

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**KARACİĞER HASTALIĞININ BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDEN DERİN AĞ MİMARİSİ İLE TEŞHİS EDİLMESİNİ
İYİLEŞTİRMEK İÇİN EN UYGUN VERİ ARTIRMA TEKNİĞİNİN
ARAŞTIRILMASI**

Elnura ADIGOZALOVA

**FEN BİLİMLERİ ENSTİTÜSÜ
BIYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

HAZİRAN 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**KARACİĞER HASTALIĞININ BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDEN DERİN AĞ MİMARİSİ İLE TEŞHİS EDİLMESİNİ
İYİLEŞTİRMEK İÇİN EN UYGUN VERİ ARTIRMA TEKNİĞİNİN
ARAŞTIRILMASI**

Elnura ADIGOZALOVA

**FEN BİLİMLERİ ENSTİTÜSÜ
BIYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

HAZİRAN 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KARACİĞER HASTALIĞININ BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDEN DERİN AĞ MİMARİSİ İLE TEŞHİS EDİLMESİNİ
İYİLEŞTİRMEK İÇİN EN UYGUN VERİ ARTIRMA TEKNİĞİNİN
ARAŞTIRILMASI**

**Elnura ADIGOZALOVA
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

HAZİRAN 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KARACİĞER HASTALIĞININ BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDEN DERİN AĞ MİMARİSİ İLE TEŞHİS EDİLMESİNİ
İYİLEŞTİRMEK İÇİN EN UYGUN VERİ ARTIRMA TEKNİĞİNİN
ARAŞTIRILMASI**

Elnura ADIGOZALOVA
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 12/06/2023 tarihinde jüri tarafından Oybirliği / Oylukluğu ile kabul edilmiştir.

Doç. Dr. Evgin GÖÇERİ (Danışman)

Doç. Dr. Çiğdem SARAÇ

Dr. Öğr. Üyesi Turgay BATBAT

ÖZET

KARACİĞER HASTALIĞININ BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN DERİN AĞ MİMARİSİ İLE TEŞHİS EDİLMESİNİ İYİLEŞTİRMEK İÇİN EN UYGUN VERİ ARTIRMA TEKNİĞİNİN ARAŞTIRILMASI

Elnura ADIGOZALOVA

Yüksek Lisans Tezi, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Evgin GÖÇERİ

Haziran 2023; 26 sayfa

Karaciğer hastalığının otomatik olarak teşhis edilmesi için son zamanlarda derin öğrenmeye dayalı yöntemler geliştirilmektedir. Derin öğrenme teknikleri ile yapılan görüntü sınıflandırma yaklaşımlarında ağ mimarilerinin eğitilmesi ve test edilmesi için çok sayıda veriye ihtiyaç duyulmaktadır. Fakat tıbbi alanda tedarik edilen görüntüler yetersiz sayıdadır. Bu nedenle çeşitli veri artırma yöntemleri uygulanmakta ve artırılmış sayıdaki veriler ile ağ mimarilerinin eğitilmesi sağlanmaktadır. Fakat, literatürdeki çalışmalarda farklı türden görüntülerin kullanılmış olması, farklı ağ mimarilerinin kullanılması, bu mimarilerin farklı sayılardaki eğitim ve test veri setleri ile eğitilip test edilmesi nedeniyle hangi veri artırma tekniğinin hangi görüntü türü için daha başarılı sonucun elde edilmesini sağladığı net değildir. Bu nedenle, bu tez çalışmasında literatürdeki karaciğer görüntüleri ile yaygın olarak uygulanmış olan veri artırma teknikleri incelendikten sonra görüntülerin sınıflandırılması üzerindeki etkileri karşılaştırılıp en etkili olan veri artırma yaklaşımı belirlenmiştir. Bu tez kapsamında yapılan çalışmalarda, on adet veri artırma tekniği uygulanmış, her teknikten elde edilen artırılmış sayıdaki görüntüler ile eğitim ve test veri setleri oluşturulmuştur. Tasarlanan evrimsel ve artık bağlantıların olduğu bir derin sinir ağ mimarisi oluşturulan on eğitim seti ile eğitildikten sonra test setleri ile test edilmiştir. Dolayısı ile uygulanan veri artırma tekniklerinin sayısı kadar sınıflandırma işlemi gerçekleştirilmiş olup her sınıflandırma işleminin sonuçları beş farklı sayısal değerlendirme ölçütü kullanılarak değerlendirilmiştir. Bütünleşik olarak uygulanan geometrik dönüşümlere dayalı veri artırma tekniğinin bilgisayarlı tomografi ile çekilen karaciğer görüntülerinin yüksek performans ile sınıflandırılmasında en uygun teknik olduğu belirlenmiştir. Bununla birlikte, tuz-biber tipi gürültüsü ve kayma ile veri artırımının sağlanması görüntülerin sınıflandırma performansını en az artıran yaklaşım olduğu da tespit edilmiştir.

ANAHTAR KELİMELE: Derin öğrenme, Görüntü sınıflandırma, Karaciğer görüntüleri, Karaciğer hastalık teşhisi, Veri artırma teknikleri

JÜRİ: Doç. Dr. Evgin GÖÇERİ

Doç. Dr. Çiğdem SARAÇ

Dr. Öğr. Üyesi Turgay BATBAT

ABSTRACT

INVESTIGATION OF THE OPTIMAL DATA AUGMENTATION TECHNIQUE TO IMPROVE LIVER DISEASE DIAGNOSIS WITH A DEEP NETWORK ARCHITECTURE FROM COMPUTED TOMOGRAPHY IMAGES

Elnura ADIGOZALOVA

MSc Thesis in Biomedical Engineering

Supervisor: Assoc. Prof. Dr. Evgin GÖÇERİ

June 2023; 26 pages

Recently, deep learning-based methods have been developed for the automatic diagnosis of liver disease. In image classification approaches with deep learning techniques, a large amount of data is needed to train and test network architectures. However, the number of images supplied in the medical field is insufficient. For this reason, various data augmentation methods are applied and network architectures are trained with the increased number of data. However, since the studies in the literature use different types of images, use different network architectures, train and test these architectures with different numbers of training and test data sets, it is not clear which data augmentation technique provides more successful results for which image type. Therefore, in this thesis, after analysis of the data augmentation techniques applied to liver images in the literature, the most effective data augmentation approach has been determined by comparing their effects on the classification of the images. In the studies carried out within the scope of this thesis, ten data augmentation techniques have been applied, training and test data sets have been created with the increased number of images obtained from each technique. A deep neural network architecture with convolutional and residual connections designed has been trained with ten training sets and then tested with test sets. Therefore, classification processes have been carried out as much as the number of data augmentation techniques applied, and the results of each classification process have been evaluated using five different numerical evaluation criteria. It has been determined that the data augmentation technique based on geometric transformations applied integratedly is the most appropriate technique for the classification of liver images taken by computed tomography with high performance. In addition, it has also been determined that providing data augmentation with salt-pepper type noise and shear is the approach that least improves the classification performance of the images.

KEYWORDS: Data augmentation techniques, Deep learning, Image classification, Liver images, Liver disease diagnosis

COMMITTEE: Assoc. Prof. Dr. Evgin GÖÇERİ

Assoc. Prof. Dr. Çiğdem SARAÇ

Asst. Prof. Dr. Turgay BATBAT

ÖNSÖZ

Bu tez çalışmasının oluşmasında ve çalışmaların her aşamasında yardımcı olan, desteğini esirgemeyen ve bana emeği geçen danışman hocam Doç. Dr. Evgin GÖÇERİ'ye sonsuz teşekkürlerimi sunarım.

Yüksek lisans eğitimim boyunca bana kattıkları değerli bilgiler için Akdeniz Üniversitesi Biyomedikal Mühendisliği Bölümü'ndeki tüm öğretim üyelerine teşekkür ederim.

Akdeniz Üniversitesinde yüksek lisans eğitimi alma, farklı bir ülkede farklı deneyimler edinmem imkanını sağlayan Yurtdışı Türkler ve Akraba Toplulukları koordinasyonunda yürütülen Türkiye Bursları programına minnettarlığımı bildiririm.

Bu süre boyunca manevi ve psikolojik desteğini esirgemeyen ve hep yanımda olan arkadaşım Mehriban ALİYEVA'ya teşekkür ederim.

Son olarak eğitim hayatım boyunca hep daha iyisi için teşvik eden, bana hep inanan aileme sevgi ve teşekkürlerimle...

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ.....	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
3. MATERYAL VE METOT	7
3.1. Materyal.....	7
3.2. Metot	8
3.2.1. Uygulanan veri artırma yöntemleri.....	8
3.2.2. Verilerin Sınıflandırılması.....	9
3.2.3. Bulguların değerlendirilmesi için kullanılan sayısal ölçütler	13
4. BULGULAR.....	16
5. TARTIŞMA	18
6. SONUÇLAR	21
7. KAYNAKLAR	23
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Karaciğer Hastalığının Bilgisayarlı Tomografi Görüntülerinden Derin Ağ Mimarisi ile Teşhis Edilmesini İyileştirmek için En Uygun Veri Artırma Tekniğinin Araştırılması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

12/06/2023

Elnura ADIGOZALOVA

SİMGELER VE KISALTMALAR

Simgeler

- . : Ondalık ayırıcı
G : Görüntü verisi
N : Eklenen gürültü
S : Sabit sayı

Kısaltmalar

- AFLD : Alcoholic Fatty Liver Disease
BT : Computed Tomography (CT)
CNN : Convolutional Neural Network
CR : Cholangiocarcinoma
GAN : Generative Adversarial Network
HCC : Hepatocellular Carcinoma
MRI : Magnetic Rezonans Imaging
MKK : Mathew Korelasyon Katsayısı
NAFLD : Non-Alcoholic Fatty Liver Disease
R-CNN : Region-based CNN

ŞEKİLLER DİZİNİ

Şekil 1.1. Tümör içeren karaciğer görüntü örnekleri.....	1
Şekil 3.1. Karaciğer görüntü örnekleri (a,b,c,d), sarı çerçeve içinde gösterilen karaciğer tümörleri (e,f,g,h), ikilik (<i>binary</i>) olarak gösterilen tümör görüntüleri (i,j,k,l)	7
Şekil 3.2. Bir evrişimsel derin ağ mimarisinin katmanları	10
Şekil 3.3. Artık bağlantı içeren yapı	11
Şekil 3.4. ResNet18	12



ÇİZELGELER DİZİNİ

Çizelge 4.1. Uygulanan veri artırma yöntemleri, bir tane görüntüden elde edilen görüntü sayısı.....	16
Çizelge 4.2. Veri artırma yöntemlerinden sağlanan veriler ile sınıflandırma sonuçları.....	17



1. GİRİŞ

Günümüzde, dünya çapında hastalık ve ölümlerin ana nedenlerinden biri olan karaciğer hastalıkları başlıca olarak viral hepatit, karaciğer fibrozu, metabolik yağlı karaciğer hastalığı (*Non-Alcoholic Fatty Liver Disease (NAFLD)*), alkole bağlı yağlı karaciğer hastalığı (*Alcoholic Fatty Liver Disease (AFLD)*), karaciğer sirozu, hepatosellüler-karsinom (*Hepatocellular Carcinoma (HCC)*) ve kolanjiyo-karsinom (*cholangiocarcinoma (CR)*) gibi karaciğer kanserlerinden oluşmaktadır (Khan vd. 2022; Wang vd. 2023; Law vd. 2023). Karaciğer hastalıkları (siroz, viral hepatit ve karaciğer kanseri) iki milyondan fazla ölüme neden olmakta ve dünya genelindeki tüm ölümlerin %4'ünü oluşturmaktadır ve bu rakamın 2040 yılına kadar hızla artacağı öngörülmektedir (Araújo vd. 2021). En yaygın kronik karaciğer hastalığı olarak bilinen NAFLD'nin küresel yaygınlığı %25.2'ye ulaşmış durumdadır ve 2030 yılına kadar %33.5 olacağı tahmin edilmektedir (Ye vd. 2022; Krishnan vd. 2023).

Bazı karaciğer hastalıkları, hafif ve geçici semptomlara neden olurken, bazıları da ölümcül olabilmekte ve ciddi, kalıcı hasarlara yol açabilmektedir. NAFLD, karaciğer kanseri, siroz gibi karaciğer hastalıklarının erken evrede teşhis edilmesi ile ilgili özel testler yapılmadığı müddetce herhangi bir belirti göstermemektedir. Karaciğer hastalıklarının erken safhada ve doğru teşhis edilmesi hastanın iyileşme oranını büyük ölçüde etkilemekte, karaciğer bozukluğu ve karaciğer yetmezliği gibi hastalıklardan kaynaklanan ölüm riskini azaltmaktadır (Bai vd. 2019; Krishan ve Mittal 2021; Duell vd. 2022; Prakash ve Saradra 2022).

Karaciğer hastalıklarının erken evrede, hızlı ve doğru teşhis edilebilmesi için otomatik yöntemler önerilmekte ve son yıllarda derin öğrenmeye dayalı teknikler geliştirilmektedir. Fakat bu teknikler ile karaciğer tümörlerinin tespit edilmesi, sağlıklı ve sağlıklı karaciğer görüntülerinin otomatik olarak sınıflandırılması, özellikle tümörlerin küçük olması, kenarlarının belirsiz olması ve karaciğer dokusu ile benzer renk yoğunluğuna sahip olması durumunda oldukça zordur. Şekil 1.1'de bilgisayarlı tomografi (*BT (Computed Tomography (CT))*) cihazı ile elde edilmiş olan ve tümörlü dokunun otomatik olarak tespit edilmesinin zor olduğu örnek karaciğer kesitleri (Soler vd. 2010) yer almaktadır.



Şekil 1.1. Tümör içeren karaciğer görüntü örnekleri (Soler vd. 2010)

Ayrıca, derin öğrenmeye dayalı olarak yapılan çalışmalarda ağ mimarisinin eğitilmesi ve test edilmesi için çok sayıda veriye ihtiyaç duyulmaktadır. Fakat tıbbi alanda yeterli miktarda eğitim verisinin olmaması bu çalışmalar için en önemli engellerden biri olmaya devam etmektedir. Bu durumun temel nedenlerini, bazı hastalıklar için yeterli sayıda hasta olmaması, hastaların görüntülerinin kullanılmasına izin vermek istememeleri, tıbbi cihaz veya donanımın eksikliği, istenilen kriterlere uygun görüntülerin elde edilememesi olarak özetlemek mümkündür. Bu sebepten dolayı, veri örnekleri üretebilen ve derin sinir ağlarının etkili bir şekilde eğitilmesini sağlayacak stratejilerine ihtiyaç duymaktadır (Garcea vd. 2022). Bu sorunun en aza indirgenebilmesi için olası çözümlerden biri, mevcut gözlemlere dayalı olarak yeni ek gözlemler oluşturmak ve bu sayede eğitim veri setinin boyutunu artırmak için tasarlanmış düzenleme yöntemlerinden biri olan veri artırmadır. (Lewy ve Mańdziuk 2022).

Ağ mimarisinin genelleme hatasını azaltmak için bir tür düzenleme tekniği olarak kabul edilebilen veri artırma yöntemleri, eğitim setindeki görüntülerin kullanılması ile hastaların edinimindeki ve anatomik yapılarındaki değişikliklerin benzetimini sağlayan temsili örnekler oluşturmak için uygulanan yöntemlerdir. Bu yöntemler ile oluşturulan yeni veriler, ağ yapısının orijinal eğitim verilerine çok özel olan özellikleri öğrenmekten kaçınmasına yardımcı olmalı, bu nedenden dolayı da ağı daha genelleştirilebilir bir hale getirebilmeli ve sonuç olarak test setleri ile yapılan uygulamaların performanslarını artırmalıdır (Chlap vd. 2021).

Derin öğrenmeye dayalı olarak gerçekleştirilen sınıflandırmalarda, veri kümelerindeki sınıf dağılımlarının dengesizliği de bir başka yaygın olan zorluktur. Örneğin, bir sınıfın (azınlık sınıfı) diğer sınıftan (çoğunluk sınıfı) önemli ölçüde daha az sayıda örnek veri içermesi durumunda, ikili sınıflandırma sorunları ortaya çıkmaktadır. Bu nedenle, ağ yapısı çoğunluk sınıfına doğru önyargılı (tarafli) olabilmekte ve genellikle sınıflandırma işlemleri beklenmedik bulgular veya düşük performans ile sonuçlanabilmektedir. Bu durumda azınlık sınıfındaki görüntülerin artırılması dengesizlik sorununu en aza indirebilmek için etkili bir çözüm olmaktadır (Oza vd. 2022).

Bölüm 2’de açıklandığı gibi, literatürdeki çalışmalarda derin öğrenmeye dayalı yaklaşımlardan yüksek başarı oranı ile sonuçların elde edilebilmesi için çeşitli veri artırma yöntemleri uygulanmış ve artırılmış sayıdaki veriler ağ mimarisinin eğitilmesinde kullanılmıştır. Fakat literatürdeki çalışmalarda farklı ağ mimarileri ile sınıflandırmaların yapılmış olması, farklı görüntüleme cihazları ile elde edilen görüntülerin kullanılmış olması, ağ mimarilerinin farklı sayıda veri setiyle eğitilip test edilmesi nedeniyle hangi veri artırma tekniğinin sınıflandırma performansının artmasında en etkili yaklaşım olduğu net değildir. Bu nedenle, gerçekleştirilen bu tez çalışmasında, literatürdeki karaciğer görüntüleri ile yaygın olarak uygulanmış olan veri artırma teknikleri incelendikten sonra görüntülerin sınıflandırılması üzerindeki etkileri karşılaştırılıp en etkili olan veri artırma yaklaşımı belirlenmiştir. Bu tez kapsamında yapılan çalışmalarda, on adet veri artırma tekniği uygulanmış, her teknikten elde edilen artırılmış sayıdaki görüntüler ile eğitim ve test veri setleri oluşturulmuştur. Tasarlanan evrimsel ve artık bağlantıların olduğu bir derin sinir ağ mimarisi oluşturulan on eğitim seti ile eğitildikten sonra test setleri ile test edilmiştir. Dolayısı ile uygulanan veri artırma tekniklerinin sayısı kadar sınıflandırma işlemi gerçekleştirilmiş olup her

sınıflandırma işleminin sonuçları beş farklı sayısal değerlendirme ölçütü kullanılarak değerlendirilmiştir.

Bu tez kapsamında yapılan çalışmalarda, literatürde kullanılmış olan veri artırma tekniklerinin BT ile çekilmiş karaciğer görüntüleri üzerine uygulanmış olması, bu görüntü türlerinden tümör içeren ve içermeyen karaciğer görüntülerinin derin ağ mimarisi ile otomatik olarak sınıflandırılmasında yüksek performansı sağlamak için en uygun veri artırma yönteminin belirlenmiş olması, veri artırma tekniklerinin bu görüntüler ile kullanıldığında sağladığı avantaj ve dezavantajlarının belirlenmiş olması nedeniyle bu çalışma literatürdeki çalışmalardan farklıdır. Yapılmış çalışmalar incelendiğinde bu özelliklere sahip bir çalışmaya rastlanılmamıştır.

Bu tez çalışmasından elde edilen bulgular, otomatik olarak karaciğer sınıflandırma işlemini gerçekleştirmek üzere derin öğrenmeye dayalı teknikler geliştiren araştırmacılara, yüksek performans ile sonuçların elde edilmesini sağlayacak veri artırma yöntemini tercih etmelerine yardımcı olacaktır. Bununla birlikte, araştırmacıların kullandıkları görüntü türüne uygun olan veri artırma yöntemini, avantaj ve dezavantajlarını da tespit etmelerine yardımcı olacaktır.

Tez çalışmasının birinci bölümünde karaciğer hastalıkları, önemi ve yaygınlığı, derin öğrenmeye dayalı yaklaşımlarda veri artırma tekniklerinin gerekliliği ile ilgili bilgilere değinilmiştir. İkinci bölümde, literatürde karaciğer görüntüleri üzerine veri artırma tekniklerinin uygulandığı çalışmalar sunulmuştur. Üçüncü bölümde bu tez çalışması kapsamında kullanılan materyal ve uygulanan yöntemler açıklanmıştır. Dördüncü bölümde, uygulamalardan elde edilen bulgulara yer verilmiştir. Beşinci bölümde çalışmalarımızda kullanılan teknikler hakkında tartışmalara yer verilmiş ve son bölümde de ulaşılan sonuçlar açıklanmıştır.

2. KAYNAK TARAMASI

Literatürdeki güncel çalışmalarda karaciğer görüntüleri ile uygulanan derin öğrenmeye dayalı yaklaşımlardan yüksek performans elde edilebilmesi için çeşitli veri artırma yöntemleri uygulanmıştır. Uygulanan veri artırma yöntemleri incelendiğinde, kayma, konum değiştirme, görüntülerin dikey ve yatay olarak veya rastgele açılarla döndürülmesi, gürültü ekleme, renk uzayı dönüştürerek veri artırımının sağlanmasının yanı sıra, üretken-düşman ağ (*Generative Adversarial Network (GAN)*) yapısının kullanıldığı da gözlenmektedir (Chaki 2022; Aswathy ve Vinod Chandra 2022; Tiago vd. 2022; Zhang vd. 2022; Lyu vd. 2022; Guan vd. 2022; Bali ve Mahara 2023; El-Shafai vd. 2023).

Örneğin, güncel bir çalışmada manyetik rezonans görüntüleme (*Magnetic Rezonans Imaging (MRI)*) cihazı ile elde edilmiş olan karaciğer görüntülerinin bir evrişimli sinir ağı (*Convolutional Neural Network (CNN)*) kullanılarak otomatik olarak sınıflandırılması sağlanmış ve HCC teşhisi için başarılı sonuçların elde edildiği bulgular ile gösterilmiştir (Kim vd. 2020). Yapılan çalışmada veri setlerindeki görüntü sayılarının artırılması için döndürme, kayma ve yakınlaştırma yöntemleri kullanılmış ve %94 doğruluk değeri ile sınıflandırmanın yapılabildiği belirtilmiştir.

İyi huylu ve kötü huylu tümör içeren karaciğer görüntülerin sınıflandırılması için yakın zamanda gerçekleştirilen bir çalışmada, bölge tabanlı evrişimsel sinir ağı (*Region-based CNN (R-CNN)*) ile sınıflandırma sağlanmış ve %92.6 doğruluk değeri ile sonuçlar elde edilmiştir (Tao vd. 2022). Bu çalışmada karaciğer manyetik rezonans görüntülerinin artırılması için farklı açılarla döndürme ve çevirme (*flipping*) yöntemi kullanılmıştır.

Karaciğer hastalığının erken evrede tespit edilebilmesi amacıyla tümörlerin hızlı ve doğru bir şekilde karaciğer BT görüntülerinden otomatik olarak çıkarılması ve karakteristik özelliklerinin belirlenmesi için geliştirilen bir yaklaşımda, evrişimli ağ katmanlarından oluşan U şeklindeki ağ modeli (*U-Net*) ve *RetinaNet* uygulanarak bölütleme sağlanmıştır (Araújo vd. 2021). Karaciğer BT görüntülerinin kullanıldığı bu çalışmada önerilen yöntemden yüksek performans elde etmek için veri artırma tekniği olarak yatay ve dikey çevirme, döndürme, yatay ve dikey kaydırma uygulanmış, %83.86 hassaslık ve %99.96 özgüllük değerleri ile bölütleme yapılabildiği belirtilmiştir.

Az sayıdaki BT görüntüsü içeren bir veri kümesi kullanılarak karaciğer parankimasından tümörlü dokunun otomatik olarak çıkarılmasını iyileştirmek amacı ile yapılan bir çalışmada, evrişimli katmanlar ile tasarlanan bir derin ağ mimarisi kullanılmış ve veri artırma adımı için döndürme, gürültü ekleme, kaydırma, yakınlaştırma teknikleri uygulanmıştır (Truong vd. 2018). Önerilen yöntem ile zar puanı (*dice score*) ölçütüne göre % 94.58 oranında başarılı sonuçlara ulaşıldığı ve geleneksel yöntemlerden daha iyi bulguların elde edildiği belirtilmiştir.

BT görüntülerinden karaciğer bölütlemeyi iyileştirmek amacı ile yapılan bir başka çalışmada kodlayıcı-kod çözücü mimarisi olan W-Net modeli önerilmiş, eğitim veri kümesini artırmak için döndürme, yatay ve dikey çevirme uygulanmıştır (Khattab vd. 2022). Artırılmış sayıdaki görüntüleri içeren veri kümeleri kullanılarak uygulanan

derin ağ modelinin, U-Net ve U-Net'e dayalı olarak geliştirilen diğer derin ağ modellerine göre daha başarılı sonuçlar verdiği gösterilmiştir.

BT görüntülerinden yüksek performans ile karaciğer organını bitişindeki diğer doku ve organlardan ayırmak için evrimsel katmanlar ve kalıntı ağlarının kullanıldığı bir çalışmada, eğitim veri setlerinin genişletilmesi için rastgele döndürme ve kesme uygulanmıştır (Xu vd. 2021). Sunulan bulgular ile, kullanılan yöntemin benzerlerine göre daha iyi sonuçlar verdiği, zar skor kriterine göre uygulanan yöntemin %86.82 başarılı olduğu gösterilmiştir.

Derin öğrenmeye dayalı olarak karaciğer ve karaciğer tümörlerinin bölütlenmesini gerçekleştirmek için önerilen, çift ölçekli ve evrimsel bir sinir ağının kullanıldığı bir başka çalışmada da veri artırma yöntemi olarak döndürme, kırma ve ölçeklendirme teknikleri uygulanmıştır (Meng vd. 2020). Bu yaklaşım ile elde edilen sonuçlar Hausdorff uzaklık katsayısı hesaplanarak değerlendirildiğinde, tümör bölütleme için bu katsayı değerinin 7.69, karaciğer bölütleme için ise 29.16 olduğu ifade edilmiştir.

Artık ağ (*Residual Network (ResNet)*) ve bir U-Net yapısı birleştirilerek oluşturulan bir ağ mimarisinin kullanıldığı güncel bazı çalışmalarda karaciğer ve tümörleri daha iyi bir performans ile bölütlemek için, BT görüntüleri ile oluşturulan eğitim veri setlerinin genişletilmesi farklı açılarla döndürmeye dayalı olarak gerçekleştirilen veri artırma yöntemi ile sağlanmıştır (Rahman vd. 2022; Sabir vd. 2022). Sunulan deneysel çalışma sonuçlarına göre, uygulanan derin ağ modeline dayalı bölütleme tekniği sayesinde karaciğer ve tümörlü bölgeler yüksek doğrulukla tespit edilip bölütlenebilmektedir. Elde edilen sayısal sonuçların doğruluk kriterine göre değerlendirildiği bir çalışmada %99.23 doğruluk (Rahman vd. 2022), zar skor kriterine göre değerlendirildiği bir çalışmada da % 97 değerine ulaşıldığı belirtilmiştir (Sabir vd. 2022).

MRI ile elde edilen karaciğer görüntülerinden oluşturulmuş veri setlerinin kullanıldığı bir çalışmada, tümörlerin sınıflandırılması için evrimsel katmanlar ile tasarlanan bir derin ağ mimarisi kullanılmış ve veri setlerinin genişletilmesi için döndürme, kesme, çevirme, ölçekleme ve kayma yöntemleri uygulanmıştır (Zhen vd. 2020). Deneysel bulgulara göre, uygulanan yaklaşım ile tümörlerin iyi huylu ve kötü huylu olarak sınıflandırılması %94.6 doğruluk değeri sağlanabilmektedir.

BT cihazı ile elde edilen karaciğer görüntülerinden oluşturulmuş veri setlerinin kullanıldığı bir başka çalışmada, tümörlerin sınıflandırılması için evrimsel katmanlar ile tasarlanan U-Net tabanlı bir derin ağ mimarisi kullanılmış ve veri setlerindeki görüntülerin artırılması döndürme ve kesme yöntemleri ile sağlanmıştır (Szeskin vd. 2022). Bu çalışma ile sınıflandırmanın özgüllük kriterine göre ortalama %97 değeri ile başarılı olduğu belirtilmiştir.

Karaciğer kanserinin tespit edilmesi için geliştirilen bir yaklaşımda, evrimsel katmanların olduğu iki derin ağ mimarisi ile BT görüntülerinden sınıflandırma gerçekleştirilmiş ve döndürmeye dayalı veri artırma tekniği kullanılmıştır (Naaqvi vd. 2022). Yapılan sayısal analizler sonucunda, uygulanan sınıflandırma yönteminin F1 puanına göre %98.75 ve doğruluk kriterine göre %98.5 oranında performans sağladığı ifade edilmiştir.

Karaciğer hastalığının erken evrede teşhis edilebilmesinde ve tedavi sürecinin planlanmasında önemli bir role sahip olan otomatik karaciğer bölütlemesi için, güncel bir çalışmada BT görüntüleri kullanılarak evrişimsel katmanlardan oluşan iki basamaklı U-Net modeli tasarlanmış, yüksek performans ile sonuçların elde edilmesi için veri artırma tekniği olarak döndürme, yatay ve dikey çevirme, ölçeklendirme ve kayma işlemleri uygulanmıştır (Araújo vd. 2022). Geliştirilen yaklaşımın performansı ortalama hassaslık, özgüllük ve zar puanı hesaplanarak incelendiğinde sırası ile %95.45, %99.86 ve %95.64 oranları ile bölütleme yapıldığı gözlenmiştir.


Çok fazlı BT görüntülerinde sağlıklı ve sağlıklı (kansersiz) karaciğer dokularının U-Net mimarisine dayalı kademeli bir evrişimli sinir ağı kullanılarak otomatik bölütlemesini ele alan bir başka çalışmada Gauss gürültüsü eklenmesi, döndürme, yatay veya dikey çevirme, yatay veya dikey kaydırma teknikleri kullanılarak görüntü artırımı sağlanmıştır. Bu çalışmada zar puanına göre değerlendirme yapılmış ve ortalama olarak %78.3 oranında başarı elde edildiği belirtilmiştir (Ouhmich vd. 2019).

Karaciğer BT görüntüleri ile yapılan bir sınıflandırma çalışmasında evrişimsel katmanların olduğu derin ağ yapısı oluşturulmuş ve yüksek performans ile sonuçların elde edilmesi için veri artırma yöntemi olarak GAN yapısı kullanılmıştır (Frid-Adar vd. 2018). Ulaşılan sonuçlar, veri setlerindeki görüntü miktarının artırılması için GAN kullanılarak oluşturulmuş olan yapay görüntülerin kullanılması durumunda sınıflandırma performansını iyileştirdiğini, hassaslık ve özgüllük kriterleri dikkate alınarak yapılan değerlendirmelere göre sırası ile %85.7 ve %92.4 oranında başarılı sonuçlar elde edildiği belirtilmiştir.

3. MATERYAL VE METOT

3.1. Materyal

Bu tez çalışması kapsamında yapılan uygulamalarda kullanılan görüntüler açık erişimli olan 3DIRCADb (Soler vd. 2010) veri tabanından elde edilmiştir. Bu veri tabanı karaciğerinde tümör olan 10 erkek ve 10 kadın olmak üzere toplam 20 farklı hastadan alınmış ve BT cihazı ile çekilmiş olan görüntüler içermektedir. Bu tez çalışmasında 3DIRCADb veri tabanından alınıp kullanılan görüntüler el ile (*manuel*) kenarları tespit edilip diğer organlardan ayrılmış olan karaciğer görüntüleridir. Kullanılan bu görüntülerden, tümör içeren karaciğer görüntü örnekleri Şekil 3.1’de gösterilmiştir. Ayrıca, bu örnek görüntülerdeki tümörlü dokunun olduğu kısım sarı çerçeve içinde ve ikilik (*binary*) olarak da Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Karaciğer görüntü örnekleri (a,b,c,d), sarı çerçeve içinde gösterilen karaciğer tümörleri (e,f,g,h), ikilik (*binary*) olarak gösterilen tümör görüntüleri (i,j,k,l) (Soler vd. 2010)

3.2. Metot

Bu tez çalışmasında, karaciğer görüntülerinin derin öğrenmeye dayalı olarak gerçekleştirilen otomatik sınıflandırma tekniklerinde daha başarılı sonuçların ele alınmasını sağlamak amacı ile kullanılmış olan veri artırma yöntemleri araştırılmış olup, hangi yöntemlerinin hangi parametre değerleri ile uygulanacağı tespit edilmiştir. Belirlenen bu yöntemler Bölüm 3.2.1’de açıklanmış olup, her veri artırma yöntemi uygulandıktan sonra elde edilen verilerin sınıflandırması için kullanılan derin ağ mimari yapısı ve özellikleri de Bölüm 3.2.2’de anlatılmıştır. Sınıflandırma aşamalarından sağlanan sayıların bulguların hangi değerlendirme ölçütleri ile değerlendirildiği ile ilgili açıklamalara da Bölüm 3.2.3’de yer verilmiştir.

3.2.1. Uygulanan veri artırma yöntemleri

Bu tez çalışması kapsamında, literatürde yaygın olarak kullanılan, dönüşümlere ve yoğunluk değerlerinin değiştirilmesine dayalı olarak gerçekleştirilen aşağıdaki veri artırma yöntemleri uygulanmıştır.

1. Yöntem: Bu yöntemde $[-20^\circ, 20^\circ]$ aralığında rastgele seçilen bir açı kullanılarak x ve y ekseninde kayma (*shearing*) işlemi uygulanmıştır. Bu işlem 3 defa 3 farklı açı ile tekrarlanmış olup, bu yöntem ile veri artırma işlemi sonucunda orijinal bir görüntüden 3 görüntü oluşturulmaktadır.
2. Yöntem: Bu yöntemde $[-20, 20]$ aralığında rastgele örneklenen farklı değerler kullanılarak x ve y eksenlerinde öteleme (*translation*) işlemi uygulanmıştır. Bu işlem 3 farklı değer ile 3 defa tekrarlanmış olup, bu yöntem ile veri artırma işlemi sonucunda orijinal bir görüntüden 3 görüntü oluşturulmaktadır.
3. Yöntem: Bu yöntemde $[-30^\circ, 30^\circ]$ aralığında rastgele seçilen 3 farklı döndürme açısı kullanılarak saat yönünde döndürme işlemleri uygulanmıştır. Bu yöntem ile orijinal bir görüntüden 3 görüntü oluşturulmaktadır.
4. Yöntem: Bu yöntemde orijinal bir görüntüye gürültü eklenerek veri artırma sağlanmıştır. Bu aşamada yeni görüntülerin elde edilmesi için kullanılan formül;

$$G = G + (\text{rand}(\text{size}(G)) - S) * N \quad (3.1)$$

olup, bu formülde yer alan N eklenen gürültüyü, S sabit sayıyı ve G görüntü verisini temsil etmektedir. Çalışmalarda Gauss tipi gürültü eklemesi yapılmıştır. Bu gürültü ekleme işlemi için gerekli olan ortalama (*mean*) değeri sıfır alınmış ve değişinti (*variance*) değeri de girdi olarak kullanılan görüntü verisinden elde edilmiştir. Uygulamalarda 0.5, 0.4 ve 0.3 olmak üzere 3 sabit değer kullanılmış ve bu nedenle bir görüntüden 3 görüntü oluşturulmuştur.

5. Yöntem: Bu yöntemde her görüntüye 3 farklı yoğunluk değeri (0.01, 0.02 ve 0.03) ile tuz-biber tipi gürültü eklenerek veri artırma sağlanmış olup, bir orijinal görüntüden 3 görüntü oluşturulmuştur.

6. Yöntem: Bu yöntemde veri artırma işlemi, 5. yöntemdeki gürültü ekleme ve ardından 1. yöntemdeki kayma algoritmalarının uygulanması ile sağlanmıştır. Her orijinal görüntüye 3 farklı yoğunluk değeri ile gürültü eklenip, elde edilen her görüntüye 3 farklı açı ile kayma işlemi uygulandığından, bu yöntem sonucunda her orijinal görüntüden 9 görüntü oluşturulmuştur.
7. Yöntem: Bu yöntemde, önce Gauss tipi gürültü eklemesi 4. yöntemde anlatıldığı gibi uygulanmış ve ardından görüntüye $[-30^\circ, 30^\circ]$ aralığında bir açı değeri ile saat yönünde döndürme uygulanmıştır. Her orijinal görüntüye 3 sabit değer ile gürültü eklenip, elde edilen her görüntüye rastgele seçilen 3 farklı açı değeri ile döndürme işlemi uygulandığından, bu yöntem sonucunda her orijinal görüntüden 9 görüntü oluşturulmuştur.
8. Yöntem: Bu yöntem ile veri artırma, görüntünün $[-30^\circ, 30^\circ]$ aralığında rastgele seçilen bir açı değeri ile saat yönünde döndürülmesi ve ardından $[-20, 20]$ aralığında rastgele seçilen bir değer ile x ve y ekseninde öteleme işleminin uygulanması ile sağlanmıştır. Bu ardışık işlem her orijinal görüntü için 3 defa uygulanmış ve bu yöntem ile bir görüntüden 3 görüntü oluşturulmuştur.
9. Yöntem: Bu yöntemde, $[-20, 20]$ aralığında rastgele seçilen bir değer ile x ve y ekseninde öteleme işlemi uygulanmış ve ardından $[-30^\circ, 30^\circ]$ aralığında rastgele seçilen bir açı değeri ile x ve y ekseninde kayma uygulanmıştır. Bu ardışık işlem her orijinal görüntü için 3 defa uygulanmış ve bu yöntem ile bir görüntüden 3 görüntü oluşturulmuştur.
10. Yöntem: Bu yöntem ile veri artırma sırasıyla öteleme, kayma ve döndürme olmak üzere üç işlemin ardışık olarak uygulanması ile sağlanmıştır. Öteleme ve kayma işlemleri 9. yöntemde anlatıldığı gibi uygulanmış olup, döndürme adımı $[-30^\circ, 30^\circ]$ aralığında rastgele seçilen bir açı değeri ile saat yönünde döndürme uygulanmıştır. Bu ardışık işlem her orijinal görüntü için 3 defa uygulanmış ve bu yöntem ile bir görüntüden 3 görüntü oluşturulmuştur.

3.2.2. Verilerin sınıflandırılması

Bu tez çalışmasında her veri artırma yöntemi ile elde edilen görüntü verileri kullanılarak artırılmış sayıdaki görüntü verisi ile yeni eğitim ve test veri setleri oluşturulmuş ve derin bir ağ mimarisi oluşturulan her yeni eğitim veri setleri ile eğitildikten sonra test veri setleri ile test edilmiştir.

Bu çalışmada sınıflandırma derin öğrenme yaklaşımı ile sağlanmıştır. Derin öğrenme ile sınıflandırma yaklaşımında, biyolojik bir beyin yapısındaki sinirsel ağlarda öğrenme eyleminin nasıl gerçekleştirildiği incelenerek geliştirilmiş olan derin ağ mimarileri kullanılmaktadır. Oluşturulan yapay sinir ağlarında, ağırlık değerlerine sahip sinaps yapıları ile birlikte birbirlerine bağlanmış olan çeşitli sayıda katmanlar ve nöron yapıları bulunmaktadır (Patrick vd. 2022).


Derin ağ mimarisindeki ağırlık değerleri, yapay sinir ağında öğrenmenin gerçekleştirilmesini sağlayacak şekilde geri yönlü bir yayılım (*back propagation*) tekniği ile ayarlanmaktadır (LeCun vd. 2012; Nielsen 2015). Yapay sinir ağ mimarisi,

oluşturulmuş olan eğitim veri setlerinden bir çıktılarının ne olacağını öğrenmek için eğitilmektedir. Ağ mimarisinin eğitimi boyunca ağırlık değerlerinin optimizasyonu kullanılan amaç fonksiyonunun en küçük ya da en büyük değerinin hesaplanması ile gerçekleştirilmektedir. En küçük optimizasyon değerinin hesaplanması için kullanılan fonksiyonun ismi “kayıp fonksiyon” olarak bilinmektedir (Goodfellow vd. 2017).

Derin öğrenmeye dayalı yaklaşımlarda kullanılan kayıp fonksiyon, skaler bir sayı değeri ile ağ mimarisindeki gerekli bütün özellikleri belirlemekte ve bu nedenden dolayı ağ mimarisinin performansını da belirlemektedir (Reed ve Marks II 1999). Kullanılan bir kayıp fonksiyonunun değerini mümkün olan en küçük değere ulaştırmak için, yapay sinir ağ modelindeki ağırlık değerleri her dönemden (başka bir ifade ile her devirden (*epoch*)) sonra kullanılan bir iyileştirici fonksiyon (*optimizer*) ile hesaplanmakta ve güncellenmektedir.

Derin öğrenme tekniği ile gerçekleştirilen yaklaşımlarda çok farklı ağ yapıları tasarlanıp, farklı sınıflandırma mimarileri uygulanabilmektedir. Bu ağ mimarilerinden en çok bilinen ve uygulananı ise evrişim işlemlerinin yapıldığı katmanları içeren ve evrişimsel yapay sinir ağ olarak bilinen ağ mimarileridir. Bu ağ modellerinin diğerleri ile karşılaştırıldığında daha fazla tercih edilip uygulanmasının en temel sebebi, evrişimsel işlemler yapıldığından başka bir önsel bilgi kullanımına gereksinim duyulmadan veri setlerinden gerekli niteliklerin elde edilmesini tam otomatik bir yöntem ile gerçekleştirebilmesidir.

Evrişimsel bir yapay sinir ağ mimarisinin oluşturulması için üç temel katmana ihtiyaç vardır. Bu katmanlar evrişim katmanı (*convolutional layer*), havuzlama katmanı (*pooling layer*) ve tam bağlantılı katman (*fully connected layer*). Şekil 3.2 bu temel katmanları içeren bir evrişimsel ağ modelini göstermektedir.



Şekil 3.2. Bir evrişimsel derin ağ mimarisinin katmanları


En genel ifade ile, tasarlanmış olan bir evrişimsel derin ağ mimarisinde; ardışık olarak kullanılan evrişim katmanları sayesinde desen, kenar ve köşe gibi düşük seviyeli

olarak adlandırılabilen niteliklerin çıkarımı sağlanmakta, çıkarılan bu nitelikler ise daha sonra daha yüksek seviyeli niteliklerin elde edilmesi amacı ile ileri katmanlarda birleştirilerek kullanılmaktadır.

Bu tez çalışması kapsamında, görüntülerin sınıflandırılması aşamasından elde edilen sonuçların tarafsız (*unbiased*) olması için veri tabanından sağlıklı karaciğer görüntüleri (108 tane) ve tümör içeren karaciğer görüntüleri (108 tane) eşit sayıda alınmış olup toplam 216 görüntü kullanılmıştır. Bu görüntüler üzerinde yukarıda açıklanan veri artırma yöntemleri uygulanarak artırılmış sayıdaki veriler orijinal görüntü verilerine eklenmiş ve sınıflandırma aşamasında kullanılacak olan eğitim ve test veri setleri oluşturulmuştur. Sınıflandırma işleminde derin ağ mimarisinin eğitimi görüntülerin %70'i ile, test edilmesi ise görüntülerin geri kalan %30'u ile sağlanmıştır.

Sınıflandırma aşamasında görüntüler sağlıklı ve sağlıklı olmayan karaciğer olmak üzere iki sınıfa ayrıştırılmıştır. Bu tez çalışmanın amacı, sınıflandırıcı modellerin değerlendirilmesinden olmayıp, sınıflandırmanın iyileştirilmesinde farklı veri artırma tekniklerinin değerlendirilmesidir. Bu nedenle, yapılan çalışmada bir derin ağ mimari modeli oluşturulup kullanılmıştır. Oluşturulan derin ağ yapısı ResNet mimarisidir. Bu ağ mimarisinin tercih edilmesinin nedeni, gradyan kayması sorununu çözebilme ve yüksek öğrenme yeteneğine sahip olmasıdır (He vd. 2016).

ResNet ağ mimari yapısında artık bağlantı (*residual connection*) ve toplu normalizasyonlar (*batch normalizations*) kullanılmaktadır. Şekil 3.3'de gösterilmiş olduğu gibi, artık bağlantılar bir ağ katmanının çıktılarını daha derin olan başka bir katmana iletmektedir. Artık bağlantı yapısında 3x3'lük filtre kullanılmakta olup, adım büyüklük değeri 2 olarak alınmakta ve evrişim işlemlerinin gerçekleştirildiği iki tane evrişim katmanı yer almaktadır.




Şekil 3.3. Artık bağlantı içeren yapı

Artık bağlantı yapısının kullanılmasının en önemli nedeni, ağın derinliğinin artırılmasından dolayı ortaya çıkan gradyan kaybolması (*vanishing gradient*) sorununu

çözmektir. Çünkü evrişimli katmanlardan oluşturulan derin bir ağ mimarisi ile görüntü sınıflandırması uygulandığında, görüntü sahnenin uzamsal yapısının artık fark edilemediği küçük özellik haritalarıyla temsil edilene kadar çözünürlüğü aşamalı olarak azaltmaktadır. Bu nedenle oluşan gradyan kaybolması sorunu sınıflandırmaların hatalı yapılmasına yol açmaktadır (Yu vd. 2017). Artık bağlantı yapılarının kullanılması durumunda, ağın derinliği artsa bile gradyan kaybı sorununun oluşması önlenabilmektedir. Literatürdeki çalışmalar artık ağların nispeten sık ağların toplulukları gibi davrandığını göstermiştir (Veit vd. 2016).

Şekil 3.4’de 18 ağırlık katmanı bulunan ResNet18 mimari yapısı gösterilmektedir. Bu ağ yapısındaki derinlik miktarının artırılması ile 34, 50 ve 101 katmanlı yeni modeller (ResNet34, ResNet50, ResNet101) tasarlanabilmektedir. Bu tez çalışmasında 101 katmanlı hali olan ResNet101 mimarisi kullanılmıştır.



Şekil 3.4. ResNet18

Ayrıca bu tez çalışmasında transfer öğrenme (bilgi transferi) yaklaşımının avantajından da yararlanılmıştır. Transfer öğrenme yaklaşımı, ağ mimarisinin eğitilmesi için, verilerin veya donanımsal yapının yetersiz olması durumunda bir derin öğrenme modelinin oluşturulmasında en etkili teknik olup öğrenmenin hızlı olmasını sağlamaktadır. Çünkü bu yaklaşım, büyük veri kümeleri kullanılarak ağların ön eğitimi ve ardından daha az eğitim verisine sahip hedef görevler için ağlarda ince ayar yapılması esasına dayanmaktadır. Klasik makine öğrenme yöntemlerinde, her işlevin yeniden öğrenilmesi gerekirken, transfer öğrenme tekniği kullanılması sayesinde, önceki işlevler ile öğrenilen bilgi yeni gerçekleştirilecek olan işlevin öğrenme amacına aktarılmaktadır.

Az sayıda veri ile gerçekleştirilmesi gereken çalışmalarda, mevcut veri ile oluşturulan özel ağ yapısı, genel bir işlevin gerçekleştirilmesi için oluşturulmuş olan büyük bir veri seti kullanılıp eğitildikten sonra var olan veriler ile eğitilebilir. Bu düşünceden yola çıkılarak geliştirilmiş olan transfer öğrenme yaklaşımında transfer edilenler, kullanılan parametrelerin ilk (başlangıç) değerleridir.

Gerçekleştirilen uygulamalarda, ağ mimarisindeki ağırlık değerleri için ilk olarak rastgele seçilen değerler kullanmak yerine, daha önceden eğitilmiş olan derin ağ yapısının ağırlık değerleri ile başlatılması; ağ mimarisinin iyi bir başlangıç değeri ile öğrenmeye başlamasını ve daha yüksek doğruluk değerleri ile sonuçlar vermesini sağlamaktadır. Eğer gerçekleştirilecek çalışmalarda veri miktarı yetersiz ise, transfer öğrenimi tekniği ayrıca ağ mimarisinin aşırı öğrenme problemine de çözüm olmaktadır.

Bu nedenle, bu tez çalışmasında ResNet101 ağ mimarisi 1000 adet sınıf ve 1 milyon resimden oluşan büyük bir veri seti olan ImageNet (Russakovsky vd. 2015) ile daha önceden eğitilip, gerekli olan temel niteliklerin bu ağ modeli ile önceden öğrenilmesi sağlanmıştır. Daha önceden öğrenilmiş olan niteliklerin (*pre-trained features*) kullanımı sayesinde, eğitim aşamasının hızlı olması sağlanmıştır. Bu tez çalışmasında oluşturulan veri setleri ile ResNet101 mimarisi tekrar eğitilmiş ve test edilmiştir.

Kullanılan ResNet101 ağ mimari yapısının optimizasyon ve aktivasyon işlemlerinde uyarlamalı moment kestirim (*adaptive moment estimation (adam)*) ve doğrultulmuş lineer birim (*rectified linear unit*) fonksiyonları kullanılmış olup, ağı eğitimi süresince ağırlık değerlerinin güncellenmesi çapraz-entropi (*cross-entropy*) kayıp fonksiyonu ile sağlanmıştır. Parametre olarak kullanılan mini parti boyutu (*mini batch size*), devir sayısı (*epoch number*) ve ilk öğrenme oranı değerleri ise sırası ile 10, 6 ve 0.0003'tür.

3.2.3. Bulguların değerlendirilmesi için kullanılan sayısal ölçütler

Sınıflandırma işlemlerinden elde edilen bulguların sayısal verilere dayalı olarak değerlendirilebilmesi için farklı değerlendirme ölçütleri kullanılmıştır. Görüntü sınıflandırma çalışmalarında bulguların değerlendirilmesi için yaygın olarak kullanılan ve bu tez çalışmasında da tercih edilmiş olan sayısal değerlendirme ölçütleri doğruluk (*accuracy*), özgüllük (*specificity*) ve hassaslık (*sensitivity*) ölçütüdür.

Bu tez kapsamındaki çalışmalarda kullanılan değerlendirme ölçütlerinin hesaplanması için $T_{Pozitif}$ (*True Positive*), $T_{Negatif}$ (*True Negative*), $F_{Pozitif}$ (*False Positive*) ve $F_{Negatif}$ (*False Negative*) terimleri kullanılmış olup, bu terimlerin ne anlama geldiği aşağıda açıklanmıştır.

- $T_{Negatif}$: Bu terim Gerçek Negatif durumunu temsil etmekte olup, negatif olan örneklerin kullanılan derin ağ yapısı tarafından da negatif olarak tahmin edilmiş olmasını ifade etmektedir.
- $T_{Pozitif}$: Bu terim Gerçek Pozitif durumunu temsil etmekte olup, pozitif olan örneklerin kullanılan derin ağ yapısı tarafından da pozitif olarak tahmin edilmiş olmasını ifade etmektedir.
- $F_{Negatif}$: Bu terim Yanlış Negatif durumunu temsil etmekte olup, pozitif olan örneklerin kullanılan derin ağ yapısı tarafından negatif olarak tahmin edilmiş olmasını ifade etmektedir.

- $F_{Pozitif}$: Bu terim Yanlış Pozitif durumunu temsil etmekte olup, negatif olan örneklerin kullanılan derin ağ yapısı tarafından pozitif olarak tahmin edilmiş olmasını ifade etmektedir.

Doğruluk olarak kullanılan ölçüt, ağ yapısının sınıflandırma işlemlerini ne kadar doğrulukta gerçekleştirdiğinin bir göstergesidir. Dolayısı ile, ağ yapısı tarafından doğru olarak tahmin edilmiş olan tüm değerlerin (yani $T_{Pozitif}$ ve $T_{Negatif}$ değerlerinin) tahmin edilen tüm değerlerin ($F_{Pozitif}$, $T_{Pozitif}$, $F_{Negatif}$, $T_{Negatif}$ değerlerinin) toplamına oranıdır.

Hassaslık olarak kullanılan ölçüt, ağ yapısı tarafından gerçekte pozitif olan örneklerden ne kadarının doğru olarak tahmin edildiğinin bir göstergesidir. Dolayısı ile, ağ yapısı tarafından doğru olarak tahmin edilmiş olan pozitif örneklerin ($T_{Pozitif}$), gerçekte pozitif sınıfa dahil olan toplam değerlere (yani $F_{Negatif}$ ve $T_{Pozitif}$ değerlerine) oranıdır.

Özgüllük olarak kullanılan ölçüt, ağ yapısı tarafından gerçekte negatif olan örneklerden ne kadarının doğru olarak tahmin edildiğinin bir göstergesidir. Dolayısı ile, ağ yapısı tarafından doğru olarak tahmin edilmiş olan negatif örneklerin ($T_{Negatif}$), gerçekte negatif sınıfa dahil olan toplam değerlere (yani $T_{Negatif}$ ve $F_{Pozitif}$ değerlerine) oranıdır.

Bu nedenlerden dolayı, yukarıda ifade edilen doğruluk, hassaslık ve özgüllük ölçütlerinin hesaplanması için aşağıda yer alan matematiksel formüller kullanılmıştır:

$$Doğruluk = \frac{T_{Pozitif} + T_{Negatif}}{T_{Pozitif} + T_{Negatif} + F_{Pozitif} + F_{Negatif}} \quad (3.2)$$

$$Özgüllük = \frac{T_{Negatif}}{T_{Negatif} + F_{Pozitif}} \quad (3.3)$$

$$Hassaslık = \frac{T_{Pozitif}}{T_{Pozitif} + F_{Negatif}} \quad (3.4)$$

Bu ölçütlerin yanı sıra, bu tez çalışması kapsamında F1-Skor ve Mathew Korelasyon Katsayısı (MKK) da hesaplanıp, elde edilen bulgular uygulanan yaklaşımların etkilerinin karşılaştırılmasında kullanılmıştır. Bu sayısal ölçütlerin hesaplanmasında, yukarıda belirtilen doğruluk, özgüllük ve hassaslık formüllerinde kullanılan terimler kullanılmaktadır. Bu ölçütlerin hesaplanması şu formüller gerçekleştirilmiştir:

$$F1-Skor = \frac{2 * T_{Pozitif}}{2 * T_{Pozitif} + F_{Pozitif} + F_{Negatif}} \quad (3.5)$$

$$MKK = \frac{T_{Pozitif} * T_{Negatif} - F_{Pozitif} * F_{Negatif}}{\sqrt{(T_{Pozitif} + F_{Pozitif})(T_{Pozitif} + F_{Negatif})(T_{Negatif} + F_{Pozitif})(T_{Negatif} + F_{Negatif})}} \quad (3.6)$$

4. BULGULAR

Bu bölümde, bu tez çalışması kapsamında uygulanan 10 adet veri artırma yönteminin her birisi ile elde edilen görüntü sayıları sunulmaktadır. Bununla birlikte, her veri artırma yöntemi ile elde edilen yeni görüntüler kullanılarak oluşturulmuş olan yeni veri setleri ile, tekrar eğitilip test edilen derin ağ mimarisinden sağlanmış olunan bulgular da sunulmaktadır.

Bu tez çalışmasında uygulanmış olan 10 farklı veri artırma yaklaşımında kullanılan işlemler ve her yaklaşım ile orijinal bir görüntüden elde edilen görüntü sayıları Çizelge 4.1’de gösterilmektedir. Bu çizelgede, 6. ve 7. veri artırma yöntemi ile her bir orijinal görüntüden 9 adet yeni görüntü elde edilmesinin sağlandığı, diğer veri artırma yöntemlerinin kullanılması durumunda ise her bir orijinal görüntüden 3 adet yeni görüntünün elde edildiği bilgisi sunulmaktadır.

Çizelge 4.1. Uygulanan veri artırma yöntemleri, bir tane görüntüden elde edilen görüntü sayısı

Veri Artırma Yöntemleri	Uygulanan İşlemler	Bir Görüntüden Elde Edilen Görüntü Sayısı
1. Yöntem	Kayma (Shearing)	3
2. Yöntem	Öteleme (Translation)	
3. Yöntem	Döndürme	
4. Yöntem	Gauss tipi gürültü ekleme	
5. Yöntem	Tuz-biber tipi gürültü ekleme	
6. Yöntem	Tuz-biber tipi gürültü ekleme ve kayma	9
7. Yöntem	Gauss tipi gürültü ekleme ve döndürme	
8. Yöntem	Döndürme ve öteleme	3
9. Yöntem	Öteleme ve kayma	
10. Yöntem	Öteleme, kayma ve döndürme	

Bu tez çalışmasında uygulanmış olan veri artırma yöntemleri ile birlikte, tümör içeren ve içermeyen karaciğer BT görüntülerinin otomatik olarak sınıflandırılması

sonucunda hesaplanan doğruluk, hassaslık, özgüllük, F1-Skor ve MKK değerleri % olarak Çizelge 4.2’de gösterilmektedir.

Çizelge 4.2. Veri artırma yöntemlerinden sağlanan veriler ile sınıflandırma sonuçları

Veri Artırma Yöntemleri	Doğruluk (%)	Hassaslık (%)	Özgüllük (%)	F1-Skor (%)	MKK (%)
1. Yöntem	83.34	89.19	76.20	84.45	67.37
2. Yöntem	80.39	80.58	93.19	80.45	70.68
3. Yöntem	84.32	84.17	92.25	84.18	76.44
4. Yöntem	79.53	79.35	96.69	78.66	78.82
5. Yöntem	78.56	85.70	71.42	80.01	58.75
6. Yöntem	62.37	65.15	70.05	62.50	56.07
7. Yöntem	85.24	86.10	96.64	84.35	81.41
8. Yöntem	85.69	80.95	90.78	85.00	71.46
9. Yöntem	83.85	84.84	94.39	83.08	80.24
10. Yöntem	88.25	90.49	97.14	88.53	82.80

5. TARTIŞMA

Bölüm 2'deki kaynak taraması çalışmaları göstermiştir ki, çeşitli tıbbi görüntüleme cihazları kullanılarak elde edilen görüntüler ile, derin öğrenme tabanlı yaklaşımlarda dengesizlik dağılımı ve veri kıtlığı problemlerinin üstesinden gelmek için literatürde çeşitli veri artırma yöntemleri yaygın olarak uygulanmaktadır. Literatürdeki derin öğrenmeye dayalı bu yaklaşımlarda farklı derin ağ modelleri, farklı görüntüleme teknikleri ile elde edilen görüntüler, farklı parametre ve farklı fonksiyonlar kullanılmıştır.

Veri artırma yöntemleri sayesinde artırılmış sayıdaki veriler kullanıldığında iyi sonuçların elde edildiği Bölüm 2'de sunulan yayınlarda ifade edilmiştir. Fakat karaciğer BT görüntülerinden tümör tespiti için hangi veri artırma yönteminin en etkili olduğu ve sınıflandırma performansını en iyi şekilde artırdığı net değildir. Çünkü sadece kullandıkları görüntü türleri değil, aynı zamanda tasarlanan derin ağ mimarisi, kullanılan parametre ve fonksiyonların farklılığı gibi pek çok farklılıklar mevcuttur. Bu nedenle, hangi veri artırma tekniğinin karaciğer BT görüntülerinin ayrıştırılmasında en etkili yöntem olduğu belirli değildir. Bu belirsizlik, veri artırma yöntemlerinin bu görüntülerin otomatik olarak sınıflandırılmasında etkilerinin araştırılması ve sınıflandırma performansının artırılmasında en çok katkı sağlayan yöntemin tespit edilmesi gerektiğini ortaya koymuştur. Dolayısı ile, bu tez çalışması ile literatürde yaygın kullanılan veri artırma yöntemi araştırılmış ve sınıflandırma performansı üzerindeki etkileri incelenip karşılaştırılmıştır.

Bu tez kapsamında yapılan çalışmalarda amaç sınıflandırıcıdan ziyade veri artırma yöntemlerinin etkilerini incelemek olduğu için bir derin ağ mimarisi tasarlanmıştır. Kaybolan gradyan problemini ortadan kaldırma yeteneğine sahip olmakla birlikte diğer derin ağ mimarilerine göre içerdiği artık bağlantılar sayesinde daha hızlı öğrenmeyi de gerçekleştirebilme kabiliyetinde olan, 101 katmanlı ResNet yapısı tercih edilmiştir.

Ayrıca, tüm sınıflandırma işlemlerinin yapılması aşamasında, ağ mimarisinde aynı fonksiyonlar ve parametreler ile ağın eğitilmesi ve test edilmesi sağlanmıştır. Sınıflandırma aşamalarında aynı sınıflandırıcının kullanılması, veri artırma yöntemlerinin sağladığı etkilerin tarafsız (*objective*) olarak karşılaştırılması ve değerlendirilmesini sağlamıştır.

Sınıflandırma sonuçlarının değerlendirilmesi aşamasında da beş farklı sayısal değerlendirme ölçütü kullanılmış olup, hesaplanan bulgulara göre, sınıflandırma performansını en çok artıran yöntem belirlenmiştir. Aynı zamanda en az etki ile sınıflandırmanın yapılmasını sağlayan veri artırma yöntemi tespit edilmiştir. Yöntemlerin kullanılan görüntüler için avantaj ve dezavantajları da irdelenmiştir.

Bu tez çalışması kapsamında kullanılan algoritmaların programlanması aşamasında, dönüşüm tabanlı veri artırma yöntemlerinin karaciğer BT görüntüleri ile uygulanmasının kolay olduğu gözlemlenmiştir. Bununla birlikte, veri artırma yöntemlerinin, görüntülerin sınıflandırılması üzerine etkinliklerinin görüntülerdeki yoğunluk ve tümör içeren dokunun büyüklüğü gibi özelliklerine ve ayrıca eğitim için kullanılan veri setlerindeki görüntülerin tüm önemli görsel özelliklere sahip olup

olmadığına da bağlıdır. Eğitim için kullanılan veri setlerindeki görüntülerin çoğunluğunun benzer özelliklere sahip olması durumunda, sınıflandırıcının aşırı uydurma ve daha az genelleme yaparak sonuçları oluşturma riski de vardır.

Literatürde kullanılan rastgele silme veya rastgele kesme işlemleri ile mevcut görüntülerden yeni görüntülerin oluşturulması bu tez kapsamında uygulanmamıştır. Bunun nedeni ise, karaciğer tümörlerinin çok küçük olması veya karaciğerin kenar bölgesinde olması durumunda, görüntü üzerinde uygulanacak olan rastgele silme veya kesme işlemleri tümör olan doku bölgesi yok olabilmektedir. Bunun yanı sıra, tümörlerin büyüklük veya şekilleri değişikliğe uğrayabilmektedir. Bu durum ise tümörlerin karakteristik özellikleri ile ilgili önemli bilgilerin kaybolmasına yol açmaktadır. Karaciğer hastalıklarının doğru sınıflandırılmasında ve hastalıkların hangi evrede olduğunun tespit edilmesinde, ayrıca uygulanacak olan tedavi planlamasının yapılmasında tümörlerin karakteristik özelliklerinin korunması gerekmektedir.

Ayrıca, rastgele silme veya rastgele kesme yöntemleri ile veri artırma işlemlerinin uygulanması durumunda sağlıklı karaciğer görüntülerinde karaciğerin kenar bilgileri de kaybolabilmektedir. Bu durum ise, karaciğer kenarlarının doğru belirlenmesi ve karaciğer bölütleme işleminin doğru yapılması için uygulanan yaklaşımların performansının düşük olmasına sebep olabilir.

Literatürde kullanılan GAN tabanlı veri artırma yöntemlerinin kaybolan gradyan ve mod çökme problemlerine neden olduğu bilinmektedir (Yi vd. 2019). GAN tabanlı veri artırma yöntemlerinin sebep olduğu diğer önemli problem de, eğitim prosedürünün hem üretici hem de ayırmacı ağların simetrisini ve hizalamasını garanti etmemesi durumunda, tatmin edici eğitim sonuçları elde etmenin kolay olmamasıdır (Yi vd. 2019).

GAN ile veri artırma yaklaşımından kaynaklanan bir başka sorun ise yeni görüntülerin oluşturulması esnasında istenmeyen sinyaller (*artifacts*) eklenmesi nedeniyle görüntünün gerçekçi bir görüntü olmayabilmesidir. Başka bir deyişle, üretilen yeni görüntülerin kalitesi çok düşük olabilir.

Ayrıca, GAN tabanlı veri artırma yöntemlerinin uygulanabilmesi için güçlü donanımsal özelliklere sahip bilgisayar kaynaklarına gereksinim duyulmaktadır. Bununla yanı sıra, yeni görüntülerin oluşturulması dönüşüm tabanlı veri artırma yöntemlerine göre daha uzun zaman gerektirmektedir.

Bu tez çalışması kapsamında uygulanan veri artırma yöntemlerinin özelliklerine göre sağladıkları avantajlar maddeler halinde şöyle listelenebilir:

- Veri setlerindeki görüntü sayılarının artırılmasında etkili yöntemlerdir. Özellikle döndürme, öteleme ve kayma gibi geometrik dönüşümler ile oluşturulan yeni görüntüler farklı parametreler ile uygulanarak veri sayısının önemli ölçüde artırılabilmesini sağlamakta ve veri kümelerini zenginleştirebilmektedir.
- Tümörler görüntülerde farklı konumlarda, şekil ve büyüklüklerde görünebileceğinden, eğitim setlerinde özellikle döndürülmüş ve farklı

büyükliklerdeki tümörleri içeren görüntülerin olması ağ modellerinin daha etkili bir şekilde öğrenmesine yardımcı olmaktadır.

- Öteleme yöntemi ile veri artırma sayesinde, görüntülerdeki tümörlerin konumuna göre taraflı olarak sonuçların oluşması önlenmekte, ağ modelinin tek bir uzamsal konumdaki özelliklere odaklanmasının önüne geçilmektedir. Başka bir ifade ile, bir ağ modelini öteleme yöntemi kullanılarak artırılmış sayıdaki görüntülerle eğitmek, ağın coğrafi olarak değişmeyen özellikleri öğrenmesini sağlamaktadır.
- Uygulanan veri artırma yöntemleri, yeni oluşturulan görüntülerin etiketlerini ve özelliklerini koruyabilmekte, etiketlerin korunması da sınıflandırma aşamasında kolaylık sağlamaktadır. Çünkü tümör içeren orijinal görüntüden veri artırma işleminden sonra oluşturulan görüntüler de tümör içermektedir.
- Görüntülerin yoğunluk değerlerinin gürültü eklenerek değiştirilmesi ile yeni görüntülerin oluşturulması, veri setlerindeki görüntülerin sadece sayısını değil, aynı zamanda görüntü çeşitliliğinin de artmasını sağlamakta ve sınıflandırma performansının artmasına yardımcı olabilmektedir. Karaciğer görüntüleri çeşitli görüntüleme cihazlarındaki farklı teknikler ve teknolojiler ile elde edilmekte olduğundan piksel yoğunlukları da çeşitlendirilebilmektedir. Dolayısı ile, gürültü ekleme işlemi ile yoğunluk değerleri değişmiş olan yeni görüntüler sınıflandırma aşamasında öğrenmenin daha etkili olmasını sağlamaktadır.

Bu tez çalışması kapsamında uygulanan veri artırma yöntemlerinin dezavantajları maddeler halinde şöyle listelenebilir:

- Dönüşüm tabanlı yöntemler ile veri artırma sağlandığında, orijinal görüntü ile yeni oluşturulan görüntünün içerik olarak (*pattern, texture*) benzerliğinden dolayı, tümör yapılarının patolojik çeşitliliği yeterince artırılamamaktadır.
- Gürültü ekleme ile yoğunluk değerlerini değiştirmeye dayalı veri artırma yöntemleri, görüntüdeki karaciğer ve tümör dokusuna ait özelliklerin değişmesine ve görüntü kalitesinin düşmesine sebep olabilmektedir.
- Eklenecek gürültü türü ve miktarının her görüntü için doğru bir şekilde belirlenmesi zordur. Eklenen gürültü nedeniyle doğal olmayan görüntülerin oluşması riski vardır.

Eğitim veri setlerinin düşük kaliteli ve doğal olmayan görüntüler eklenerek genişletilmesi, derin ağ mimarisinin öznitelik çıkarımını hatalı yapmasına ve gerekli özniteliklerin öğrenilememesine sebep olmakta, dolayısı ile düşük performans ile sınıflandırma işlemlerinin sonuçlanması durumu oluşabilmektedir. Bu nedenle tercih edilecek olan veri artırma yöntemlerinin görüntü sayısını artırırken üretilen yeni görüntülerde de bilgi kaybı olmamasını ve görüntü kalitesinin düşmemesini sağlayacak özellikte olması gerekmektedir.

6. SONUÇLAR

Karaciğer BT görüntülerinin bir derin ağ mimarisi kullanılarak tam otomatik bir yaklaşımla sınıflandırılması için tercih edilen veri artırma teknikleri, sınıflandırma performansını önemli ölçüde etkilemektedir. Bununla birlikte, literatürde kullanılmış olan veri artırma tekniklerinin karaciğer BT görüntüleri üzerine uygulanması durumunda, görüntülerin ve veri artırma tekniklerinin özelliklerinden kaynaklanan çeşitli avantaj ve dezavantajların olduğu gözlenmiştir. Bu nedenle, bu görüntülerin derin öğrenmeye dayalı olarak sınıflandırılmasında yüksek performans ile sonuçların elde edilebilmesi için görüntü özelliklerine uygun veri artırma tekniği kullanılmalıdır.

Bu tez çalışması kapsamında uygulanmış olan veri artırma yöntemlerinin karaciğer BT görüntülerini sınıflandırmadaki etkilerinin, derin ağ mimarisinin eğitilmesinde kullanılan eğitim setlerindeki görüntülerin tüm önemli görsel özelliklere sahip olup olmadığına bağlı olduğu gözlenmiştir. Özellikle görüntülerdeki yoğunluk değerlerine ve tümörlü bölgenin büyüklüğü gibi özelliklere bağlı olduğu gözlenmiştir. Eğitim veri setlerinin oluşturulmasında özellikle çeşitli yoğunluk değerlerine sahip, döndürülmüş ve farklı büyüklüklerde tümör içeren görüntüler kullanılması, ağ modellerinin daha etkili bir şekilde öğrenmesine yardımcı olmaktadır. Ağ yapısının eğitilmesi sürecinde kullanılan veri setlerinin çeşitlilikten uzak olması, başka bir ifade ile, benzer görsel özellikler taşıyor olması, aşırı uydurma problemine ve daha az genelleme ile sonuçların elde edilmesine neden olmaktadır.

Bu tez çalışması ile gözlenmiştir ki, dönüşüm tabanlı veri artırma yöntemlerinin karaciğer BT görüntüleri ile uygulanması kolaydır. Döndürme, öteleme ve kayma gibi geometrik dönüşümlere dayalı yöntemlerde, algoritmalar farklı parametreler ile istenildiği kadar uygulanarak veri sayısının önemli ölçüde artırılabilmesi ve veri kümelerini zenginleştirilmesi sağlanabilmektedir. Öte yandan, dönüşüm tabanlı yöntemler ile veri artırma sağlandığında, orijinal görüntü ile yeni oluşturulan görüntünün desen olarak benzerliklerinden dolayı görüntülerin çeşitliliği yeterince artırılamamaktadır.

Ağ modelinin tek bir uzamsal konumdaki özelliklere odaklanmasının önüne geçilmesi, görüntülerdeki tümörlerin konumuna göre sonuçların taraflı olarak oluşması, öteleme ile veri artırma sayesinde sağlanabilmektedir. Başka bir deyiş ile, öteleme yöntemi kullanılarak artırılmış sayıdaki görüntülerle derin ağ yapısının eğitilmesi, ağın konum olarak değişmeyen özelliklerin öğrenilmesi mümkün olmaktadır.

Görüntülerin yoğunluk değerlerinin gürültü eklenerek değiştirilmesi sayesinde görüntülerin sadece sayısının değil aynı zamanda çeşitliliklerinin de artırılması da sağlanabilmektedir. Yoğunluk değerleri değiştirilerek üretilmiş olan yeni görüntüler sınıflandırma aşamasında öğrenmenin daha etkili olmasını sağlamaktadır. Öte yandan, gürültü ekleme ile yoğunluk değerlerinin değiştirilmesi durumunda, görüntüdeki karaciğer ve tümör dokusuna ait önemli karakteristik özelliklerin değişmesi, görüntü kalitesinin düşmesi, gerçeklikten uzak veya doğal olmayan görüntülerin oluşması riski de doğabilmektedir. Bunun yanı sıra, eklenecek gürültü türünün doğru seçilmesi ve miktarının her görüntü için doğru bir şekilde belirlenmesi de zordur.

GAN tabanlı veri artırma yöntemlerinin kaybolan gradyan ve mod (*mode*) çökme problemlerine neden olduğu, yeni görüntülerin sentezlenmesi sürecinde yapay sinyallerin eklenmesi durumunda üretilen görüntülerin düşük kalitede olabildiği literatürdeki çalışmalarda belirtilmiştir (Yi vd. 2019). Bununla birlikte, GAN tabanlı veri artırma yöntemlerinin uygulanması dönüşüm tabanlı veri artırma yöntemlerine göre daha güçlü donanımsal özelliklere sahip olan bilgisayar kaynaklarının kullanımını gerektirmektedir.

Bu tez çalışması kapsamında yapılan çalışmalar göstermiştir ki, tümör içeren ve içermeyen karaciğer BT görüntülerinin derin öğrenmeye dayalı olarak yüksek performans ile sınıflandırılmasında kullanılmak üzere oluşturulacak veri setlerinin genişletilmesi için en uygun veri artırma yöntemi, bütünleşik bir yöntem olup, döndürme, kayma ve öteleme işlemlerinin ardışık olarak uygulanması ile sağlanabilmektedir. Bununla birlikte, kayma ve tuz-biber tipi gürültü ekleme algoritmalarının birlikte kullanıldığı veri artırma yönteminden elde edilen yeni görüntüler ile veri setlerinin genişletilmesinin sınıflandırma üzerinde en az etkili olan bir yaklaşım olduğu da gözlenmiştir.

7. KAYNAKLAR

- Araújo, J. D. L., da Cruz, L. B., Ferreira, J. L., da Silva Neto, O. P., Silva, A. C., de Paiva, A. C. and Gattass, M. 2021. An automatic method for segmentation of liver lesions in computed tomography images using deep neural networks. *Expert Systems with Applications*, 180, 115064.
- Araújo, J. D. L., da Cruz, L. B., Diniz, J. O. B., Ferreira, J. L., Silva, A. C., de Paiva, A. C. and Gattass, M. 2022. Liver segmentation from computed tomography images using cascade deep learning. *Computers in Biology and Medicine*, 140, 105095.
- Aswathy, A. L. and Vinod Chandra, S. S. 2022. Cascaded 3D UNet architecture for segmenting the COVID-19 infection from lung CT volume. *Scientific Reports*, 12.
- Bai, Z., Jiang, H., Li, S. and Yao, Y. D. 2019. Liver tumor segmentation based on multi-scale candidate generation and fractal residual network. *Ieee Access*, 7, 82122-82133.
- Bali, M. and Mahara, T. 2023. Comparison of Affine and DCGAN-based Data Augmentation Techniques for Chest X-Ray Classification. *Procedia Computer Science*, 218, 283-290.
- Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L. and Haworth, A. 2021. A review of medical image data augmentation techniques for deep learning applications. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 545-563.
- Chaki, J. 2022. Two-fold brain tumor segmentation using fuzzy image enhancement and DeepBrainet2. 0. *Multimedia Tools and Applications*, 81(21), 30705-30731.
- Duell, P. B., et al. 2022. Nonalcoholic fatty liver disease and cardiovascular risk: a scientific statement from the American Heart Association. *Arteriosclerosis, thrombosis, and vascular biology*, 42(6), e168-e185.
- Devarbhavi, H., Asrani, S. K., Arab, J. P., Nartey, Y. A., Pose, E. and Kamath, P. S. 2023. Global burden of Liver Disease: 2023 Update. *Journal of Hepatology*.
- El-Shafai, W., Mahmoud, A. A., Ali, A. M., El-Rabaie, E. S. M., Taha, T. E., El-Fishawy, A. S., Zahran, O. and El-Samie, F. E. A. (2023). Efficient classification of different medical image multimodalities based on simple CNN architecture and augmentation algorithms. *Journal of Optics*, 1-13.
- Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J. and Greenspan, H. 2018. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing*, 321, 321-331.
- Garcea, F., Serra, A., Lamberti, F. and Morra, L. 2022. Data augmentation for medical imaging: A systematic literature review. *Computers in Biology and Medicine*, 106391.

- Goodfellow, I., Bengio, Y., and Courville, A. 2017. Deep learning (adaptive computation and machine learning series). The MIT Press, Cambridge, Massachusetts, 800 p.
- Guan, Q., et al. 2022. Medical image augmentation for lesion detection using a texture-constrained multichannel progressive GAN. *Computers in Biology and Medicine*, 145, 105444.
- He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition, pp. 770-778, 20 June - 1 July, Computer Vision Foundation, Las Vegas.
- Krishnan, A., et al. 2023. Cardiovascular Outcomes and Mortality After Bariatric Surgery in Patients With Nonalcoholic Fatty Liver Disease and Obesity. *JAMA Network Open*, 6(4), e237188-e237188.
- Krishan, A. and Mittal, D. 2023. Multi-class liver cancer diseases classification using CT images. *The Computer Journal*, 66(3), 525-539.
- Khan, R. A., Luo, Y. and Wu, F. X. 2022. Machine learning based liver disease diagnosis: A systematic review. *Neurocomputing*, 468, 492-509.
- Khattab, M. A., Liao, I. Y., Ooi, E. H. and Chong, S. Y. 2022. Compound W-Net with fully accumulative residual connections for liver segmentation using CT images. *Computational and Mathematical Methods in Medicine*, 2022.
- Kim, J., Min, J. H., Kim, S. K., Shin, S. Y. and Lee, M. W. 2020. Detection of hepatocellular carcinoma in contrast-enhanced magnetic resonance imaging using deep learning classifier: a multi-center retrospective study. *Scientific Reports*, 10(1), 9458.
- Law, S. K., Au, D. C. T., Leung, A. W. N. and Xu, C. 2023. A Mini-Review of Traditional Chinese Medicines on Liver Diseases. *Pharmacological Research-Modern Chinese Medicine*, 7, 100243.
- LeCun, Y. A., Bottou, L., Orr, G. B., and Müller, K. R. 2012. Efficient backprop. In: Montavon, G., Orr, G. B., and Müller, K. R. (Eds.), *Neural Networks: Tricks of the Trade*. Springer, Berlin, pp. 9-48.
- Lewy, D. and Mańdziuk, J. 2023. An overview of mixing augmentation methods and augmentation strategies. *Artificial Intelligence Review*, 56(3), 2111-2169.
- Lyu, J., Zhang, Y., Huang, Y., Lin, L., Cheng, P. and Tang, X. (2022). AADG: Automatic Augmentation for Domain Generalization on Retinal Image Segmentation. *IEEE Transactions on Medical Imaging*, 41(12), 3699-3711.
- Meng, L., Tian, Y. and Bu, S. 2020. Liver tumor segmentation based on 3D convolutional neural network with dual scale. *Journal of applied clinical medical physics*, 21(1), 144-157.
- Naaqvi, Z., Akbar, S., Hassan, S. A. and Ain, Q. U. 2022. Detection of Liver Cancer through Computed Tomography Images using Deep Convolutional Neural

- Networks. *2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2)*, pp. 1-6, 24-26 May, Pakistan.
- Nielsen, M. A. 2015. Neural networks and deep learning. Determination Press, San Francisco, California, 216 p.
- Ouhmich, F., Agnus, V., Noblet, V., Heitz, F. and Pessaux, P. 2019. Liver tissue segmentation in multiphase CT scans using cascaded convolutional neural networks. *International journal of computer assisted radiology and surgery*, 14, 1275-1284.
- Oza, P., Sharma, P., Patel, S., Adedoyin, F. and Bruno, A. 2022. Image augmentation techniques for mammogram analysis. *Journal of Imaging*, 8(5), 141.
- Patrick, M. K., Adekoya, A. F., Mighty, A. A., and Edward, B. Y. 2022. Capsule networks—a survey. *Journal of King Saud University-Computer and Information Sciences*, 34(1): 1295-1310.
- Prakash, K. and Saradha, S. 2022. A Deep Learning Approach for Classification and Prediction of Cirrhosis Liver: Non Alcoholic Fatty Liver Disease (NAFLD). *6th International Conference on Trends in Electronics and Informatics (ICOEI)*, pp. 1277-1284, 28-30 April, India.
- Rahman, H., Bukht, T. F. N., Imran, A., Tariq, J., Tu, S. and Alzahrani, A. 2022. A Deep Learning Approach for Liver and Tumor Segmentation in CT Images Using ResUNet. *Bioengineering*, 9(8), 368.
- Reed, R., and Marks II, R. J. 1999. Neural smithing: supervised learning in feedforward artificial neural networks. The MIT Press, Cambridge, Massachusetts, 360 p.
- Russakovsky, O., et al. 2015. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115: 211-252.
- Sabir, M. W., Khan, Z., Saad, N. M., Khan, D. M., Al-Khasawneh, M. A., Perveen, K., Qayyum, A. And Azhar Ali, S. S. 2022. Segmentation of Liver Tumor in CT Scan Using ResU-Net. *Applied Sciences*, 12(17), 8650.
- Szeskin, A., Rochman, S., Weiss, S., Lederman, R., Sosna, J. and Joskowicz, L. 2023. Liver lesion changes analysis in longitudinal CECT scans by simultaneous deep learning voxel classification with SimU-Net. *Medical Image Analysis*, 83, 102675.
- Soler, L., Hostettler, A., Agnus, V., Charnoz, A., Fasquel, J., Moreau, J., Osswald, A., Bouhadjar, M. and Marescaux, J. 2010. 3D image reconstruction for comparison of algorithm database: A patient specific anatomical and medical image database. *IRCAD, Strasbourg, France, Tech. Rep*, 1(1).
- Tao, M., Lou, J. and Wang, L. 2022. MRI Liver Image Assisted Diagnosis Based on Improved Faster R-CNN. *Traitement du Signal*, 39(4).
- Tiago, C., Gilbert, A., Beela, A. S., Aase, S. A., Snare, S. R., Šprem, J. and McLeod, K. 2022. A Data Augmentation Pipeline to Generate Synthetic Labeled Datasets of 3D Echocardiography Images Using a GAN. *IEEE Access*, 10, 98803-98815.

- Truong, T. N., Dam, V. D. and Le, T. S. 2018. Medical images sequence normalization and augmentation: improve liver tumor segmentation from small dataset. *3rd International Conference on Control, Robotics and Cybernetics (CRC)*, pp. 1-5, 26-28 September, Malaysia.
- Veit, A., Wilber, M.J. and Belongie, S. 2016. Residual networks behave like ensembles of relatively shallow networks. *Advances in neural information processing systems*, 29.
- Wang, S., Gao, S., Ye, W., Li, Y., Luan, J. and Lv, X. 2023. The emerging importance role of m6A modification in liver disease. *Biomedicine & Pharmacotherapy*, 162, 114669.
- Xu, Y., et al. 2021. PA-ResSeg: A phase attention residual network for liver tumor segmentation from multiphase CT images. *Medical Physics*, 48(7), 3752-3766.
- Ye, J., Zhuang, X., Li, X., Gong, X., Sun, Y., Wang, W., Feng, S., Wu, T. and Zhong, B. 2022. Novel metabolic classification for extrahepatic complication of metabolic associated fatty liver disease: A data-driven cluster analysis with international validation. *Metabolism*, 136, 155294.
- Yi, X., Walia, E. and Babyn, P. 2019. Generative adversarial network in medical imaging: A review. *Medical image analysis*, 58, 101552.
- Yu, F., Koltun, V. and Funkhouser, T. 2017. Dilated residual networks. *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, pp. 472-480, 21-26 July, USA.
- Zhang, C., Bao, N., Sun, H., Li, H., Li, J., Qian, W., & Zhou, S. (2022). A deep learning image data augmentation method for single tumor segmentation. *Frontiers in Oncology*, 12, 297.
- Zhen, S. H., et al. 2020. Deep learning for accurate diagnosis of liver tumor based on magnetic resonance imaging and clinical data. *Frontiers in oncology*, 10, 680.

ÖZGEÇMİŞ

ELNURA ADIGOZALOVA

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2021-2023	Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Antalya
Lisans	Azerbaycan Devlet Petrol ve Sanayi Üniversitesi
2016-2020	Enformasyon Teknolojileri ve Yönetim Fakültesi, Biyomedikal Mühendisliği Bölümü, Bakü

MESLEKİ VE İDARİ GÖREVLER

Stajyer	Milli Onkoloji Merkezi
14.05.2019-14.08.2019	Radyoloji Bölümü, Bakü
Stajyer	Nergis Kliniği
05.06.2018- 05.09.2018	Cihaz Takip Birimi, Bakü