

2023

TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKÂ YARIŞMALARI

(Bilgisayarlı Görüyle Tarama Mamografilerinde BI-RADS
Kategorisi ve Meme Kompozisyonu Tahmini Yarışma
Kategorisi)

PROJE DETAY RAPORU

TAKIM ID: 180522

YARIŞMA SEVİYESİ

ORTAÖĞRETİM

YÜKSEKÖĞRETİM

İçindekiler

1. Proje Mevcut Durum Değerlendirmesi	3
2. Özgünlük	5
3. Sonuçlar ve İnceleme	6
4. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri	10
5. Referanslar	12



1. Proje Mevcut Durum Değerlendirmesi

Proje Sunuş Raporu'ndaki iş planlanmasına bağlı kalınarak, bir yandan güncel literatür takip edilmiş, bir yandan veri setleri işlemeye hazır hale getirilmiş bir yandan da önerilen modeller eğitilerek performans değerlendirmeleri yapılmıştır.

Veri Setleri Üzerine:

Proje Sunuş Raporu'nda da vurgulandığı üzere öncelikle veri setleri kullanacağımız modellere uygun hale getirilmek üzere düzenlenmiştir. Ardından eğitim aşamasında karşılaşılan problemlere göre veri setleri üzerinde detaylarını aşağıda paylaştığımız ek düzenlemeler yapılmıştır.

İlk olarak Sağlık Bakanlığı tarafından paylaşılan veri seti detaylıca incelenmiştir. Veri seti 3972 hastanın sağ/sol meme ve mediolateral oblique(MLO)/cranial caudal(CC) mamografisi için ayrı, toplamda 4 farklı mamografisini içermektedir. Mamografiler DICOM veri formatındadır. Eğiteceğimiz modeller DICOM formatındaki görselleri işleyemediğinden ve 140GB'lara ulaşan veri setinin modelin eğitimi için çok büyük olacağından dolayı veri setini küçültmek amacıyla DICOM formatındaki görseller JPG'ye çevrilmiştir. Bu sayede veri setinin boyutu 20GB'a düşürülmüştür.

4 mamografi için tek bir etiket verildiğinden ve modelin tüm mamografileri aynı anda işleyerek en doğru sonucu elde etmesinin amaçlanmasından dolayı her hastanın 4 mamografisi birleştirilmiştir. Birleştirme sonucu 4728x5928 boyutunda fotoğraflar elde edilmiştir. Ardından fotoğraflar model eğitimi için çok büyük olmasından dolayı 832x832 ölçülerinde yeniden boyutlandırılmıştır.

Veri seti çeşitli eğitimler için farklı kısımlara bölünmüştür. Bu kısımlar şunlardır:

- BI-RADS0 / BI-RADS1-2 / BI-RADS4-5 sınıflandırması için 3 sınıflı veri seti
- A / B / C / D sınıflandırması için 4 sınıflı veri seti
- Ansambl Model için ilk aşama olarak veri setinin AB / CD olarak bölünmesi, AB ve CD kısımlarının ise kendi içlerinde BI-RADS sınıflandırması için BI-RADS0 / BI-RADS1-2 / BI-RADS4-5 olarak 3 sınıfa bölünmesi (Ansambl Model yapısı *Modeller Üzerine* kısmında detaylandırılacaktır.)

Yarışma puanlamasında puanın 0.7'sini BI-RADS skoru, 0.15'ini meme kompozisyonu ve 0.15'ini de kadran bilgisi oluşturmaktadır. Hatta BI-RADS skorunun yanlış tahmin edilmesi dahilinde meme kompozisyonu ve kadran bilgisi tahminleri de yanlış kabul edilmektedir. Bu da BI-RADS skoru tahmininin yarışmanın önemli bir bölümünü oluşturduğunu kanıtlar. Bu sebeple projenin şu anki aşamasında öncelik BI-RADS skoru tahminine verilmiştir. Meme kompozisyonu tahmini ise BI-RADS tahmini için oluşturulmuş ansambl model kurgusu dolayısıyla gerçekleştirilmektedir. Kadran bilgisi tahmini üzerinde çalışmalarımız devam etmektedir, projenin ileriki aşamalarında model pipeline'ına dahil edilecektir.

Veri seti bölünürken sınıfların ağırlıklarının korunmasına özen gösterilmiştir. Veri setini parametre ağırlıklarını koruyarak bölmek için sklearn.model_Selection modülünün StratifiedShuffleSplit metodu kullanılmıştır. Elde edilen veri setinin dağılımlarına örnek *Resim 1*'de görülebilir.

a percent in train birads0 13.559322033898304
b percent in train birads0 28.30508474576271
c percent in train birads0 31.186440677966104
d percent in train birads0 26.949152542372882

a percent in test birads0 13.88888888888889
b percent in test birads0 37.5
c percent in test birads0 25.0
d percent in test birads0 23.611111111111111

Resim 1 – Örnek Veri Seti Dağılımı

Görüldüğü üzere, BI-RADS etiketlerine göre 3 sınıfa ayrılan veri setinde kompozisyon etiketlerinin kendi aralarındaki dağılımı mümkün olduğunca korunmuştur. Bu sayede, model daha tutarlı bir şekilde eğitilebilmiştir. Modelin kompozisyonun veri elde ihtimalinin önüne geçilmiştir. Düzenli dağılım sayesinde model daha iyi şekilde geliştirilmiştir.

Modeller Üzerine:


Proje Sunuş Raporu'nda iki farklı mimari türü kullanılması önerilmiştir. Bu mimariler konvolüsyonel sinir ağı ve dönüştürücülerdir (transformer). Kullanılması önerilen modeller arasında EfficientDet [1], NFNet-F4+ [2], CoCa [3], SwinV2 [4], R-CNN [5] bulunmaktadır.

Sağlık Bakanlığı tarafından veri seti paylaşıldıktan sonra veri seti detaylıca incelenmiştir ve veri miktarının dönüştürücü eğitimi için yeterli olup olmadığı konusunda kararsız kalmıştır. Bu sebeple state-of-art konvolüsyonel sinir ağı modellerinden biri olan EfficientNet üzerinde deneme eğitimi gerçekleştirilmiştir. Eğitim için EfficientNet-b3 modeli kullanılmıştır. Eğitim sonucunda overfitting gözlemlenmiştir. EfficientNet modelinin hem donanımın sınırlarını zorlamasından hem de diğer modellere nazaran düşük parametre miktarına rağmen eğitim sırasında overfitting yaşanmasından dolayı dönüştürücü eğitiminden vazgeçilmiştir. Eğitim sonuçları bölüm 3'de detaylandırılacaktır.

Modellerin Birleştirilmesiyle Elde Edilen Yeni Model Ağı - Sistemi ve Veri Seti'nin Bu Yeni Sisteme Uygun Olacak Biçimde Düzenlemesi Üzerine:

Proje Sunuş Raporunda bahsedilen amaçlara paralel olarak, modellerin bağımsız kullanılmasının yanı sıra, ilk önce meme kompozisyonlarına göre görüntüyü 2 sınıfa ayıran, ardından da ayrılmış sınıflar üzerinde özel olarak eğitilen BI-RADS modellerinin kullanılmasıyla 2 aşamalı bir model ağ – sistemi geliştirilmiştir. Model ağ sisteminin şeması özgünlük kısmında bulunmaktadır.

Bu model ağının geliştirilme amacı, yağlı dokuda kanserli hücre ayırımı yapılmasının zorlaşmasından dolayıdır. Yüksek kompozisyonlu meme mamografilerinde kanserli hücrenin diğer dokulardan ayrıştırılması zorlaşmaktadır. Dokular arası oluşan fark *Resim 2'de* bariz bir şekilde görülebilmektedir.



Resim 2 - Farklı Kompozisyon Sınıflarına Ait Mamografiler [6]

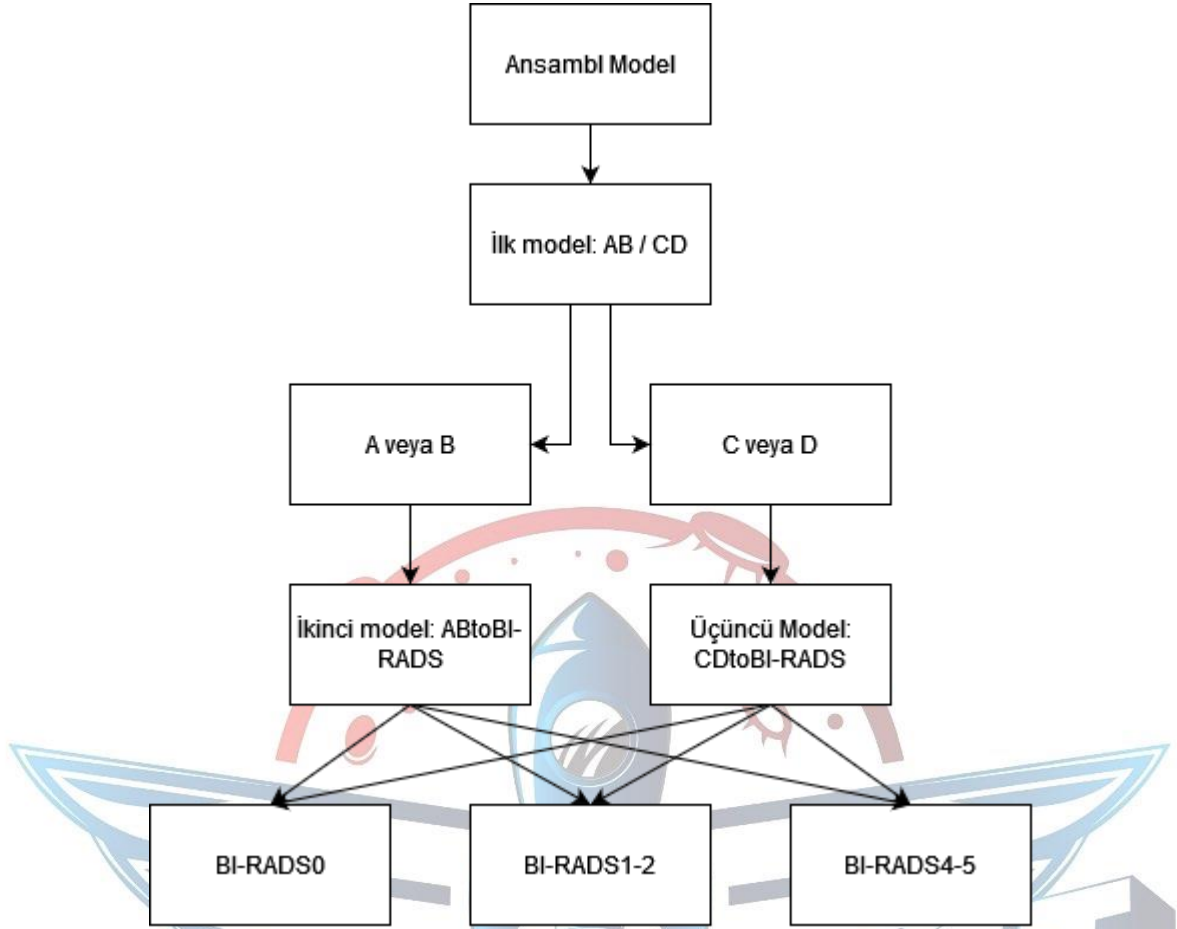
Bu sebeple, genel BI-RADS sınıf tespiti yapan modellerin doğruluğunda düşme gözlemlenmiştir. Bu durumun önüne geçmek için ilk önce mamografileri AB / CD olarak 2 kategoriye ayıran 1 model, ardından da AB kategorisi için BI-RADS sınıflandırması yapan 1 model ve CD kategorisi için BI-RADS sınıflandırması yapan ayrı bir model eğitilmiştir. Model şeması özgünlük kısmında görülebilir.

2. Özgünlük

Projede kullanılan model, konvolüsyonel sinir ağları arasında en yüksek performansı veren modellerden biridir. Modeller eğitilirken ezberlemeyi (overfitting) engellemek için görsellerde döndürme, yansıtma, merkez kırpma (center crop), yaklaştırma gibi veri artırma yöntemleri kullanılmıştır. Model eğitimleri sırasında transfer öğrenmesi kullanılmıştır. Bu sayede yüksek doğruluklara daha kısa sürede ulaşılabilmektedir. Modeller karşılaştırılırken loss ve accuracy metrikleri kullanılmıştır.

Model eğitiminde fotoğraflar birleştirilerek modelin tüm açılardan bakarak öğrenmesi sağlanmıştır. Ayrıca, veri seti farklı kısımlara bölünerek farklı model kombinasyonları oluşturulmuş ve birbirleriyle karşılaştırılmıştır.

Kompozisyon sınıflarının BI-RADS sınıflandırması üzerinde etkisi olduğu için bir Ansembl model ağı geliştirilmiştir. Bu model ağı sayesinde BI-RADS sınıflandırılma performansı artırılmıştır. Hazırlanmış model ağ şeması Resim 3'deki gibidir.



Resim 3 – Ansambl Model Ağ Yapısı

3. Sonuçlar ve İnceleme

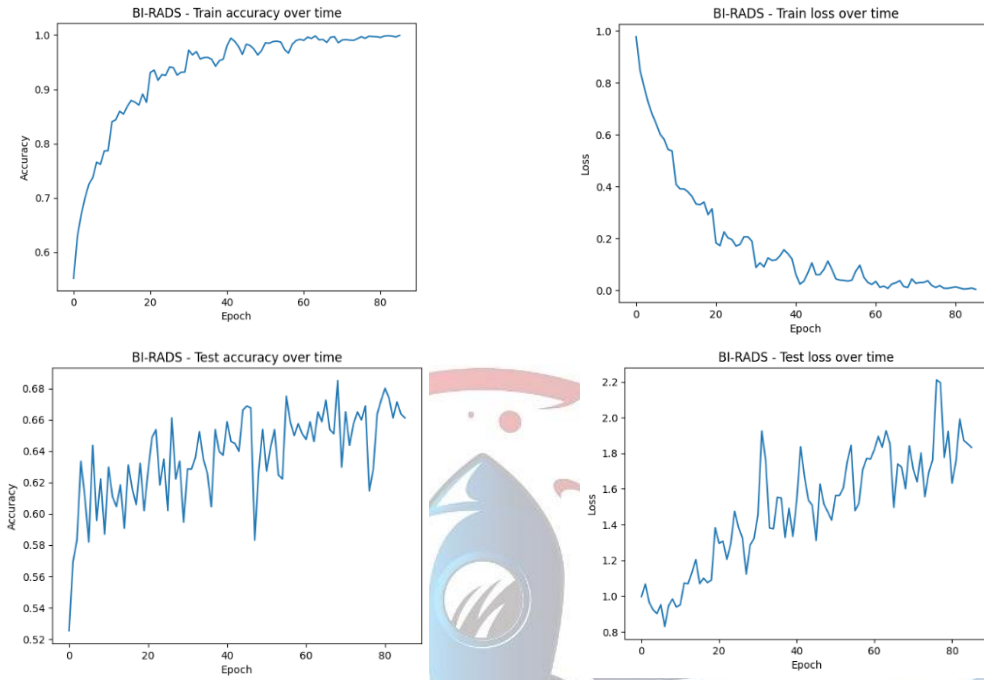
Model eğitime EfficientNet-b3 ile başlanmıştır. Sağlık Bakanlığı tarafından sağlanan mamografiler birleştirilerek 4 fotoğraftan 1 fotoğraf elde edilmiştir. EfficientNet-b3 modeli, **ilk başta** Sağlık Bakanlığı tarafından sağlanan verinin **dağılımı korunmadan bölünen veri setinde** eğitilmiştir. Excel dosyasında BI-RADS sınıflarının sıralı olduğu düşünüldüğünde, modele yüksek sapmalı veri verildiği anlaşılmaktadır. Nitekim, model 0.99 eğitim doğruluğu elde ederken test doğruluğu yalnızca 0.56 da sınırlı kalmıştır. Bu sebeple, veri seti sınıflar arası dağılım korunarak Modelin eğitimi 1 saat 20 dakika sürmüştür. Grup boyutu 4, görüntü boyutu olarak ise 832x832 parametreleri kullanılmıştır. Bu parametreler Kaggle websitesinin sağladığı GPU kullanılarak eğitilebilecek deneme yanılma yoluyla bulunmuş en yüksek parametrelerdir. Bu eğitimden sonra veri seti dağılımı korunarak tekrar bölünmüştür. Bu sayede daha tutarlı sonuçlar elde edilebilmiştir.

Modeller her train epoch'u sonunda validasyon veri setiyle test edilmiştir. **Eğitim sonunda en iyi model en yüksek test doğruluğuna göre seçilmiştir.** Fakat eğitim sırasında **test değerleri modelin ağırlıklarını değiştirmek için kullanılmamıştır.**

Model 1: BI-RADS0 / BI-RADS1-2 / BI-RADS4-5 sınıflandırması

Veri seti sınıf dağılımlarına göre tekrar bölündükten sonra eğitim tekrarlanmıştır. EfficientNet-b3 modeli; transfer öğrenmesi kullanılarak, 85 epoch boyunca, 4 grup boyutu ve 832x832 fotoğraf boyutuyla eğitilmiştir. Eğitim verisetinde 0.994 doğruluk elde edilirken, test verisetinde doğruluk 0.6851 seviyesine çıkabilmiştir. Bu durum, modelin parametre sayısının

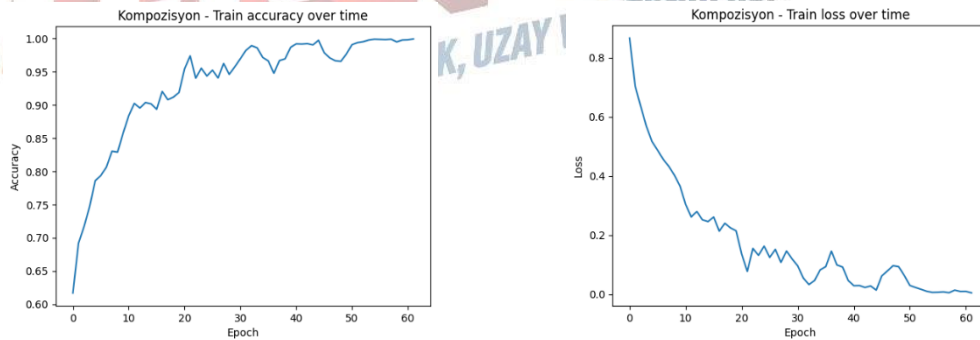
fazla olduğunu, eğitim verisini öğrenmek yerine ezberlediğini göstermektedir. Dağılımlara dikkat edilmeyen veriseti kullanılarak eğitilen model ile elde edilen 0.58 doğruluk değeri bu sayede 0.68 seviyesine çıkarılmıştır. Modelin sonuçları *Resim 4*'deki gibidir.




Resim 4 – BI-RADS sınıflandırması yapan modelin metrikleri

Model 2: A / B / C / D Kompozisyon sınıflandırması

Veri seti A / B / C / D sınıflandırması için 4 sınıfa ayrılmıştır. Sınıflar arası BI-RADS dağılımları korunmuştur. EfficientNet-b3 modeli; transfer öğrenmesi kullanılarak 61 epoch boyunca 4 grup boyutu ve 832x832 fotoğraf boyutu değerleriyle eğitilmiştir. Eğitim verisetinde 0.991, test veri setinde 0.6524 doğruluk değeri elde edilmiştir. Modelin sonuçları *Resim 5*'deki gibidir.





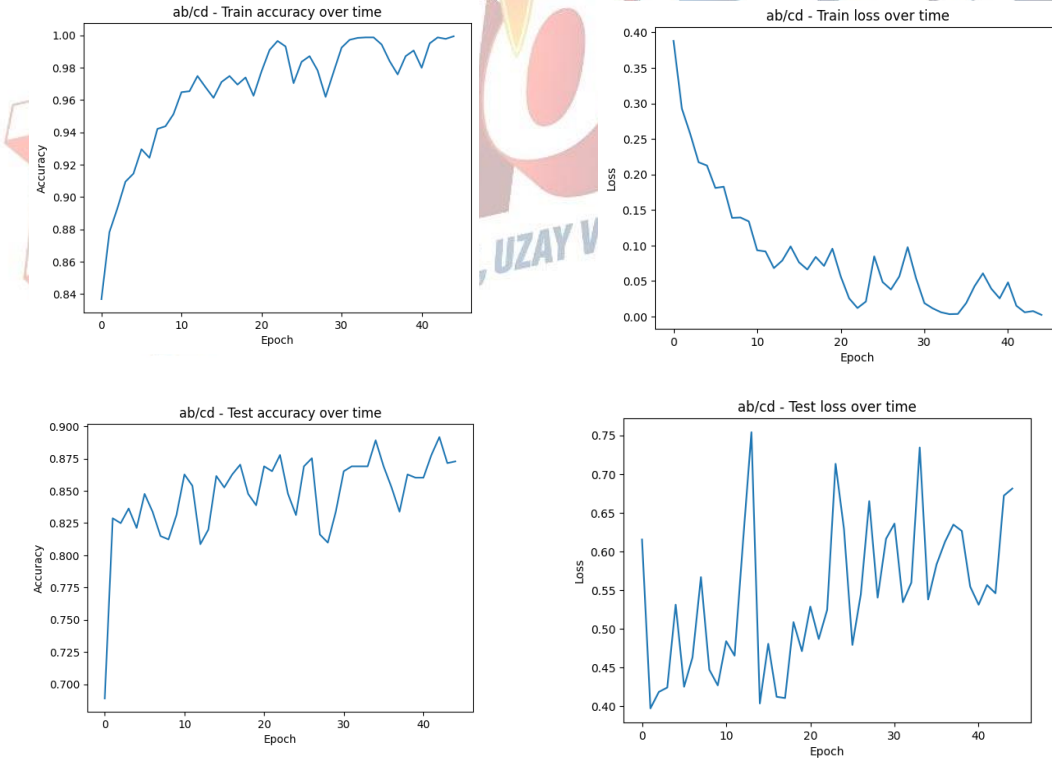
Resim 5 – Kompozisyon sınıflandırması yapan modelin metrikleri

Ansaml Model Ağ Yapısı:

Proje mevcut durum değerlendirmesinde de bahsedildiği üzere, meme kompozisyonunun BI-RADS skorunu etkilediği görülmüştür. Bu sebeple, ilk önce veri setini AB veya CD olacak şekilde sınıflandıran, ardından da A ve B sınıfları için BI-RADS sınıflandırması yapan ayrı bir model, C ve D sınıfları için BI-RADS sınıflandırması yapan ayrı bir model eğitilmiştir.

Model AB/CD:

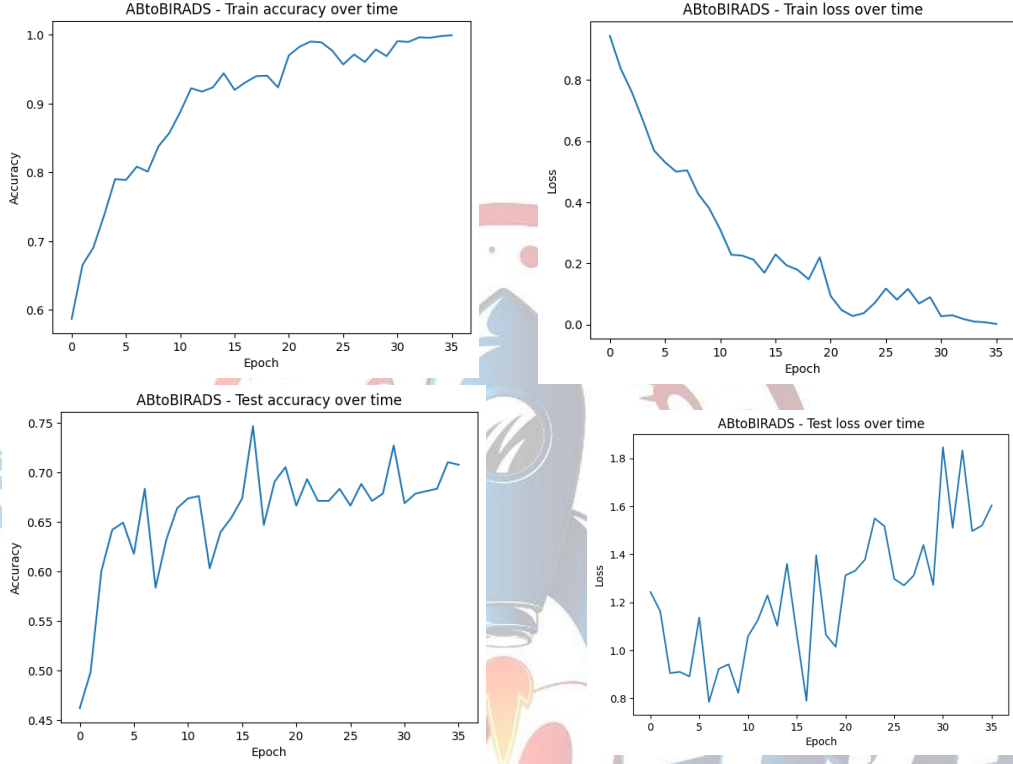
Bu model, A veya B / C veya D sınıflandırması yapan modeldir. Modelin eğitimi sırasında transfer öğrenmesi kullanılmış; 44 epoch boyunca, 4 grup boyutu ve 832x832 görüntü boyutu ile eğitilmiştir. Eğitim sonucunda eğitim doğruluğu 0.994, test doğruluğu ise 0.8917 olarak ölçülmüştür. Model sonuçları Resim 6'daki gibidir.



Resim 6 - AB / CD sınıflandırması yapan modelin metrikleri

Model *ABtoBI-RADS* :


Bu model, A ve B sınıfları için BI-RADS sınıfı tahmini yapan modeldir. Eğitim sırasında transfer öğrenmesi kullanılmış; 35 epoch boyunca ve 4 grup sayısı ile eğitim yapılmıştır. Eğitim doğruluğu olarak 0.994, test doğruluğu olarak ise 0.7470 elde edilmiştir. Modelin sonuçları *Resim 7*'deki gibidir.




Resim 7 – ABtoBI-RADS modelinin metrikleri

Model *CDtoBIRADS* :

Bu model, C ve D sınıfları için BI-RADS sınıfı tahmini yapan modeldir. Eğitim sırasında transfer öğrenmesi kullanılmış; 37 epoch boyunca ve 4 grup sayısı ile eğitim yapılmıştır. Eğitim doğruluğu olarak 0.994, test doğruluğu olarak ise 0.6745 elde edilmiştir. Modelin sonuçları *Resim 8*'deki gibidir.





Resim 8 – CDtoBI-RADS modelinin metrikleri

Ansambl model ağı sonuçlarına bakıldığında, AB/CD sınıflandırması için doğruluğu 0.89, A ve B için test doğruluğu 0.74, C ve D için test doğruluğu 0.6745 olarak elde edilmiştir. Kompozisyona göre eğitilmiş modeller birlikte kullanıldığında 0.6713 doğruluk oranına sahip olan BI-RADS modelinin performansını aşmayı başarmıştır. Bu sonuçlar, kompozisyonun BI-RADS sınıflandırmasını etkilediği hipotezimizi doğrulamaktadır.

4. Deney ve eğitim aşamalarında kullanılan veri setleri

Yarışmada hastanın sağ ve sol CC ve MLO mamografilerinden BI-RADS sınıfı, meme kompozisyonu ve kadran bilgisi tahmin edilmesi istenmektedir. Tahminlerin doğruluğuna göre BI-RADS skoru için 0.70, BI-RADS skoru doğru ise meme kompozisyonu ve kadran bilgisi bilgilerinin her birinden 0.15 puan elde edilmektedir. Doğruluğu arttırmak için Sağlık Bakanlığı tarafından sağlanan veri seti haricinde araştırmacıların kullanımına açık olan çeşitli veri setleri kullanılmıştır.

Ek veri seti olarak çeşitli kaynaklardan literatür taranarak Sağlık Bakanlığı tarafından sağlanan veri setine en yakın olan veri setlerini seçmeye çalıştık. Bunlar DDSM [7,8], INbreast [9] ve VinDr-Mammo [10,11] 'dur. Veri setlerindeki görüntüleri JPG formatına çevirdik.

DDSM veri seti; Massachusetts Genel Hastanesi, Wake Forest Üniversitesi Tıp Fakültesi, Sacred Heart Hastanesi ve Washington Üniversitesi St Louis Tıp Fakültesi kaynaklarından toplanan verilerle Michael Heath ve arkadaşları tarafından oluşturulmuş bir koleksiyondur.

Vakalar; kalsifikasyonlar ve kitleler için ROI'lerin yanı sıra CADe ve CAD algoritmaları için yararlı olabilecek aşağıdaki bilgilerle açıklanmıştır: Kitle şekli, kitle marjı, kalsifikasyon tipi, kalsifikasyon için BI-RADS tanımlayıcıları dağılım ve meme yoğunluğu; 0'dan 5'e kadar genel BI-RADS değerlendirme; anormalliğin incelik derecesi 1'den 5'e kadar; ve hasta yaşı. Veri tabanında yaklaşık 2.500 çalışma bulunmaktadır. Her çalışma; her bir göğüse ait ikişer görüntü ile birlikte, bazı hasta bilgilerine (çalışma sırasındaki yaş, ACR meme yoğunluğu derecesi, anormallikler için incelik derecesi, anormalliklerin ACR anahtar kelimesi açıklaması) ve görüntü bilgilerine (tarayıcı, uzamsal, çözünürlük, ...) ait bilgiler içermektedir.

Bir vaka, 6 ila 10 dosyadan oluşur. Bunlar bir "ics" dosyası, bir genel bakış "16-bit PGM" dosyası, kayıpsız JPEG kodlamasıyla sıkıştırılmış dört görüntü dosyası ve sıfır ila dört adet bindirme dosyasıdır. Şüpheli alanlar içeren resimler, şüpheli bölgelerin konumları ve türleri hakkında ilişkili piksel düzeyinde "gerçek referans değer" bilgisine sahiptir.

Veri setiyle birlikte ayrıca, hem mamograma ve gerçek görüntülere erişim hem de otomatik görüntü analizi algoritmaları için performans rakamlarını hesaplamak için yazılım sağlanmaktadır. DDSM veri seti <http://www.eng.usf.edu/cvprg/mammography/database.html> web adresinden indirilebilir ve bu adresten veri seti hakkında daha detaylı bilgiye ulaşılabilir.

Kullandığımız bir diğer veri seti ise Ines C. Moreira ve arkadaşları tarafından ortaya konulan INbreast veri setidir. Görüntüler, Portekiz Ulusal Veri Koruma Komitesi ve Hastane Etik Kurulu'nun izniyle bir üniversite hastanesinde (Centro Hospitalar de S. João [CHSJ], Göğüs Merkezi, Porto) bulunan bir meme merkezinden alınmıştır. INbreast toplam 115 vakayı (410 resim) içerir ve bunların 90 vakası her iki göğsü de etkilenen kadınlardan (vaka başına dört resim) ve 25 vaka mastektomi hastalarındandır (vaka başına iki resim). Veri setine; çeşitli lezyon türleri (kitleler, kalsifikasyonlar, asimetrikler ve bozulmalar) dahil edilmiştir. Uzmanlar tarafından yapılan doğru konturlar da XML formatında sağlanmıştır. INbreast'in bazı güçlü yönleri: dijitalleştirilmiş mamogramların aksine tam alanlı dijital mamogramlarla oluşturulmuş olması , çok çeşitli vakalar sunması ve kesin açıklamalarla birlikte halka açık hale getirilmesidir. Veri tabanında normal mamogram örnekleri, kitleli mamogramlar, kalsifikasyonlu mamogramlar, mimari bozulmalar, asimetrikler ve çoklu bulgulu görüntüler yer alır. Görüntüler DICOM formatında kaydedilmiştir. Ardından biz de bu fotoğrafları JPG formatına çevirerek eğitim süresince kullandık.

VinDr-Mammo veri seti, Hieu Huy Pham ve arkadaşları tarafından sunulan BI-RADS sistemi takiben kanser değerlendirmesi ve meme yoğunluğu tespitini sağlamak amacıyla deneyimli mamografi uzmanları tarafından birden fazla kez okunmuş, 5.000 dördümlü incelemeden oluşan büyük ölçekli bir tam alan dijital mamografi (FFDM) veri setidir. Veri setinde bulunan daha fazla inceleme gerektiren meme anormallikleri de sınırlayıcı dikkörtgenlerle işaretlenmiştir. Veri setini oluşturan araştırmacıların iddiasına göre, VinDr-Mammo veri seti şu anda BI-RADS değerlendirmesi ve anormallik açıklamaları içeren tam alanlı dijital mamografi içeren en büyük halka açık veri setidir. HMUH ve H108'in Resim Arşivleme ve İletişim Sistemlerinde (PACS) saklanan 2018 ve 2020 yılları arasında alınan mamografi incelemeleri havuzundan, toplam 20.000 görüntüye karşılık gelen 5.000 mamografi incelemesi rastgele örneklenip ardından kimlik bilgileri kaldırılmıştır. Veri seti, hem memenin genel değerlendirmesini hem de memedeki anormal bölgeler hakkında bilgileri içerir. BI-RADS değerlendirme kategorileri 1'den 5'e; ve meme yoğunluk seviyeleri A, B, C veya D olarak verilmiştir. Anormal bölgelere ilişkin olarak bu çalışmada yer alan bulgu kategorilerinin listesi; kitle, kalsifikasyon, asimetrikler, mimari bozulma ve diğer ilişkili özellikler, yani şüpheli lenf nodu, deri kalınlaşması, deri retraksiyonu ve meme retraksiyonu şeklindedir. Dört anormal kategori (kütle, kalsifikasyon, asimetrikler ve mimari bozulma) de BI-RADS olarak değerlendirilir. Görüntü üzerinde BI-RADS 2'nin bulguları işaretlenmemiştir. Sadece takip muayenesi gerektiren BI-RADS 3, 4 veya 5'in bulguları sınırlayıcı kutularla işaretlenmiştir. Sağlık Bakanlığı tarafından paylaşılan veriye benzer şekilde, VinDr-Mammo veri setinde de mamografilerin BI-RADS kategorileri her hasta için ayrı ayrı belirtilmiştir. Bu sayede veri setini Sağlık Bakanlığı veri seti formatına uyarlamak zahmetli olmamıştır.

5. Referanslar (5 puan)

- [1] Tan, M. et al. (2020). Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 10781-10790.
- [2] Brock, A. et al. (2021). High-Performance Large-Scale Image Recognition Without Normalization preprint arXiv:2102.06171v1.
- [3] Yu, J. et al. (2022). CoCa: Contrastive Captioners are Image-Text Foundation Models. preprint arXiv:2205.01917v2.
- [4] Liu, Z. et al. (2022). Swin Transformer V2: Scaling Up Capacity and Resolution. preprint arXiv:2111.09883v2.
- [5] Girshick, R. (2013). Rich feature hierarchies for accurate object detection and semantic segmentation. preprint arXiv:1311.2524v5.
- [6] Zonderland, H. ve Smithuis, R. (2013). Bi-RADS for Mammography and Ultrasound 2013. Retrieved from: <https://radiologyassistant.nl/breast/bi-rads/bi-rads-for-mammography-and-ultrasound-2013> (Son Erişim Tarihi: 23 Ocak 2023)
- [7] The Digital Database for Screening Mammography, Michael Heath, Kevin Bowyer, Daniel Kopans, Richard Moore and W. Philip Kegelmeyer, in Proceedings of the Fifth International Workshop on Digital Mammography, M.J. Yaffe, ed., 212-218, Medical Physics Publishing, 2001. ISBN 1-930524-00-5. 8.
- [8] Current status of the Digital Database for Screening Mammography, Michael Heath, Kevin Bowyer, Daniel Kopans, W. Philip Kegelmeyer, Richard Moore, Kyong Chang, and S. Munish Kumaran, in Digital Mammography, 457-460, Kluwer Academic Publishers, 1998; Proceedings of the Fourth International Workshop on Digital Mammography.
- [9] Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J., & Cardoso, J. S. (2012). INbreast: toward a full-field digital mammographic database. Academic radiology, 19(2), 236–248. <https://doi.org/10.1016/j.acra.2011.09.014>
- [10] Pham, H. H., Nguyen Trung, H., & Nguyen, H. Q. (2022). VinDr-Mammo: A largescale benchmark dataset for computer-aided detection and diagnosis in full-field digital mammography (version 1.0.0). PhysioNet. <https://doi.org/10.13026/br2v-7517>. 5.
- [11] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. Circulation [Online]. 101 (23), pp. e215–e220.