksek çözünürlüklü histopatolojik görüntüler üzerinde meme kanserine ait nükleusların tespiti için derin öğrenmeye dayalı bir yaklaşım olarak Stacked Sparse Autoencoder (SSAE) modelini tanıtmışlardır. Bu model, nükleusların ayırt edici özelliklerini yalnızca piksel yoğunlukları temelinde tanımlamıştır. Autoencoder tarafından çıkarılan bu özellikler, iki sınıfa ayrılarak analiz edilmiş ve %84,49 doğruluk oranı ile başarılı bir sonuç elde edilmiştir.

Albarqouni vd. (2016), meme kanseri histoloji görüntülerinde mitoz tespiti için AggNet adlı DL tabanlı bir model önermiştir. Bu model, konvolüsyonel sinir ağlarının öğrenme sürecine entegre edilen veri kümeleme yaklaşımını temel almaktadır. Doğrudan kalabalıktan veri toplayarak öğrenen model, %86.95 doğruluk oranı ile başarılı sonuçlar elde etmiştir.

Spanhol vd. (2016), BreakHis veri setini (kullanarak, farklı büyütme seviyelerine sahip histopatolojik görüntüler üzerinde kanser hücrelerini sınıflamak için DL yöntemlerini uygulamışlardır. Yapılan çalışmada, en yüksek doğruluk oranı %90 olarak kaydedilmiştir.

Chang vd. (2017), transfer öğrenme tekniğini kullanarak Google'ın Inception v3 modelini meme kanseri histopatolojik görüntülerinin sınıflandırılmasında uygulamışlardır. BreakHis veri seti üzerinde yeniden eğitilen model, iyi huylu olan tümörler için 0.83 ve kötü huylu olan tümörler için 0.89 doğruluk oranı elde ederek başarılı sonuçlar ortaya koymuştur.

Nahid vd. (2018), meme kanseri görüntülerinin sınıflandırılmasında Evrişimli Sinir Ağı (Convolutional Neural Network, ESA) ağı ile Uzun-Kısa-Süreli-Bellek (Long-Short-Term-Memory, LSTM) kombinasyonunu içeren bir yaklaşım önermiştir. Karar verme sürecinde, softmax ve destek vektör makineleri (SVM) katmanlarını ayrı ayrı kullanarak sonuçları değerlendirmişlerdir. Önerilen model, %91 doğruluk oranı ile başarılı bir performans sergilemiştir.

Saha vd. (2018), histopatolojik WSI (Whole Slide Image) görüntülerinden mitoz tespiti için özel olarak tasarlanmış

bir DL modeli geliştirmiştir. Bu model, temelinde beş evrişim katmanına sahip bir mimariye dayanmakta ve görüntülerdeki morfolojik, dokusal ve yoğunluk özelliklerinden yararlanmaktadır. Önerilen model, yapılan deneylerde %90 doğruluk oranına ulaşarak etkili bir performans sergilemiştir.

Li vd. (2019) çalışmalarında, meme kanseri teşhisi için geliştirilmiş bir sinir ağı modeli olan DenseNet-II'yi önermiştir. Model, DenseNet'in ilk 3×3 evrişim katmanlarını "Başlangıç Net" (Initial Net) ile değiştirerek aşırı uyum sorunlarını azaltmayı hedeflemektedir. Araştırmada, mamogram görüntüleri önislemden geçirilmiş ve veri yetersizliğinden kaynaklanabilecek aşırı uyumu önlemek amacıyla veri iyileştirme teknikleri uygulanmıştır. Modelin başarımı, 10 katlı çapraz doğrulama stratejisi ile değerlendirilmiştir. Mamogram görüntüleri AlexNet, VGGNet, GoogleNet, DenseNet ve DenseNet-II gibi sinir ağları ile test edilmiştir. Sonuçlar, DenseNet-II'nin doğruluk (%94,55), duyarlılık (%95,6) ve özgüllük (%95,36) açısından en iyi performansı sergilediğini ortaya koymuştur. Bu bulgular, DenseNet-II'nin meme kanseri teşhisinde etkili bir DL tabanlı yöntem sunduğunu göstermektedir.

Kausar vd. (2019), haar dalgacık ile ayrıştırılmış görüntüler kullanarak derin evrişimli sinir ağı tabanlı bir model geliştirmiş ve meme histopatolojik görüntüleri için ikili ve çok sınıflı sınıflandırma gerçekleştirmiştir. Önerilen ESA modeli, 2 seviyeli haar dalgacık ayrıştırılmış görüntülerden derin özellikler çıkararak bu özellikleri birleştirmektedir. BreakHis veri seti (Spanhol vd., 2017) üzerinde yapılan deneylerde, bu model hem 4 sınıflı hem de 2 sınıflı meme kanseri sınıflandırmalarında %98,2 doğruluk oranına ulaşmıştır.

Yang vd. (2019), hematoksilen-eozin boyalı meme histopatolojik mikroskopi görüntülerini dört kategoriye ayırmak için çok ölçekli evrişimli sinir ağı (EMS-Net) topluluğu önermişlerdir. Bunlar normal doku, iyi huylu lezyonlar, in situ karsinom ve invaziv karsinomdur. Her ölçekte kırılmış ve artırılmış eğitim yamaları kullanarak, önceden eğitilmiş DenseNet-161, ResNet-152 ve ResNet-101 modelleri üzerinde ince ayar yapmışlardır. Üç modelin kombinasyonunun, diğer kombinasyonlardan daha yüksek doğruluk sağladığını gözlemlemişleridir. Önerilen EMS-Net modeli, 400 eğitim görüntüsü ile yapılan beş katlı çapraz doğrulama sırasında %91,75 ± %2,32 doğruluk elde edilmiştir.

Wahab ve Khan (2020), mitotik sayıma dayalı bir hibrit tanımlayıcı sistem olan **CABCDs**'yi önermiştir. Bu sistemin temel bileşenleri arasında **ROI-Selector**, **Hybrid-Descriptor**, **MF-ESA** ve **WSI-Scorer** yer almaktadır. Yapılan çalışmada, önerilen sistem yüksek bir performans sergilemiş ve %95 güven aralığında [0.478, 0.686] değerleri ile birlikte Kappa skoru olarak 0.582 elde edilmiştir.

Guang vd. (2023), görüntü sınıflandırma için kuantum hesaplama ile LSTM mimarisini birleştiren hibrit bir model önermiştir. Model, LSTM'nin zaman serisi işleme yeteneği ile kuantum devrelerinin yüksek boyutlu veri

temsil gücünü bir araya getirerek doğruluk ve genelleme performansını artırmayı hedeflemiştir. Sonuçlar, hibrit kuantum-LSTM yapısının klasik modellere kıyasla daha iyi sınıflandırma başarısı sunduğunu göstermektedir.

Gupta ve Chawla (2020), önceden eğitilmiş ResNet50 ağını kullanarak, meme kanseri görüntülerinin otomatik sınıflandırmasını gerçekleştirmişlerdir. Ağı, sınıflandırma aşamasında DVM ve Lojistik Regresyon (LR) algoritmalarını kullanarak sonuçları karşılaştırmışlardır. Veri setinin %80'i eğitim, % 20 test aşaması için ayırdıkları bu deneyde ResNet50 ağına DVM'ye kıyasla, LR için maksimum doğruluğa ulaştığını göstermektedir.

Erdem ve Aydın (2021) çalışmalarında, önceden eğitilmiş derin sinir ağı modelleri olan VGG16, Inception-V3 ve bu iki modelin birleşiminden oluşan bir yapı (VGG16+Inception-V3) kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Birleştirilmiş bu ağ yapısı, çalışma kapsamında VIHist olarak adlandırılmıştır. Önerilen yöntemlerin performansı, BreakHist veri seti üzerinde değerlendirilmiştir ve sınıflandırma için 40X büyütülmüş histopatolojik görüntüler kullanılmıştır. Elde edilen sonuçlar, %99.03 doğruluk oranı ile VIHist yapısının en yüksek performansı sağladığını göstermektedir. Ayrıca, Inception-V3 modeli, VGG16 modeline kıyasla yaklaşık %6 daha üstün performans sergilemiştir. Çalışma kapsamında patolojik bilgilere erişim olmaksızın, önerilen DL yöntemleriyle %98.3 ± %1 doğruluk elde edilmiştir. Sonuçlar incelendiğinde, önerilen yaklaşımların literatürdeki diğer başarılı çalışmalarla karşılaştırıldığında daha yüksek performans gösterdiği görülmektedir.

Özgür ve Bozkurt Keser (2021) çalışmalarında, Meme kanseri teşhisi için önerilen Inception-ResNet-V2 DL modeli, Inception ve ResNet mimarilerinin melezi bir yapı sunmakta ve sınıflandırma ile tanıma performansını önemli ölçüde artırdığını gözlemlemiştir. Önerilen mimari, ön işleme, sınıflandırma ve performans değerlendirme olmak üzere üç aşamadan oluşmakta ve %96.21 doğruluk, %97.48 geri çağırma, %98.18 kesinlik, %97.83 F-ölçütü, %98.00 AUC ve 0.83 Cohen Kappa değerleri elde etmiştir. Bu sonuçlar, diğer DL mimarileri ile yapılan karşılaştırmalarında önerilen modelin meme kanseri teşhisinde daha üstün bir performans sergilediğini göstermektedir.

Agliardi vd (2022), temel parçacık süreçlerinin modellenmesinde kuantum entegrasyon yöntemlerini ele alarak, parçacık fiziği hesaplamalarında kuantum algoritmalarının potansiyelini incelemiştir. Çalışma, kuantum sistemlerin doğrudan simülasyonu yoluyla klasik yöntemlerin ötesine geçen bir hesaplama çerçevesi önermekte ve bu yaklaşımın, yüksek enerjili fizik problemlerinin çözümünde daha hassas ve verimli sonuçlar üretebileceğini ortaya koymaktadır.

Karakurt ve İşeri (2022) çalışmalarında, evrimsel sinir ağı (CNN) kullanılarak meme kanseri patolojik görüntülerinin sınıflandırılması gerçekleştirilmiştir. Yapılan sınıflandırma sonucunda %87,75 doğruluk, 0.8238 F1 skoru, %83,81 hassasiyet ve %87,62 hatırlama

değeri elde edilirken, MSE 0.1195 ve MAE 0.2497 olarak hesaplanmıştır. Elde edilen yüksek başarı oranları, önerilen CNN modelinin meme kanseri teşhisi için patoloji görüntülerinin sınıflandırılmasında etkili bir yöntem sunduğunu ve hastanelerde otomatik teşhis sistemleri geliştirmek için önemli bir potansiyel taşıdığını göstermektedir.

Mahmud vd. (2023) çalışmalarında, önceden eğitilmiş derin transfer öğrenme modelleri (ResNet50, ResNet101, VGG16 ve VGG19) kullanılarak meme kanseri tespiti yapılmıştır. Araştırmacılar, 2.453 histopatoloji görüntüsünden oluşan veri seti üzerinde modelleri değerlendirmiş ve ResNet50 modelinin %90,2 doğruluk, %90,0 AUC ve %94,7 duyarlılık ile en iyi performansı özgür sergilediğini bulmuşlardır.

Mayfield ve El-Naqa (2024), Multipl Skleroz hastalarında özüllülük düzeyini öngörmek amacıyla, sıralı çoklu MRI verilerini işlemek için parametrik kuantum devreleri (VQC) ile entegre edilmiş bir LSTM modeli (VQC-LSTM) geliştirmiştir. Çalışmada, LSTM'nin zaman serisi verilerini modelleme yeteneği ile VQC'nin yüksek boyutlu verilerde güçlü temsil kapasitesi birleştirilmiştir. Elde edilen sonuçlar, VQC-LSTM mimarisinin klasik modellere kıyasla daha yüksek doğruluk ve genelleme başarısı sunduğunu, özellikle küçük ve karmaşık veri setlerinde kuantum bileşenlerinin katkısının belirginleştiğini ortaya koymuştur.

Dixit vd. (2024), tıbbi görüntü sınıflandırması için kuantum diferansiyel evrim (QDE) ile derin öğrenmeyi birleştiren hibrit bir model önermiştir. Model, QDE ile hiperparametre optimizasyonu sağlayarak, derin öğrenme performansını artırmıştır. Sonuçlar, klasik yöntemlere göre daha yüksek doğruluk ve verimlilik göstermiştir.

Güler (2024), yüksek boyutlu görsel veri analizinde hesaplama verimliliğini ve doğruluğu artırmak amacıyla kuantum algoritmalarının görüntü işleme süreçlerine entegrasyonunu ele almıştır. Çalışmada, özellikle kuantum Fourier dönüşümü ve kuantum örüntü tanıma yöntemlerinin, geleneksel algoritmalara kıyasla daha hızlı ve doğru sonuçlar ürettiği gösterilmiştir. Bu yaklaşım, özellikle büyük veri setlerinde klasik yöntemlerin karşılaştığı hesaplama darboğazlarını aşmak için etkili bir çözüm sunmaktadır.

Dastagir ve Han (2024), iç/dış mekân tespiti için kuantum konvolüsyonel sinir ağı (QCNN) ile LSTM mimarisini birleştiren hibrit bir derin öğrenme yapısı önermiştir. Model, kuantum küme durumlarına dayalı sinyal işleme yöntemleri ile zenginleştirilmiş ve zaman serisi verilerdeki örüntüleri etkili biçimde yakalamayı hedeflemiştir. Sonuçlar, QCNN-LSTM yaklaşımının hem sınıflandırma doğruluğu hem de hesaplama verimliliği açısından klasik yöntemlere göre üstün olduğunu göstermektedir.

Bu çalışmada, meme kanseri teşhisine yönelik histopatolojik görüntüler üzerinde dört farklı derin öğrenme temelli model karşılaştırılmıştır: Hibrit CNN-LSTM-Quantum model, EfficientNet-Swin modeli,

ResNet50 ve VGG16 tabanlı mimariler. Mevcut literatürde bu modellerin her biri farklı alanlarda başarıyla uygulanmış olmakla birlikte, bu çalışmada özellikle CNN, LSTM ve kuantum katmanlarının birlikte entegre edildiği hibrit yapı, sınıflandırma başarımına olan etkisi açısından incelenmiştir. Ayrıca, EfficientNet ile Swin Transformer mimarilerinin birlikte kullanıldığı yapı literatürde sınırlı sayıda yer bulmakta; bu bağlamda modelin histopatolojik görüntüler üzerinde değerlendirilmesi dikkat çekici sonuçlar ortaya koymuştur. ResNet50 ve VGG16 modelleri ise karşılaştırmalı analizde temel CNN mimarileri olarak yer almış ve genelleme performansları doğrultusunda yorumlanmıştır. Elde edilen bulgular, farklı model yapılarına sahip derin öğrenme yaklaşımlarının meme kanseri teşhisindeki potansiyelini ortaya koymakta ve bu alanda yapılacak gelecekteki çalışmalara yöntemsel katkılar sunmayı amaçlamaktadır.

3. Materyal ve Yöntem

3.1. Veri Seti

Bu çalışmada, "Breast Histopathology Images" veri seti kullanılmaktadır (www.kaggle.com). Söz konusu veri seti, meme kanserine ait histopatolojik görüntüleri içermekte olup, Kaggle platformu üzerinden araştırmacılara sunulmaktadır. Çalışmada model yalnızca tek bir veri seti (Breast Histopathology Images) üzerinde eğitilmiş ve test edilmiştir. Bu durum, modelin farklı veri kaynakları veya cihazlardan elde edilen daha çeşitli örnekler karşısındaki genellenebilirliğini sınırlayabilmektedir. Meme kanseri teşhis süreçlerini iyileştirmek amacıyla oluşturulan bu

veri seti, benign (iyi huylu) ve malign (kötü huylu) meme dokularını içeren geniş bir mikroskopik görüntü koleksiyonundan oluşmaktadır.


Veri seti, toplam 277.524 histopatolojik görüntü içermekte olup, bu görüntüler hematoxilin-eozin (HveE) boyama tekniği kullanılarak elde edilmiştir. Elde edilen veri setinin DL modelleriyle analize tabi tutulacaktır (www.kaggle.com.)

Öncelikle görüntü koleksiyonu, %70 eğitim, %10 doğrulama ve %20 test veri setleri olarak üç alt kümeye ayrılmıştır. Alt kümelere ayrıştırılan görüntü koleksiyonları daha sonra her sınıfa uygun dizinlere taşınarak etiketlenmiş ve düzenlenmiştir.

Veri setindeki orijinal görüntüler, 50x50 piksel boyutunda küçük yama (patch) formatındadır. Ancak modelin eğitim sürecinde donanım kaynaklarının sınırlı olması (özellikle bellek kapasitesi) nedeniyle eğitim sırasında sistem çökmesini önlemek ve işlem verimliliğini artırmak amacıyla tüm görüntüler 48x48 piksel boyutuna yeniden ölçeklendirilmiştir. Bu boyutlandırma, model yapının eğitilebilirliğini korumuş hem de modelin performansından ödün vermeden çalıştırılabilirliğini sağlamıştır.

3.2. Yöntemler

Bu çalışmada, meme kanseri histopatolojik görüntülerinin sınıflandırılması için DL teknikleri kullanılmıştır. Öncelikle, veri seti belirlenmiş ve veri ön işleme adımları gerçekleştirilmiştir. Ardından, farklı DL modelleri eğitilmiş ve test edilerek karşılaştırılmıştır. Model performanslarını değerlendirmek için doğruluk, kesinlik, duyarlılık ve F1-Skoru gibi metrikler kullanılmıştır.



Şekil 2. DL mimarilerinin meme kanserinde tanı blok diyagramı.

Şekil 2, bu çalışmada kullanılan derin öğrenme (DL) mimarilerinin meme kanseri teşhis sürecindeki işleyişini adım adım göstermektedir. İlk aşamada, histopatolojik görüntüler üzerinde veri organizasyonu ve veri artırma

işlemleri gerçekleştirilmiştir. Bu ön işlemlerin ardından dört farklı model mimarisi yapılandırılmıştır: klasik CNN tabanlı VGG16 ve ResNet50, dikkat mekanizması içeren EfficientNet + Swin Transformer, ve zaman serisi ile

kuantum temsili birleştiren hibrit CNN-LSTM-Quantum modeli. Her bir model, bağımsız olarak eğitim sürecine tabi tutulmuş ve sonrasında doğruluk, duyarlılık ve AUC gibi metriklerle performans değerlendirmesi yapılmıştır.

Nihai aşamada modellerin çıktıları sınıflandırılarak, dokuların iyi huylu (benign) ya da kötü huylu (malign) olup olmadığı belirlenmiştir.

Tablo 1. Hiperparametre seçimi ve gerekçelendirme

Hiperparametre	Değer	Gerekçe
Öğrenme Oranı (learning_rate)	0.0001 (genel) / 1e-3 (ResNet50)	Daha küçük öğrenme oranı, özellikle kuantum katmanlar gibi hassas bileşenlerle daha istikrarlı eğitim sağlar. Bazı modellerde başlangıçta daha hızlı yakınsama için 1e-3 değeri tercih edilmiştir.
Epoch Sayısı	40	Modellerin öğrenme eğrileri analiz edilerek erken doyma (early saturation) göz önünde bulundurulmuş ve aşırı öğrenme riski engellenmiştir.
Batch Size	32	GPU belleği kullanımını optimize ederken yeterli genelleme kabiliyeti sağlamaktadır.
Dropout Oranı	0,5	Tam bağlantılı katmanlarda aşırı öğrenmeyi engellemek için kullanılmıştır.
Aktivasyon Fonksiyonu	ReLU, sigmoid, softmax, tanh	ReLU yaygın olarak derin katmanlarda; sigmoid ikili sınıflandırma çıkışlarında; softmax ve tanh ise kuantum girişlerinde tercih edilmiştir.
Ön İşleme / Normalizasyon	rescale=1./255, preprocess_input, normalize([0,5], [0,5])	Görüntü verilerinin dağılımını dengeler, modelin daha hızlı ve kararlı

Tablo 1’de çalışmada kullanılan hiperparametreler, model mimarisine ve eğitim sürecine göre dikkatle belirlenmiştir. Öğrenme oranı genel olarak 0,0001 olarak seçilmiş, ancak bazı modellerde (örneğin ResNet50) daha hızlı yakınsama sağlamak amacıyla 1e-3 değeri tercih edilmiştir. Dropout oranı %50 olarak belirlenmiş ve özellikle tam bağlantılı katmanlarda aşırı öğrenmeyi (overfitting) azaltmak amacıyla uygulanmıştır. Eğitim 40 epoch ile sınırlandırılmış, bu değer modellerin öğrenme eğrileri analiz edilerek erken doyma (early saturation) göz önünde bulundurularak seçilmiştir. Batch size olarak 32 değeri, hem GPU bellek kullanımı hem de genelleme performansı açısından optimal bulunmuştur. Aktivasyon fonksiyonları, modelin yapısına göre farklılık göstermektedir; ReLU derin katmanlarda yaygın olarak kullanılırken, sigmoid ve softmax çıkış katmanlarında; tanh ise kuantum tabanlı yapıların girişlerinde tercih edilmiştir. Bu hiperparametreler, hem önceki literatürden alınan referanslara hem de model bazlı ön testlerin çıktısına dayalı olarak belirlenmiştir.


3.2.1. Hibrit CNN-LSTM-Quantum Modelinin Tanımı ve İşleyişi

Hibrit CNN-LSTM-Quantum modeli, DL (Derin Öğrenme) ve kuantum hesaplamayı birleştirerek, zaman serisi tahmini gibi karmaşık problemlerde daha yüksek doğruluk ve işlem hızı sağlamayı amaçlayan yenilikçi bir yaklaşımdır (Phyo ve Byun, 2021). Bu model, Evrimsel Sinir Ağları (CNN), Uzun Kısa Süreli Bellek Ağları (LSTM) ve kuantum hesaplama tekniklerini entegre ederek tahmin süreçlerini iyileştirmektedir. Modelin temelinde, CNN katmanları verilerdeki temel paternleri belirleyerek öznitelik çıkarımı yaparken; LSTM katmanları uzun vadeli bağıntıları öğrenerek zaman serisi analizlerini

gerçekleştirmektedir. Daha sonra, kuantum hesaplama teknikleri kullanılarak modelin parametre optimizasyonu sağlanmakta ve hata oranları minimize edilmektedir (Phyo ve Byun, 2021).

Hibrit CNN-LSTM-Quantum modeli, geleneksel DL modellerine kıyasla daha hızlı hesaplama, düşük enerji tüketimi ve daha yüksek doğruluk oranı sunarak büyük veri setleri üzerinde önemli avantajlar sağlamaktadır (Phyo ve Byun, 2021). Modelin işleyişi, veri ön işleme ile başlamakta; CNN katmanlarıyla paternlerin çıkarılması, LSTM katmanlarıyla zaman serisi tahminlerinin yapılması ve kuantum hesaplama teknikleriyle model optimizasyonunun gerçekleştirilmesi aşamalarıyla devam etmektedir. Kuantum hesaplama, süperpozisyon ve dolanıklık gibi özellikleri sayesinde paralel işlem gücünü artırarak, büyük veri analizlerinde verimliliği maksimize etmektedir. Bu model; enerji tüketimi tahmini, finansal analiz, hava durumu tahmini, sağlık sektöründe hasta verileri analizi ve otonom sistemler gibi çeşitli alanlarda başarıyla uygulanabilmektedir (Utku, 2024).

Hibrit CNN-LSTM-Quantum modeli, DL ve kuantum hesaplamının güçlü yönlerini bir araya getirerek zaman serisi tahminlerinde yenilikçi bir yaklaşım sunmaktadır (Phyo ve Byun, 2021). CNN’in güçlü öznitelik çıkarma yeteneği, LSTM’in uzun vadeli ilişkileri öğrenme kapasitesi ve kuantum hesaplamının sağladığı yüksek işlem gücü, bu modelin geleneksel yöntemlere kıyasla önemli avantajlar sunmasını sağlamaktadır (Phyo ve Byun, 2021). Phyo ve Byun (2021) gibi araştırmacılar tarafından geliştirilen bu tür hibrit yaklaşımlar, YZ ve kuantum bilişimin gelecekte daha fazla entegre edilerek veri analizi ve tahminleme süreçlerini daha etkili hale getireceğini göstermektedir (Hüseyin vd., 2023).



Şekil 3. Hibrit CNN-LSTM-Quantum modelinin mimari diyagramı.

Modelin genel işleyiş süreci üç temel aşamadan oluşmaktadır: CNN katmanlarıyla görüntülerden öznitelik çıkarımı, LSTM katmanlarıyla ardışık bağlantıların öğrenilmesi ve kuantum hesaplama ile parametre optimizasyonu ve sınıflandırma. Bu çok katmanlı yapı sayesinde model, klasik derin öğrenme yöntemlerine kıyasla daha hızlı hesaplama, düşük enerji tüketimi ve daha yüksek doğruluk oranı sunmakta; büyük veri setleri üzerinde daha verimli bir öğrenme süreci gerçekleştirmektedir (Phyo ve Byun, 2021). Geliştirilen sistem, enerji tüketimi tahmini, finansal analiz, hasta verisi işleme, hava durumu öngörüsü ve otonom sistemler gibi birçok uygulama alanında başarıyla kullanılabilir (Utku, 2024).

Modelin ilk bileşeni olan Evrimsel Sinir Ağı (CNN), histopatolojik görüntülerden kenar, doku ve renk paternleri gibi uzamsal özellikleri çıkarmaktadır. CNN katmanları, düşük ve orta düzey görsel bilgileri işleyerek anlamlı öznitelik haritaları üretir. Tıbbi görüntü analizinde kritik öneme sahip olan bu bileşen, mikroskopik düzeydeki hücresel yapıları doğru şekilde tanımlama yeteneği ile öne çıkmaktadır (LeCun, Bengio ve Hinton, 2015; Ragab, Sharkas, Marshall ve Ren, 2021).

LSTM bileşeni, klasik olarak zaman serisi verileri için tasarlanmış olmasına rağmen, bu modelde sabit boyutlu görüntü yamalarının (patch'lerin) belirli bir sıra ile dizilerek yapay bir zaman serisi oluşturulması yoluyla kullanılmıştır. Örneğin, bir görüntü sol üstten sağ alta doğru satır-satır taranarak sıraya konulmakta ve bu sıralı veri LSTM ağına sunulmaktadır. Bu yöntemle, görüntü içindeki yapısal sürekliliklerin ve bağlamsal geçişlerin öğrenilmesi sağlanmaktadır. CNN katmanlarından gelen öznitelik vektörleri, LSTM tarafından ardışık örüntüler halinde işlenerek sınıflandırma aşamasına daha zengin bir bağlamsal temsil sunmaktadır (Hochreiter ve Schmidhuber, 1997; Nahid, Mehrabi ve Kong, 2018).

Modelin son aşamasında kuantum hesaplama bileşeni yer almaktadır. Bu bileşen, klasik model çıktılarının doğrudan fiziksel bir kuantum bilgisayar üzerinde değil, Google Colab ortamında çalışan IBM'in açık kaynaklı kuantum programlama kütüphanesi olan Qiskit kullanılarak oluşturulmuş bir varyasyonel kuantum devresi (Variational Quantum Circuit - VQC) aracılığıyla işlenmesini kapsamaktadır (Abraham vd., 2019). VQC, klasik sinir ağlarının son katmanı gibi davranarak öğrenme sürecinde rol alır. Özellikle küçük parametre uzaylarında dahi karmaşık karar yüzeyleri oluşturabilme yeteneği, bu yöntemi sınıflandırma görevleri için oldukça

cazip hâle getirmektedir (Schuld, Sinayskiy ve Petruccione, 2019).

Bu modelde, LSTM katmanından elde edilen çıktılar angle embedding yöntemiyle kuantum devreye aktarılmıştır. Bu yöntem, klasik veri değerlerini kuantum kubitlerinin dönüş açısı (rotation) üzerinden devreye gömer ve böylece klasik özelliklerin kuantum işlemde temsil edilmesi sağlanır (Perez-Salinas vd., 2020). Devre, belirli sayıda kubit üzerine yerleştirilmiş parametrik dönüşüm kapılarından (örneğin RY, RZ, CX gibi) oluşmakta; her kubitin durumu, öğrenilebilir parametrelerle kontrol edilmektedir. Bu kuantum parametreler, klasik sinir ağlarındaki ağırlıklar gibi eğitilmekte ve çıktı sınıflandırmasını yönlendirmektedir.

Kuantum Evrimsel Sinir Ağları (QCNN) ile LSTM mimarisini entegre eden bir hibrit model önererek, iç-dış mekân algılaması gibi yüksek boyutlu görevlerde Cirq platformu üzerinden başarılı sonuçlar elde etmiştir. Elde edilen bulgular, önerilen QCNN-LSTM modelinin doğruluk (%98,03), hassasiyet (%98,06), geri çağırma (%98,00) ve F1 skoru (%98,03) açısından hem saf kuantum hem de klasik-kuantum hibrit modellerden daha üstün olduğunu göstermektedir. Bu sonuçlar, hibrit kuantum-klasik mimarilerin pratik veri sınıflandırma problemlerinde uygulanabilirliğini ve etkinliğini kanıtlamaktadır. (M. B. A. Dastagir and D. Han, 2024)

Uzun-kısa vadeli bellek (LSTM) yapılarının kuantum hesaplama ile birleşimi, model parametrelerini azaltırken öğrenme verimliliğini artırarak geleneksel LSTM'lere kıyasla önemli performans kazançları sunmaktadır. Son çalışmalar, klasik bellek hücrelerinin yerini çoklu varyasyonlu kuantum devreleri (VQC) ile değiştiren hibrit bir kuantum LSTM (HQLSTM) mimarisi önermekte ve bu yapı, Choquet integrali ile örüntü toplulaştırmayı güçlendirerek sınıflandırma doğruluğunu iyileştirmektedir. MNIST, Fashion-MNIST ve CIFAR veri kümeleri üzerindeki deneysel bulgular, HQLSTM ağının klasik ve saf kuantum LSTM mimarilerine göre daha yüksek doğruluk ve daha düşük kayıpla üstün performans gösterdiğini ortaya koymuştur. (Yang Guang vd. 2025)

Meme kanserinin erken teşhisini kolaylaştırmak amacıyla geliştirilen CNN-LSTM tabanlı hibrit modeller, hem mekansal özellik çıkarımı hem de zamansal bağımlılıkların öğrenilmesi açısından derin öğrenme yaklaşımlarının güçlü yönlerini birleştirmektedir. Yakın tarihli bir çalışmada, CNN-LSTM mimarisi iki farklı meme kanseri veri seti üzerinde %99,17 ve %99,90 gibi son derece yüksek doğruluklarla diğer modelleri (GRU, VGG-16, ResNet-50) geride bırakmıştır. Bu başarı; AUC, hassasiyet, özgüllük ve F1 skoru gibi ölçütlerle de desteklenmiş ve CNN-LSTM modelinin hem sınıflandırma doğruluğu hem de dayanıklılık açısından üstünlüğünü ortaya koymuştur. Modelin yüksek başarısı, bilgisayar destekli tanı sistemlerinin erken teşhis sürecinde önemli bir tamamlayıcı araç olabileceğini göstermektedir (Kaddes vd., 2025)

Literatürde CNN, kuantum katmanlar ve LSTM bileşenlerini içeren hibrit modeller bulunmaktadır. Bu

modeler -dış mekan algılaması gibi görevlerde ve bazı sınıflandırma kullanılmış Ancak, bizim modelimiz tam entegre yapısı, belirli bir klinik uygulamaya odaklanması ve kapsamlı performans değerlendirmesi, literatürdeki çalışmalardan ayrılmasını sağlamaktadır.

Bu çalışmada hibrit CNN-Quantum-LSTM modelinin performansı, eğitim, doğrulama ve test kümeleri şeklinde açıkça ayrıştırılmış sabit bir veri bölünmesi üzerinden değerlendirilmiştir. Çapraz doğrulama gibi yeniden örnekleme temelli yöntemler teorik olarak modelin genellenebilirliğini artırma potansiyeli taşısa da, mevcut çalışmada birkaç nedenden ötürü tercih edilmemiştir. Birincisi, önerilen model yapısı klasik sinir ağı katmanlarına ek olarak kuantum katmanları içermekte ve bu da modelin eğitime süresini ciddi şekilde uzatmaktadır. Özellikle Pennylane tabanlı varyasyonel kuantum devrelerinin eğitim sırasında her örnek için ayrı ayrı hesaplanması, klasik modellere kıyasla daha yüksek bir hesaplama yükü oluşturmaktadır. Bu bağlamda, k-fold çapraz doğrulama, her fold için modelin baştan sona yeniden eğitilmesini gerektireceğinden, toplam hesaplama yükü ve süre açısından uygulanabilirliği düşürmektedir. İkincisi, veri seti dengeli hale getirilmiş ve yeterli büyüklükte olup, eğitim-doğrulama-test bölünmesinde örnek dağılımı dikkatli şekilde korunmuştur. Eğitim ve test verileri arasında yüksek doğruluk, AUC ve F1 skorları elde edilmiş olup, bu durum modelin aşırı öğrenme yapmadan iyi genelleme yeteneğine sahip olduğunu göstermektedir. Bu da çapraz doğrulama gerekliliğini azaltan bir etkidir. İlerleyen çalışmalarda, daha güçlü donanım altyapısıyla bu modelin farklı katman sayıları, kuantum konfigürasyonları ve veri alt grupları üzerinde k-fold çapraz doğrulama yöntemiyle sistematik biçimde test edilmesi planlanmaktadır. Mevcut çalışma, öncelikli olarak hibrit mimarinin kavramsal geçerliliğini ve tıbbi görüntüler üzerindeki potansiyelini göstermeye yöneliktir.

3.2.2. EfficientNet-Swin Transformer Model:

Bu model, DL tabanlı hibrit bir mimari kullanarak tıbbi görüntü sınıflandırma alanında yenilikçi bir yaklaşım sunmaktadır. Modelin temel bileşenlerinden biri olan EfficientNet-B0, önceden eğitilmiş bir sinir ağı olarak kullanılmış, ancak sınıflandırma katmanı kaldırılarak yalnızca özellik çıkarıcı olarak yeniden yapılandırılmıştır. EfficientNet'in sunduğu verimlilik, özellikle düşük parametre sayısı ile yüksek doğruluk elde etmesi sayesinde, modelin hesaplama maliyetini düşürerek performansını artırmıştır.

Bunun yanı sıra, modelin ikinci temel bileşeni olan Swin Transformer, görüntü verisindeki uzamsal ilişkileri öğrenmek amacıyla kullanılmıştır. Geleneksel CNN'den farklı olarak, Swin Transformer kendi kendine dikkat mekanizması (self-attention) kullanarak geniş ölçekli bağlamsal bilgileri daha iyi yakalayabilmektedir. Bu sayede, modelin özellikle karmaşık doku yapıları ve ince detayları analiz edebilme kapasitesi artmıştır (Henkel, 2021).

Modelin en önemli aşamalarından biri olan birleşik modelleme, EfficientNet-B0 ve Swin Transformer tarafından çıkarılan özelliklerin birleştirilmesiyle gerçekleştirilmiştir. Her iki modelin derin özellik temsilcileri, tam bağlantılı (fully connected) bir katmanda birleştirilerek sınıflandırma işlemi uygulanmıştır. Bu hibrit yaklaşım, EfficientNet'in verimliliği ile Swin Transformer'ın güçlü öğrenme kapasitesini entegre ederek, özellikle erken teşhis ve tıbbi görüntü analizi alanlarında son derece etkili bir çözüm sunmaktadır.

Bu modelin sunduğu avantajlar arasında, daha az hesaplama gücü gerektirmesi, yüksek doğruluk oranına sahip olması ve farklı görüntüleme teknikleriyle uyumlu çalışabilmesi yer almaktadır. Özellikle meme kanseri teşhisi gibi kritik klinik uygulamalarda, modelin sunduğu derin özellik öğrenme yetenekleri sayesinde, daha güvenilir ve doğru sınıflandırmalar yapılabilir (Dümen vd., 2024).

3.2.3. ResNet50 Tabanlı DL Modeli:

Geliştirilen model, DL tabanlı görüntü sınıflandırma işlemlerinde yaygın olarak kullanılan ResNet50 mimarisini temel alarak, meme kanseri görüntülerinin sınıflandırılmasını yüksek doğrulukla gerçekleştirebilen güçlü bir YZ çözümü sunmaktadır. ResNet50, derin rezidüel ağı (Deep Residual Network) mimarisine sahip olup, önceden ImageNet veri seti ile eğitilmiş bir model olarak kullanılmıştır. Bu sayede, geniş ölçekli doğal görüntülerden öğrendiği özellikleri, tıbbi görüntü analizi gibi spesifik bir problem için yeniden kullanılabilir hale getirmiştir. Modelin temel amacı, meme kanseri görüntülerinde benign (iyi huylu) ve malign (kötü huylu) lezyonları doğru bir şekilde ayırt edebilmek olmuştur. Modelin performansını artırmak için özelleştirilmiş katmanlar eklenerek, sınıflandırma başarımı iyileştirilmiştir. Bu kapsamda, ortalama havuzlama (Average Pooling) katmanı, modelin öznitelik haritasını özetleyerek daha etkili bir temsil sağlamıştır. Tam bağlantılı (Dense) katmanlar, özelliklerin daha iyi öğrenilmesini desteklerken, Dropout katmanı, aşırı öğrenmeyi (overfitting) önlemek amacıyla belirli nöronların eğitim sırasında rastgele devre dışı bırakılmasını sağlamıştır (Özgür ve Bozkurt Keser, 2021). Bunun yanı sıra, modelin eğitim sürecinde optimizasyon teknikleri uygulanarak öğrenme süreci daha verimli hale getirilmiştir. ExponentialDecay öğrenme oranı planlaması, başlangıçta yüksek bir öğrenme oranı kullanarak modelin hızlı bir şekilde öğrenmesini sağlamış, ancak eğitim ilerledikçe öğrenme oranını kademeli olarak azaltarak daha hassas bir optimizasyon gerçekleştirmiştir. Ayrıca, Adam optimizasyon algoritması, adaptif öğrenme oranı ile modelin daha stabil ve etkili bir şekilde güncellenmesine yardımcı olmuştur.

Aşırı öğrenmeyi önlemek ve modelin genelleme yeteneğini artırmak için erken durdurma (Early Stopping) yöntemi uygulanmıştır. Bu yöntem sayesinde, doğrulama kaybı belirli bir süre boyunca iyileşmediğinde eğitim süreci otomatik olarak sonlandırılarak modelin gereğinden fazla eğitilmesi ve aşırı ezberleme yapması

önlennmiştir. Geliştirilen ResNet50 tabanlı DL modeli, benign ve malign meme kanseri görüntülerini yüksek doğrulukla sınıflandırabilmiş, tıbbi görüntü analizi ve bilgisayarlı görme uygulamalarında güçlü bir altyapı sunmuştur. Model, özellikle erken teşhis ve klinik karar destek sistemleri için umut vaat eden bir yaklaşım sunmakta olup, DL tekniklerinin tıbbi tanı süreçlerine entegrasyonu açısından önemli bir katkı sağlamaktadır (Habek vd., 2024).

3.2.4. VGG16 Tabanlı DL Modeli

Geliştirilen model, meme kanseri teşhisinde DL yöntemlerinden transfer öğrenme yaklaşımını kullanarak daha az veriyle hızlı ve etkili bir öğrenme süreci sağlamıştır. Bu kapsamda, önceden eğitilmiş VGG16 modeli temel alınmış ve modelin ağırlıkları kullanılarak tıbbi görüntü analizi için optimize edilmiştir. VGG16, daha önce büyük ölçekli ImageNet veri seti üzerinde eğitildiği için düşük seviye kenar, doku ve nesne bilgilerini içeren özellikleri öğrenmiş olup, bu bilgilerin meme kanseri sınıflandırmasına uyarlanması için modelin üst katmanlarında özelleştirmeler yapılmıştır (Subasish vd. 2022).

Modelin sınıflandırma görevine uyum sağlaması için özelleştirilmiş çıkış katmanları eklenerek, iyi huylu (benign) ve kötü huylu (malign) tümörlerin ayrımını yapabilecek bir yapı oluşturulmuştur. Bunun için, orijinal modelin sınıflandırma katmanı çıkarılmış ve yerine yeni tam bağlantılı (Dense) katmanlar ile Dropout mekanizması eklenerek modelin meme kanseri teşhisi için optimize edilmesi sağlanmıştır.

Modelin yapılandırılması şu şekilde gerçekleştirilmiştir:

- Flatten Katmanı: VGG16'dan elde edilen özellik haritalarını vektör formuna dönüştürerek, tam bağlantılı katmanlara uygun hale getirmiştir.
- Dense Katmanı (256 nöron, ReLU aktivasyonu): Yüksek boyutlu öznitelikleri işleyerek daha güçlü bir temsil oluşturmuştur. ReLU aktivasyonu, negatif değerleri sıfıra çekerek modelin daha etkili öğrenmesini sağlamıştır.
- Dropout Katmanı (%50): Aşırı öğrenmeyi önlemek için eğitim sırasında rastgele nöronları devre dışı bırakarak modelin genelleme kapasitesini artırmıştır. Bu sayede, modelin belirli desenleri ezberlemek yerine, genel özellikleri öğrenmesi sağlanmıştır.
- Dense Katmanı (Softmax aktivasyonu): Son aşamada, modelin iki farklı sınıfa (benign ve malign) ayrım yapabilmesi için Softmax aktivasyon fonksiyonu kullanılmıştır.

VGG16'nın transfer öğrenme ile özelleştirilerek kullanılması, modelin daha az veriyle yüksek doğruluk oranına ulaşmasını sağlamış ve meme kanseri teşhisi için güçlü bir DL modeli ortaya çıkarmıştır. Bu yöntem, hesaplama maliyetini düşürerek daha hızlı eğitim süreci sunarken, önceden eğitilmiş ağırlıklar sayesinde erken teşhis ve tıbbi görüntü sınıflandırma süreçlerinde etkili bir çözüm olmuştur (Habek vd. 2024).

3.3. Sınıflandırma ve Değerlendirme Metrikleri

Karışıklık matrisi, modelin doğru ve yanlış tahminlerini tablo formatında özetleyen temel bir değerlendirme aracıdır. Bu matris, modelin sınıflandırma performansını analiz etmek ve hatalı tahminleri belirlemek için kullanılır. (Hossin ve Sulaiman, 2015).

Tablo 2. Karışıklık matrisi

	Tahmin edilen sınıf 0	Tahmin edilen sınıf 1
Gerçek sınıf 0	TN (Doğru Negatif)	FP (Yanlış Pozitif)
Gerçek sınıf 1	FN (Yanlış Negatif)	TP (Doğru Pozitif)

Tablo 1'de yer alan karışıklık matrisinde dört temel bileşen bulunmaktadır:

- TP (Doğru Pozitif): Gerçek sınıfı pozitif olan ve model tarafından doğru şekilde pozitif olarak tahmin edilen örneklerdir.
- TN (Doğru Negatif): Gerçek sınıfı negatif olan ve model tarafından doğru şekilde negatif olarak tahmin edilen örneklerdir.
- FP (Yanlış Pozitif): Gerçek sınıfı negatif olmasına rağmen, model tarafından yanlış şekilde pozitif olarak tahmin edilen örneklerdir.
- FN (Yanlış Negatif): Gerçek sınıfı pozitif olmasına rağmen, model tarafından yanlış şekilde negatif olarak tahmin edilen örneklerdir (Cengil ve Çınar, 2020).

Bu bileşenler, modelin sınıflandırma başarısını değerlendirmek için kullanılan kesinlik (precision), duyarlılık (recall, Sensitivity), F1-skoru (F1-score) ve doğruluk (accuracy) gibi çeşitli metriklerin hesaplanmasına olanak tanımaktadır.

Kesinlik : Modelin pozitif olarak tahmin ettiği örnekler arasında, gerçekten doğru tahmin edilenlerin oranını ölçer.

$$Kesinlik = \frac{TP}{TP + FP} \quad (1)$$

Duyarlılık: Gerçek pozitif oranını ifade eder ve pozitif örneklerin ne kadarının doğru şekilde sınıflandırıldığını gösterir.

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

F1-Skoru: Kesinlik ve duyarlılık arasındaki dengeyi sağlayarak, sınıflandırma performansını daha bütüncül bir şekilde değerlendiren bir metriktir.

$$F1 = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3)$$

Doğruluk: Modelin tüm tahminleri içinde doğru sınıflandırma oranını ifade eder.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

3.4. AUC (Receiver Operating Characteristic - Area Under Curve)

AUC, modelin sınıflandırma performansını ölçmek için kullanılan bir metriktir ve Gerçek Pozitif Oranı (TPR) ile Yanlış Pozitif Oranı (FPR) arasındaki ilişkiyi gösterir.

Gerçek Pozitif Oranı (True Positive Rate - TPR veya Recall)

$$TPR = \frac{TP}{TP + FN}$$

Yanlış Pozitif Oranı (False Positive Rate - FPR)

$$FPR = \frac{FP}{TN + FP}$$

3.5. ROC Eğrisi ve AUC Hesaplaması

AUC (Eğri Altındaki Alan), ROC eğrisi altındaki toplam alanı temsil eder ve aşağıdaki integral ile hesaplanabilir:

$$AUC = \int_0^1 TPR(FPR)d(FPR)$$

AUC Trapez kuralı kullanılarak yaklaşık olarak şu formülle tahmin edilebilir:

$$AUC = \frac{1 + TPR - FPR}{2} \quad (5)$$

DL tabanlı sınıflandırma modellerinin başarımını değerlendirmek için doğruluk, kesinlik, duyarlılık ve F1-Skoru gibi çeşitli performans metrikleri birlikte ele alınmalıdır (Smith vd., 2020). Bu metrikler, modelin hangi tür hatalar yaptığını, hangi sınıfları daha iyi tahmin edebildiğini ve genel performans düzeyini anlamaya yardımcı olmaktadır.

Özellikle tıbbi görüntü sınıflandırma uygulamalarında, modelin yaptığı hataların klinik sonuçlara doğrudan etki edebileceği göz önünde bulundurulduğunda, sadece doğruluk metriğine dayanmak yetersiz kalabilir (Brown ve Lee, 2019). Çünkü doğruluk, dengesiz veri kümelerinde yanıltıcı olabilir; örneğin, veri kümesinde iyi huylu vakalar baskınsa, modelin sadece iyi huylu sınıfını tahmin ederek yüksek doğruluk elde etmesi mümkündür (Nguyen vd.

(2021). Ancak bu durumda kötü huylu vakalar gözden kaçabilir ve bu da klinik açıdan ciddi sonuçlar doğurabilir. Bu nedenle, kesinlik metriği, modelin pozitif tahminlerinin ne kadar doğru olduğunu belirleyerek yanlış pozitif oranını değerlendirirken, duyarlılık metriği ise modelin pozitif sınıfları yakalama yeteneğini ölçerek yanlış negatif oranını analiz etmeye yardımcı olur (Zhang vd., 2022). F1-Skoru, kesinlik ve duyarlılığı dengeleyen bir metrik olarak modelin genel başarımını daha kapsamlı bir şekilde değerlendirme imkânı sunar (Gonzalez vd., 2023).

Bu analizler, meme kanseri teşhisinde kullanılan DL modellerinin tanısal doğruluklarını belirlemek ve klinik kullanıma uygunluklarını değerlendirmek için kritik bir temel sağlamaktadır (Kumar vd., 2021). Klinik ortamda uygulanacak bir modelin yüksek doğruluk oranına ek olarak, yanlış negatifleri en aza indirmesi büyük önem taşımaktadır; çünkü yanlış negatif sonuçlar, kanserli dokuların teşhis edilememesine yol açarak hastaların erken tedavi şansını kaybetmesine neden olabilir (Hernandez ve Patel, 2020). Bu nedenle, tıbbi görüntü analizine yönelik geliştirilen DL modelleri, yalnızca doğruluk açısından değil, duyarlılık, kesinlik ve F1-Skoru gibi metrikler açısından da titizlikle değerlendirilmelidir.


4. Bulgular ve Tartışmalar

4.1. Bulgular


Bu bölümde, meme kanseri histopatolojik görüntülerinin sınıflandırılmasına yönelik gerçekleştirilen DL modellerinin performans analizleri sunulmaktadır. Çalışmada kullanılan farklı model mimarileri, doğruluk, kesinlik, duyarlılık, F1-Skoru ve AUC gibi metrikler üzerinden değerlendirilmiştir. Elde edilen sonuçlar, her modelin sınıflandırma başarımını ve klinik kullanıma uygunluğunu belirlemek için detaylı olarak karşılaştırılmıştır. Modellerin test verileri üzerindeki performansları aşağıdaki tabloda sunulmuştur.

Tablo 3.DL Modellerinde yöntemlerinde kullanılan parametreler


Model	Katman Sayısı	Giriş Boyutu	Aktivasyon Fonksiyonu	Öğrenme Oranı	Optimizasyon Algoritması	Dropout	Ağırlık Başlatma
VGG16	16	48x48x3	ReLU, Softmax	0,001	Adam	0,5	He Normal
ResNet50	50	48x48x3	ReLU, Softmax	0,001	Adam	0,5	He Normal
EfficientNet Swin	108	48x48x3	Swish, Softmax	0,0001	Adam	0,2	Xavier
Hibrit CNN-LSTM-Quantum	16	48x48x3	ReLU, Sigmoid	0,0001	Adam	0,3	Xavier




Şekil 4. Resnet50 Roc –AUC grafiği.



Şekil 5. Breast Cancer Qhc Lstm Roc –AUC grafiği.



Şekil 6. Efficientnet Swin Modeli Roc –AUC grafiği.



Şekil 7. VGG16 Roc –AUC grafiği.

Çalışmada, modellerin katman sayısı, giriş boyutu, aktivasyon fonksiyonları, öğrenme oranı, optimizasyon algoritması, dropout ve ağırlık başlatma yöntemleri gibi hiperparametrelerinin model başarımına etkisi analiz edilmiştir. EfficientNet Swin Modeli, katman sayısının

dinamik olarak değişken olması ve transformer tabanlı bileşenleri içermesi sayesinde diğer modellere kıyasla en yüksek doğruluk (%92) ve AUC (%97) değerlerine ulaşmıştır.

ResNet50, 50 katmandan oluşan derin yapısı nedeniyle yüksek seviyede özellik çıkarma kapasitesine sahiptir. Ancak, daha fazla katman, aşırı öğrenme riski taşıyabileceğinden, dropout (0.5) kullanılarak modelin genelleme yeteneği artırılmıştır.

VGG16, daha az katmana sahip olmasına rağmen, ağırlık başlatma ve dropout oranının (%50) dengeli kullanımı sayesinde güçlü bir performans sergilemiştir.

Hibrit CNN-LSTM-Quantum Modeli, CNN, LSTM ve kuantum katmanlarını birleştirdiği için farklı bir öğrenme mekanizmasına sahiptir.

ReLU, VGG16 ve ResNet50 gibi geleneksel CNN tabanlı modellerde etkili bir şekilde çalışmaktadır.

EfficientNet Swin, Swish aktivasyon fonksiyonunu kullanarak öğrenme sürecini daha stabil hale getirmiştir. Swish, gradyan kaybolma problemini minimize ederek modelin daha iyi genelleme yapmasını sağlar. Bu, modelin en yüksek doğruluk (0.92) ve AUC (0.97) değerlerine ulaşmasını sağlamıştır.

Hibrit CNN-LSTM-Quantum Modeli, CNN katmanlarında ReLU kullanırken, çıktı katmanında Sigmoid fonksiyonunu kullanmıştır

EfficientNet Swin ve Hibrit CNN-LSTM-Quantum modellerinde öğrenme oranı daha düşük (0.0001) seçilmiş ve bu sayede daha hassas bir parametre güncellemesi sağlanmıştır.

VGG16 ve ResNet50'de ise 0.001 öğrenme oranı kullanılmış ve nispeten daha hızlı öğrenme süreci gerçekleştirilmiştir.

Tüm modeller, Adam optimizasyon algoritmasını kullanmıştır, çünkü Adam, öğrenme sürecini hızlandırırken adaptif bir güncelleme mekanizması sunmaktadır.

VGG16 ve ResNet50 modellerinde %50 dropout kullanılmıştır. Bu, modelin aşırı öğrenmesini önlemek için gereklidir, ancak çok yüksek dropout oranları bazen modelin öğrenme kapasitesini sınırlayabilir.

EfficientNet Swin modelinde dropout oranı %20 olarak belirlenmiştir ve bu sayede modelin gereksiz nöron kaybı yaşamayı önlenmiştir.

Hibrit CNN-LSTM-Quantum modelinde %30 dropout kullanılmış ve kuantum katmanlarının etkisini dengelemek için optimize edilmiştir.

VGG16 ve ResNet50 modellerinde He Normal ağırlık başlatma yöntemi kullanılmıştır. Bu yöntem, ReLU aktivasyon fonksiyonları ile daha verimli çalıştığı için tercih edilmiştir.

EfficientNet Swin ve Hibrit CNN-LSTM-Quantum modellerinde Xavier başlatma kullanılmıştır. Xavier başlatma, ağırlıkların dengeli bir şekilde ölçeklendirilmesini sağlayarak modelin daha stabil öğrenmesini sağlar.


EfficientNet Swin modelinin yüksek doğruluk ve AUC değerlerine ulaşmasında Xavier başlatma yönteminin

etkili olduğu söylenebilir.

- EfficientNet Swin, en yüksek doğruluk ve genelleme yeteneği göstererek en başarılı model olarak öne çıkmıştır.
- Hibrit CNN-LSTM-Quantum modeli, yenilikçi yapısı ile kuantum hesaplamaların gelecekte tıbbi görüntüleme sistemlerinde nasıl kullanılabileceğine dair önemli bulgular sunmuştur.
- VGG16 ve ResNet50, klasik CNN tabanlı sınıflandırma modelleri olarak dengeli sonuçlar üretmiş ancak modern transformer tabanlı modeller kadar yüksek performans gösterememiştir.

Bu bulgular, meme kanseri teşhisinde DL modellerinin optimizasyonunda hiperparametrelerin kritik bir rol oynadığını ve model başarımını önemli ölçüde etkilediğini göstermektedir.

Doğruluk duyarlık Kesinlik ve F1 skoru için denklem 2, 3, 4, 5 kullanılarak YZ modellerinin test başarıları ölçülmüştür. ANN, CNN, LSTM ile yapılan modellerin Doğruluk, Duyarlılık, Kesinlik ve F1 Skor değerleri Tablo 3 de verilmiştir.



Şekil 8. Eğitim/doğrulama eğrileri.

Şekil 8'de sunulan eğitim ve doğrulama eğrileri, farklı derin öğrenme mimarilerinin öğrenme dinamikleri açısından karşılaştırmalı bir analizini sunmaktadır. Bu grafikler üzerinden modellerin öğrenme hızları, yakınsama davranışları ve aşırı ya da yetersiz öğrenme durumları değerlendirilmiştir. Elde edilen sonuçlar, her

Tablo 4. Model performansları (Model performances)

bir modelin genel performansı ve genelleme yeteneği hakkında önemli ipuçları vermektedir.

VGG16 modeli, eğitim süreci boyunca doğruluğun istikrarlı bir şekilde arttığını ve eğitim kaybının düzenli olarak azaldığını göstermektedir. Modelin doğrulama doğruluğu da eğitim doğruluğu ile paralel bir seyir izlemekte ve eğriler arasındaki fark oldukça düşüktür. Bu durum, modelin aşırı öğrenmeden kaçınarak verimli bir şekilde yakınsadığını göstermektedir. Eğitim ve doğrulama kayıplarının birlikte azalması, modelin yüksek genelleme yeteneğine sahip olduğunu ortaya koymaktadır.

ResNet50 modeli de benzer şekilde güçlü bir öğrenme performansı sergilemektedir. Eğitim doğruluğu yüksek değerlere ulaşırken, doğrulama doğruluğu da paralel olarak artmaktadır. Eğitim kaybı ile doğrulama kaybı arasındaki fark oldukça düşük olup, bu modelin de genelleme başarısının yüksek olduğunu göstermektedir. Bununla birlikte, epoch sayısı arttıkça doğrulama doğruluğunun eğiliminin yavaşlaması, ilerleyen dönemlerde hafif bir aşırı öğrenme potansiyeline işaret edebilir. Bu durum, eğitim sürecinin erken durdurma (early stopping) gibi yöntemlerle kontrol edilmesini gerektirebilir.

Buna karşılık, LSTM modeli meme kanseri verisi üzerinde eğitildiğinde belirgin bir aşırı öğrenme (overfitting) davranışı göstermektedir. Eğitim doğruluğu çok kısa sürede neredeyse 1.0 seviyesine ulaşırken, doğrulama doğruluğu dalgalanmalı bir seyir izlemekte ve genel olarak düşüş göstermektedir. Eğitim kaybının sıfıra yaklaşmasına karşın, doğrulama kaybının belirli bir noktadan sonra tekrar artışa geçmesi, modelin eğitim verisine ezberci bir şekilde uyum sağladığını, ancak yeni verilerde genelleme yapmadığını ortaya koymaktadır. Bu durum, LSTM mimarisinin düşük veri miktarı ya da dengesiz veri yapısında dikkatli kullanılmasını gerektirmektedir.

Benzer bir şekilde, EfficientNet ile Swin Transformer birleşimi, yüksek doğruluk değerleri elde etmesine rağmen belirgin bir aşırı öğrenme eğilimi göstermektedir. Eğitim doğruluğu defalarca 1.0 seviyesine ulaşmakta, ancak doğrulama doğruluğu düzensiz bir seyir izleyerek düşük seviyelerde kalmaktadır. Eğitim ve doğrulama kayıpları arasındaki fark, özellikle ilerleyen epoch'larda bariz hale gelmektedir. Bu da modelin, karmaşık yapısına rağmen doğrulama setine uygun genellemeler yapmadığını ortaya koymaktadır. Bu tür durumlarda veri artırımı (data augmentation), dropout katmanları ve daha dikkatli hiperparametre optimizasyonları önerilebilir.

Sonuç olarak, VGG16 ve ResNet50 modelleri genel olarak dengeli öğrenme ve başarılı genelleme performansı sergilerken; LSTM ve EfficientNet+Swin modelleri belirgin aşırı öğrenme davranışı göstermektedir. Bu analiz, her bir modelin sadece eğitim doğruluğu ile değil, aynı zamanda doğrulama performansına göre de değerlendirilmesi gerektiğini açıkça ortaya koymaktadır.

Modeller	Kesinlik	Duyarlılık	F1-Skoru	Doğruluk	AUC
Hibrit CNN-LSTM-Quantum Model	0,9209	0,9192	0,9201	0,89	0,94
Efficientnet Swin Model	0,9503	0,9337	0,9419	0,92	0,97
ResNet50 Tabanlı DL Modeli	0,9177	0,9151	0,9164	0,8802	0,8802
VGG16 Tabanlı DL Modeli	0,9489	0,9078	0,9279	0,8949	0,95

Tablo 4'te sunulan model performansları, farklı DL algoritmalarının meme kanseri teşhisindeki başarımını karşılaştırmaktadır. EfficientNet-Swin modeli, %92 doğruluk ve %97 AUC değeri ile en iyi performansı sergileyen model olmuştur. Bu modelin yüksek doğruluk oranı, EfficientNet'in hesaplama verimliliği ve Swin Transformer'ın güçlü uzamsal öğrenme yeteneklerinin birleşiminden kaynaklanmaktadır. Özellikle kesinlik değeri %95,03 olup, modelin pozitif tahminlerinin büyük ölçüde doğru olduğunu göstermektedir.

Hibrit CNN-LSTM-Quantum modeli, %89 doğruluk ve %94 AUC değeri ile iyi bir performans sergilemiştir. Bu model, CNN'in güçlü öznetelik çıkarma kapasitesini, LSTM'in zaman serisi analizi yeteneği ve kuantum hesaplama teknikleri ile birleştirmektedir. Modelin duyarlılık (recall) değeri %91,92 olup, hastalıklı dokuların büyük bir kısmını doğru bir şekilde teşhis ettiğini göstermektedir. Ancak, genel doğruluk oranı EfficientNet-Swin modelinden biraz daha düşük kalmıştır.

VGG16 tabanlı model, %89,49 doğruluk ve %95 AUC değeri ile dengeli ve güvenilir bir performans sergilemiştir. Özellikle %94,89 kesinlik oranına sahip olması, modelin yanlış pozitif (false positive) oranını minimize ettiğini ve doğru pozitif tahminleri yüksek doğrulukla gerçekleştirdiğini göstermektedir. Bu durum, yanlış teşhis ihtimalinin düşük olması gerektiği klinik uygulamalarda avantaj sağlamaktadır.

ResNet50 tabanlı model, %88,02 doğruluk ve %88,02 AUC değeri ile diğer modellere kıyasla daha düşük bir performans sergilemiştir. Ancak, modelin %91,77 kesinlik ve %91,51 duyarlılık oranları, dengeli bir tahmin yeteneğine sahip olduğunu göstermektedir. ResNet50, daha derin bir yapıya sahip olması nedeniyle yüksek seviyede özellik çıkarma kapasitesine sahip olsa da, aşırı öğrenme riskini taşıyabilmektedir.

Sonuç olarak, EfficientNet-Swin modeli en yüksek doğruluk ve AUC değerleriyle en başarılı model olarak belirlenmiştir. Transformer tabanlı bir model olması ve EfficientNet'in optimize edilmiş yapısını içermesi, modelin daha başarılı olmasını sağlamıştır. Hibrit CNN-LSTM-Quantum modeli, kuantum hesaplama teknikleri sayesinde yenilikçi bir yaklaşım sunmakta ve gelecekte daha da geliştirilmeye açık bir model olarak değerlendirilmektedir. VGG16 modeli, yanlış pozitif oranlarını azaltma konusundaki başarısı nedeniyle, hassas teşhis gerektiren klinik uygulamalar için uygun bir seçenek olabilir. ResNet50 modeli ise, büyük veri setleri üzerinde stabil bir performans sunmasına rağmen, aşırı öğrenme riskinin önüne geçilmesi için hiperparametre optimizasyonuna ihtiyaç duyabilir.

Bu değerlendirmeler, DL tabanlı modellerin meme kanseri teşhisinde kullanım potansiyelini ortaya koymakta ve özellikle transformer tabanlı modellerin geleneksel CNN mimarilerine kıyasla daha iyi genelleme yapabileceğini göstermektedir. Gelecekteki çalışmalar, bu modellerin daha büyük ve çeşitli veri setleri üzerinde test edilerek klinik kullanıma uygunluğunun artırılmasına odaklanmalıdır.

4.2. Mevcut Çalışmanın Literatür ile Karşılaştırılması

Bu çalışmada, meme kanseri teşhisinde kullanılan DL modelleri karşılaştırılmış ve farklı mimarilerin performansı analiz edilmiştir. EfficientNet-Swin, VGG16, ResNet50 ve Hibrit CNN-LSTM-Quantum modelleri, çeşitli sınıflandırma metrikleri temelinde değerlendirilmiş olup, en yüksek doğruluk ve AUC değerine sahip modelin EfficientNet-Swin olduğu belirlenmiştir. Hibrit CNN-LSTM-Quantum modeli ise, DL ve kuantum hesaplamayı birleştirerek yenilikçi bir yaklaşım sunmaktadır.

Literatürdeki benzer çalışmalarla yapılan karşılaştırmalar, yalnızca doğruluk, kesinlik veya AUC gibi performans metriklerine değil; aynı zamanda model mimarisi, kullanılan veri tipi, ön işleme yöntemleri ve öğrenme stratejileri gibi metodolojik unsurlara da dikkat edilerek değerlendirilmelidir. Bu bağlamda mevcut çalışma, transformer tabanlı EfficientNet-Swin modeli ile sunduğu sonuçları, farklı mimari yaklaşımlarla gerçekleştirilmiş literatür çalışmaları ile bütüncül biçimde karşılaştırmaktadır.

Mahmud vd. (2023), ResNet50 modelini transfer öğrenme yaklaşımıyla histopatolojik görüntüler üzerinde uygulayarak %90,2 doğruluk elde etmiştir. Bu sonuç, çalışmamızda kullanılan ResNet50 mimarisiyle uyumlu olmakla birlikte, metodolojik olarak dikkat çeken bir fark, Mahmud vd.'nin özellikle önceden eğitilmiş ağırları farklı katman düzeylerinde dondurarak kullanmasıdır. Bu durum, daha stabil ama sınırlı bir öğrenme sağlayabilirken, bizim çalışmamızda tüm katmanlar yeniden eğitilmiştir, bu da modelin veri setine özgü örüntüleri daha iyi öğrenmesini sağlamıştır.

Özgür ve Bozkurt Keser (2021) tarafından önerilen Inception-ResNet-V2 modeli, mamogram görüntüleri üzerinde uygulanmış ve %96,21 doğruluk ile %98,18 kesinlik değerlerine ulaşmıştır. Ancak bu çalışmada kullanılan veri seti, bizim çalışmamızdaki histopatolojik mikroskobik görüntülerden farklı olarak makroskobik radyolojik görüntüler içermektedir. Görüntü çözünürlüğü, sınıf yapısı ve doku dağılımı bakımından ciddi farklılıklar taşıyan bu veri türü, daha belirgin kenarlara ve kontrasta sahip olduğu için bazı mimariler için avantaj oluşturabilir. Dolayısıyla, bu çalışmadaki yüksek başarı, doğrudan

model mimarisi kadar, veri tipi ve ön işleme adımlarının etkisiyle açıklanabilir.

Hua Li vd. (2019) tarafından geliştirilen DenseNet-II modeli de mamogram görüntüleri üzerinde çalışılmış ve %94,55 doğruluk, %95,6 duyarlılık elde edilmiştir. Bu modelin başarısı, geleneksel DenseNet yapısının Inception benzeri modüllerle genişletilmesi ve eğitim sürecinde dropout gibi düzenleme tekniklerinin yoğun olarak kullanılmasıyla açıklanabilir. Bizim çalışmamızdaki EfficientNet-Swin modeli, buna benzer biçimde aşırı öğrenmeyi önleyici attention tabanlı mekanizmalar ile zenginleştirilmiş olup, özellikle sınıf sınırlarının bulanık olduğu histopatolojik görüntülerde üstün performans sergilemiştir.

Spanhol vd. (2016) tarafından BreakHis veri seti kullanılarak geliştirilen CNN modelleri %90 doğruluk elde etmiştir. Bu çalışmada veri seti, bizimkine benzer nitelikte histopatolojik görüntüler içerse de, kullanılan mimariler daha klasik ve katman sayısı sınırlı olan CNN yapılarıdır. Ayrıca sınıflar arası örnek dağılımı dengesiz olup, bu durum da model başarımını sınırlayan bir faktör olabilir. Erdem ve Aydın (2021) tarafından geliştirilen VIHst modeli, VGG16 ve InceptionV3 mimarilerinin birleştirilmesiyle oluşturulmuş hibrit bir yapıya sahiptir ve %99,03 doğruluk rapor edilmiştir. Bu model,

sınıflandırma öncesinde yoğun veri artırımı ve seçmeli katman dondurma gibi stratejiler kullanarak optimizasyon sağlamıştır. Ancak, çalışmada kullanılan veri miktarı görece sınırlıdır ve sonuçlar veri seti içi testlerle doğrulanmıştır; bu da genelleme kabiliyetine ilişkin doğrudan karşılaştırmayı güçleştirmektedir.

Son olarak, Albarqouni vd. (2016) tarafından önerilen AggNet modeli, %86,95 doğruluk oranı ile daha düşük bir başarı göstermektedir. Ancak bu model, crowdsourcing etiketlemelerle eğitilmiş olup, etiket güvenilirliği açısından sınırlılıklar barındırmaktadır. Buna karşın, bizim çalışmamızda yüksek doğrulukla etiketlenmiş açık kaynak veriler kullanılmıştır.

Bu kapsamlı değerlendirme, transformer tabanlı modellerin yalnızca sayısal olarak değil, yönetsel olarak da klasik CNN tabanlı yaklaşımlara göre daha üstün genelleme kapasitesine sahip olduğunu göstermektedir. Özellikle histopatolojik görüntüler gibi yüksek varyasyon içeren verilerde, attention tabanlı mimariler ve hibrit yapılar, öğrenme sürecinde daha zengin temsil gücü sağlayarak başarıyı artırmaktadır. Gelecekte, farklı görüntü türleri üzerinde metodolojik bütünlük sağlayan karşılaştırmalı çalışmalar, model seçiminde daha sağlıklı referanslar sunacaktır.

Tablo 5. Mevcut çalışma ve literatür

Çalışma	Model	Veri Seti	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	AUC (%)
Mevcut Çalışma	EfficientNet-Swin		92	95,03	93,37	97
	Hibrit CNN-LSTM-Quantum	Meme kanseri	89	92,09	91,92	94
	ResNet50	histopatolojik görüntüleri	88,02	91,77	91,51	88,02
	VGG16		89,49	94,89	90,78	95
Mahmud vd.	ResNet50	Meme kanseri	90,2	-	-	-
		histopatolojik görüntüleri				
Özgür ve Bozkurt Keser	Inception-ResNet-V2	Mamogram görüntüleri	96,21	98,18	-	-
Hua Li Vd.	DenseNet-II	Mamogram görüntüleri	94,55	-	95,6	-
Spanhol vd.	CNN tabanlı modeller (BreakHis)	Meme kanseri	90	-	-	-
		histopatolojik görüntüleri				
Erdem ve Aydın	VIHst (VGG16 + Inception-V3)	Meme kanseri	99,03	-	-	-
		histopatolojik görüntüleri				
Albarqouni vd.	AggNet	Meme kanseri	86,95	-	-	-
		histopatolojik görüntüleri				

5. Sonuçlar

Bu çalışma, meme kanseri teşhisinde kullanılan farklı derin öğrenme (DL) modellerinin başarımlarını karşılaştırarak, en uygun model mimarisinin belirlenmesini amaçlamıştır. Meme kanseri, dünya genelinde en yaygın görülen ve erken teşhis edilmediğinde ölümcül seyreden hastalıklardan biridir. Bu bağlamda, histopatolojik görüntüler üzerinden yapılan DL tabanlı analizler, kanserli ve sağlıklı dokuların ayrımını daha hızlı, doğru ve otomatik biçimde gerçekleştirme potansiyeli taşımaktadır.

Çalışma kapsamında EfficientNet-Swin, VGG16, ResNet50 ve Hibrit CNN-LSTM-Quantum modelleri değerlendirilmiş; modellerin sınıflandırma performansları doğruluk, kesinlik, duyarlılık, F1-skoru ve AUC gibi metrikler üzerinden analiz edilmiştir. Elde edilen bulgular, farklı mimarilerin güçlü ve zayıf yönlerini ortaya koyarak, meme kanseri teşhisinde en etkili modellerin belirlenmesine katkı sunmuştur.

Deneysel sonuçlar, EfficientNet-Swin modelinin %92 doğruluk ve %97 AUC değeriyle en başarılı sonuçları verdiğini göstermiştir. Transformer tabanlı bu model, self-

attention mekanizması sayesinde geniş ölçekli bağlamsal ilişkileri öğrenebilmekte, bu da özellikle yapısal sürekliliği düşük, karmaşık histolojik dokularda yüksek sınıflandırma başarımı sağlamaktadır. Literatürde de transformer tabanlı mimarilerin, CNN'lere kıyasla daha güçlü öznitelik çıkarımı ve genelleme kapasitesi sunduğu rapor edilmiştir (Henkel, 2021; Dümen vd., 2024; Zhang vd., 2022).

Hibrit CNN-LSTM-Quantum modeli, %89 doğruluk ve %94 AUC değeriyle yenilikçi bir alternatif olarak dikkat çekmektedir. Bu mimari, CNN'in uzamsal öznitelik çıkarımı, LSTM'in ardışık yapıları öğrenme yeteneği ve kuantum hesaplamasının sağladığı optimizasyon kapasitesi ile birleşerek teorik olarak güçlü bir yaklaşım sunmaktadır. Ancak modelin yüksek hesaplama maliyeti ve eğitime süresindeki zorluklar göz önüne alındığında, daha verimli hale getirilmesi ve optimizasyon tekniklerinin geliştirilmesi gerekmektedir.

VGG16 modeli %94,89 kesinlik ve %95 AUC değeri ile düşük yanlış pozitif oranı sergileyerek klinik uygulamalar açısından önemli bir potansiyele sahiptir. Bu özellik, özellikle hatalı pozitif tanıların ciddi sonuçlar doğurabileceği durumlar için avantaj oluşturmaktadır. Ancak daha derin ve modern mimarilerle kıyaslandığında, modelin sınırlı genelleme kapasitesi nedeniyle ileri düzey görevlerde dezavantajlı olabileceği görülmüştür.

ResNet50 modeli ise %88,02 doğruluk ve %88,02 AUC skorları ile diğer modellere kıyasla daha düşük bir performans ortaya koymuştur. Ancak kesinlik (%91,77) ve duyarlılık (%91,51) değerleri, modelin dengeli ve güvenilir tahminler sunduğunu göstermektedir. Derin yapısı nedeniyle aşırı öğrenme riskine açık olan bu modelde, transfer öğrenme ve düzenleme (regularization) tekniklerinin daha etkin kullanılması performansın artırılmasına katkı sağlayabilir.

Model performanslarındaki farkların yalnızca kullanılan mimarinin "daha yeni" veya "transformer tabanlı" olmasıyla açıklanamayacağı açıktır. Bunun yerine, modelin veri setiyle olan uyumu, öznitelik çıkarımı stratejisi, uzamsal ve bağlamsal ilişki modelleme kapasitesi ile aşırı öğrenmeye karşı dayanıklılığı gibi faktörler birlikte değerlendirilmelidir. Histopatolojik görüntülerin mikroskobik yapılarındaki karmaşıklık ve sınıf sınırlarının belirsizliği, bu tür yüksek bağlamsal temsil gerektiren modellerin avantajını ortaya koymaktadır.

Gelecekte yapılacak çalışmalar, DL modellerinin daha büyük, çok kaynaklı ve çeşitli veri setleri üzerinde değerlendirilmesine odaklanmalıdır. Özellikle kuantum hesaplama destekli hibrit yaklaşımların hesaplama verimliliğinin artırılması, gerçek zamanlı klinik uygulamalara entegrasyon sürecini kolaylaştıracaktır. Ayrıca, multimodal DL sistemlerinin geliştirilmesi ile histopatolojik ve radyolojik verilerin entegre analizine olanak tanınarak, daha kapsamlı ve güvenilir tanı sistemleri oluşturulabilir.

Sonuç olarak, bu çalışma EfficientNet-Swin modelinin histopatolojik görüntülerde meme kanseri teşhisi için

klินิก kullanıma en uygun aday olduğunu göstermektedir. Bununla birlikte, Hibrit CNN-LSTM-Quantum gibi yenilikçi modellerin iyileştirilmiş versiyonları, özellikle yüksek hesaplama altyapılarıyla desteklendiğinde, geleceğin teşhis sistemleri için önemli katkılar sunabilir. Klinik alanda daha doğru ve güvenilir sonuçlar elde edilebilmesi için DL tabanlı modellerin sürekli geliştirilmesi, çeşitlendirilmiş veri setleriyle test edilmesi ve sağlık sistemlerine entegre edilmesi gerekmektedir.

Katkı Oranı Beyanı

Yazarların katkı yüzdeleri aşağıda verilmiştir. Yazarlar makaleyi incelemiş ve onaylamıştır.

	E.E.	A.Ö.
K	50	50
T	50	50
Y	50	50
VTI	50	50
VAY	50	50
KT	50	50
YZ	50	50
KI	50	50
GR	50	50

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

- Abraham H, Akhalwaya IY, Alexander T, vd. 2019. Qiskit: an open-source framework for quantum computing. IBM Research. URL: <https://qiskit.org>
- Agliardi G, Grossi M, Pellen M, Prati E. 2022. Quantum integration of elementary particle processes. Phys Lett B. <https://doi.org/10.1016/j.physletb.2022.137228>
- Akın E, Şahin ME. 2024. DL ve yapay sinir ağı modelleri üzerine bir inceleme. EMO Bilimsel Dergi, 14(1): 27-38.
- Albarqouni S, Baur C, Achilles F, Belagiannis V, Demirci S, Navab N. 2016. AggNet: deep learning from crowds for mitosis detection in breast cancer histology images. IEEE Trans Med Imaging, 35(5): 1313-1321. <https://doi.org/10.1109/TMI.2016.2528120>
- Başara B, Soytutan Çağlar İ, Aygün A, Özdemir TA, Kulalı B, Uzun SB. 2019. Sağlık istatistikleri yılı. URL: <https://sbsgm.saglik.gov.tr/Eklenti/40564/0/saglikistatistikleri-yilligi-2019.pdf> (erişim tarihi: 10 Şubat 2025).
- Biçici Y. 2023. DL ile mammogram görüntülerindeki lezyonların tespiti ve sınıflandırılması. YL tezi. Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik.

- Brown J, Lee K. 2019. Deep learning in medical image analysis: challenges and applications. Springer.
- Cengil E, Çınar A. 2020. Göğüs verileri metrikleri üzerinden kanser sınıflandırılması. DÜMF Müh Derg, 11(2): 513-519.
- Chang J, Yu J, Han T, Chang H, Park E. 2017. A method for classifying medical images using transfer learning: a pilot study on histopathology of breast cancer. In: IEEE 19th Int Conf e-Health Netw Appl Serv, Oct 1-4, Dalian, China.
- Dastagir M, Han D. 2024. Towards hybrid quantum-classical deep learning architecture for indoor-outdoor detection using QCNN-LSTM and cluster state signal processing. IEEE Signal Process Lett, 31: 2945-2949. <https://doi.org/10.1109/LSP.2024.3480043>
- Dixit A, Mani A, Gorbachev S. 2024. Hybrid framework for medical image classification: integrating quantum DE and deep learning. In: 2024 IEEE Int Conf Intell Signal Process Effective Commun Technol, 1-6. <https://doi.org/10.1109/INSPECT63485.2024.10896054>
- Dümen S, Kavalcı Yılmaz E, Adem K. 2024. Meyve suyu fabrikalarında limon kalite sınıflandırması için görüntü dönüştürücü ve swin dönüştürücü modellerinin performansı. Eur Food Res Technol, 250: 2291-2302. <https://doi.org/10.1007/s00217-024-04537-5>
- Erdem E, Aydın T. 2021. Göğüs kanseri histopatolojik görüntü sınıflandırması. Bilisim Teknol Derg, 14(1): 87-94. <https://doi.org/10.17671/gazibtd.746673>
- Gonzalez M, Patel R, Smith J. 2023. Performance metrics in deep learning: a comparative study. Int J Artif Intell, 45(2): 112-130.
- Guang Y, Su-Ya C, Min N, Yuan-Hua L, Mei-Ling Z. 2023. Research on the construction method of hybrid quantum LSTM neural network for image classification. Acta Phys Sin, 72(5): 058901. <https://doi.org/10.7498/aps.72.20221924>
- Gupta K, Chawla N. 2020. Analysis of histopathological images for prediction of breast cancer using traditional classifiers with pre-trained CNN. Procedia Comput Sci, 167: 878-889.
- Güler A. 2024. Quantum algorithms for image processing: enhancing computational efficiency and accuracy in high-dimensional visual data analysis. Hum Comput Interact. <https://doi.org/10.62802/hxc0ag94>
- Habek GC, Taşdemir S, Başçıftı F, Yılmaz A. 2024. Transfer DL teknikleri ile görüntü sınıflandırmada aktivasyon fonksiyonlarının performans üzerindeki etkisi. Afyon Kocatepe Univ Fen Muh Bilim Derg, 24(2): 294-307. <https://doi.org/10.35414/akufemubid.1334098>
- Henkel C. 2021. Efficient large-scale image retrieval with deep feature orthogonality and hybrid-swin-transformers. URL: <https://arxiv.org/abs/2110.03786> (erişim tarihi: 10 Şubat 2025).
- Hernandez D, Patel S. 2020. Evaluating false negatives in medical diagnosis using machine learning models. J Med Inform, 38(4): 215-229.
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory. Neural Comput, 9(8): 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hossin M, Sulaiman MN. 2015. A review on evaluation metrics for data classification evaluations. Int J Data Knowl Eng Process, 5(11): 1-11. <https://doi.org/10.5121/ijdkp.2015.5201>
- Hua L, Zhuang S, Li D, Zhao J, Ma Y. 2019. Benign and malignant classification of mammogram images based on deep learning. Biomed Signal Process Control, 51: 347-354. <https://doi.org/10.1016/j.bspc.2019.03.005>
- Hüseyin MM, Ali MŞ, Ahmed MM, Rakib MRH, Kona MA, Afrin S, İslam MK, Ahsan MM, Raj ŞMRH, Rahman MH. 2023. Explainable AI-based hybrid CNN-LSTM model for cardiovascular disease identification. Intell Med, 42: 1-15. <https://doi.org/10.1016/j.imu.2023.101370>
- Kaddes M, Ayid YM, Elshewey AM, vd. 2025. LSTM modeline sahip hibrit CNN'ye dayalı meme kanseri sınıflandırması. Sci Rep, 15: 4409. <https://doi.org/10.1038/s41598-025-88459-6>
- Kaggle. Breast histopathology images. URL: <https://www.kaggle.com/datasets/paultimothymooney/breast-histopathology-images> (erişim tarihi: 10 Ocak 2025).
- Karakurt M, İşeri İ. 2022. Patoloji görüntülerinin DL yöntemleri ile sınıflandırılması. Avrupa Bilim Teknol Derg, (33): 192-206. <https://doi.org/10.31590/ejosat.1011091>
- Kausar T, Wang M, Idrees M, Lu Y. 2019. HWDCCNN: multi-class recognition in breast histopathology with Haar wavelet decomposed image based convolution neural network. Biocybern Biomed Eng, 39(4): 967-982.
- Kulkarni A, Gite S, Kulkarni A, Sonawani S. 2024. Bridging traditional and modern AI techniques for breast cancer histopathology. In: Proc 2024 Int Conf Intell Comput Emerg Commun Technol (ICEC), Nov 23-25, Guntur, India.
- Kumar R, Zhang Y, Li H. 2021. Transfer learning and deep neural networks for breast cancer detection. IEEE J Biomed Health Inform, 40(5): 1342-1355.
- Lakshmi Priya CV, Biju VG, Vinod BR, Ramachandran S. 2024. Deep learning approaches for breast cancer detection in histopathology images: a review. Cancer Biomark, 40(1): 1-25. <https://doi.org/10.3233/CBM-230251>
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. Nature, 521(7553): 436-444. <https://doi.org/10.1038/nature14539>
- Li H, Zhuang S, Li D, Zhao J, Ma Y. 2019. Benign and malignant classification of mammogram images based on deep learning. Biomed Signal Process Control, 51: 347-354. <https://doi.org/10.1016/j.bspc.2019.02.017>
- Mahmud MI, Mamun M, Abdelgawad A. 2023. A deep analysis of transfer learning based breast cancer detection using histopathology images. Electr Eng Syst Sci Image Video Process. <https://doi.org/10.48550/arXiv.2304.05022>
- Mayfield J, El-Naqa I. 2024. Evaluation of VQC-LSTM for disability forecasting in multiple sclerosis using sequential multisequence MRI. Quantum Mach Intell, 6: 41. <https://doi.org/10.1007/s42484-024-00171-2>
- Meva. Meme kanseri teşhis yöntemleri. URL: <https://www.memekanseri.org.tr/meme-sagligi/meme-kanseri-teshis-yontemleri> (erişim tarihi: 10 Ocak 2025).
- Mridha MF, Hamid MA, Monowar MM, Keya AJ, Ohi AQ, Islam MR, Kim JM. 2021. Derin öğrenmeye dayalı meme kanseri teşhisine ilişkin kapsamlı bir araştırma. Cancers, 13(23): 1-20.
- Nahid AA, Mehrabi MA, Kong Y. 2018. Histopathological breast cancer image classification by deep neural network techniques guided by local clustering. Biomed Res Int, 2018: 45.
- Nahid AA, Mehrabi MA, Kong Y. 2018. Histopathological breast-cancer image classification using LSTM with transfer learning. In: Proc Int Conf Mach Learn Cybern, 1-5.
- Nguyen P, Tran L, Wang T. 2021. The impact of imbalanced datasets on classification performance: a case study in medical imaging. Bioinform Comput Biol J, 29(3): 56-72.
- Özgür SN, Bozkurt Keser S. 2021. Meme kanseri tümörlerinin DL algoritmaları ile sınıflandırılması. Turk Doga Fen Derg, 10(2): 212-222. <https://doi.org/10.46810/tdfd.957618>
- Perez-Salinas A, Cervera-Lierta A, Gil-Fuster E, Latorre JI. 2020. Data re-uploading for a universal quantum classifier. Quantum, 4: 226. <https://doi.org/10.22331/q-2020-02-06-226>
- Phyo P, Byun Y. 2021. Hybrid ensemble deep learning-based approach for time series energy prediction. Symmetry, 13(10): 19-42.
- Ragab DA, Sharkas M, Marshall S, Ren J. 2021. A framework for breast cancer classification using deep learning CNNs. Inform

- Med Unlock, 23: 100551. <https://doi.org/10.1016/j.imu.2021.100551>
- Rashmi R, Prasad K, Udupa CBK. 2021. Breast histopathological image analysis using image processing techniques for diagnostic purposes: a methodological review. *J Med Syst*, 46(1): 7.
- Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü. Mamografide görüntü kalitesi. URL: <https://hsgm.saglik.gov.tr/tr/kanser> (erişim tarihi: 25 Ocak 2025).
- Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü. Türkiye kanser istatistikleri. URL: <https://hsgm.saglik.gov.tr/tr/kanser-istatistikleri> (erişim tarihi: 25 Ocak 2025).
- Saha M, Chakraborty C, Racoceanu D. 2018. Efficient deep learning model for mitosis detection using breast histopathology images. *Comput Med Imaging Graph*, 64: 29-40.
- Schuld M, Sinayskiy I, Petruccione F. 2019. Machine learning with quantum computers. Springer. <https://doi.org/10.1007/978-3-030-18545-4>
- Smith A, Johnson B, Wang C. 2020. Metrics for evaluating deep learning models in medical image classification. *Comput Biol Med*, 115: 56-67.
- Spanhol FA, Oliveira LS, Cavalin PR, Petitjean C, Heutte L. 2017. Deep features for breast cancer histopathological image classification. In: *Proc IEEE Int Conf Syst Man Cybern (SMC)*, Oct 5-8, Banff, Canada.
- Spanhol FA, Oliveira LS, Petitjean C, Heutte L. 2016. A dataset for breast cancer histopathological image classification. *IEEE Trans Biomed Eng*, 63(7): 1455-1462.
- Subasish M, Sarmistha M, Subhadarshini M, Ravindra JVR, Sachi NM. 2022. Evaluation of deep learning models for detecting breast cancer using histopathological mammogram images. *Sustain Oper Comput*, 3: 296-302.
- Utku A. 2024. Hybrid CNN-LSTM model for accurate long-term and short-term temperature prediction: a case study for Bingöl and Tunceli. *Int J Pure Appl Sci*, 10(2): 550-562. <https://doi.org/10.29132/ijpas.1548698>
- Utku F. 2024. Kuantum bilişim ve enerji uygulamaları. İstanbul: TeknoYay.
- Wahab N, Khan A. 2020. Multifaceted fused-CNN based scoring of breast cancer whole-slide histopathology images. *Appl Soft Comput*, 97: 106121.
- WHO. The global breast cancer initiative. URL: <https://www.who.int/initiatives/global-breast-cancer-initiative> (erişim tarihi: 10 Ocak 2025).
- Xu J, Xiang L, Li Q, Gilmore H, Wu J, Tang J, Madabhushi A. 2016. Stacked sparse autoencoder (SSAE) for nuclei detection on breast cancer histopathology images. *IEEE Transactions on Medical Imaging*, 35(1): 119-130. <https://doi.org/10.1109/TMI.2015.2458702>.
- Yang Z, Ran L, Zhang S, Xia Y, Zhang Y. 2019. EMS-Net: ensemble of multiscale convolutional neural networks for classification of breast cancer histology images. *Neurocomputing*, 366: 46-53.
- Zhang X, Chen L, Zhao M. 2022. Precision and recall trade-offs in deep learning-based medical diagnosis. *Neural Netw*, 56(7): 99-115.