TEKNOFEST

HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

SAĞLIKTA YAPAY ZEKA YARIŞMASI

KRİTİK TASARIM VE ÖN BULGU RAPORU

RoSa Tech

BAŞVURU ID

#49367

İçindekiler

1. Kullanılması Planlanan Güncel Donanımlar ve Özellikleri 3
1.1. Eğitim Donanımları 3
1.2. Test Donanımları 3
2. Çözüm İçin Kullanılan Yöntem ve Mimari 3
2.1. Görüntü İşleme 4
2.2. Sınıflandırma 5
2.3. Segmentasyon 7
3. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri 8
4. Elde Edilen Deneysel Sonuçların Sunumu 8
5. Referanslar 12

TEKNOFEST
HAVACILIK, UZAY VE TEKNOLOJİ FESTİVALİ

1. Kullanılması Planlanan Güncel Donanımlar ve Özellikleri

1.1. Eğitim Donanımları

Modeli geliştirmek ve veri setinin bir bölümü ile modeli eğitmek için kullanılan donanımlar şöyledir:

1. Asus Laptop-X302UV model, Intel® Core™ i5-6200U CPU @ 2.30GHz × 4 ve 8.00 GB RAM özelliğine sahip bir bilgisayar.
2. Intel Lenovo-G50-80 model Intel® Core™ i3-4005U CPU @ 1.70GHz × 4 ve 8.00 GB RAM özelliğine sahip bir bilgisayar.
3. Google tarafından sağlanan Google Collaboratory. (Google Collaboratory Tesla K80 model GPU'yu sınırlı süreyle, ücretsiz sağlayan ve Keras, Tensorflow, PyTorch gibi kütüphaneleri destekleyerek derin öğrenme uygulamaları yapmaya imkan tanıyan bir bulut servistir [1].)

Veri setlerinin tamamı kullanılarak eğitim yapılabilmesi için, bundan sonraki aşamada kullanılacak bilgisayarın modeli ağ sistemine uyumlu ethernet girişine sahip Asus LAPTOP-PM0 CGUG 6'dır. İşlemcisi Intel® CoreTM i7 – 9750H CPU ve RAM 8,00 GB'tır.64 bit işletim sistemine ve x64 tabanlı işlemciye, GPU NVIDIA GeForce GTX 1650 GDDR5 4 GB sahiptir.

1.2. Test Donanımları

Test donanımları, eğitimde bahsedilen donanım araçları ile aynıdır.

2. Çözüm İçin Kullanılan Yöntem ve Mimari

Bilgisayarlı tomografi görüntülerinin inme var/yok şeklinde sınıflandırılması ve iskemi ile kanama türündeki hastalığın mevcut olduğu görüntülerde, hastalıklı bölgenin segmentasyonu için 2 aşamalı bir mimari tasarlanmıştır. Mimari Şekil 1.' de görülmektedir.

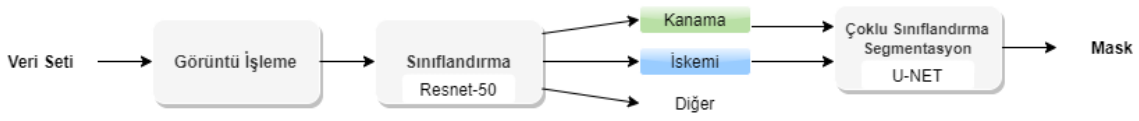

Şekil 1. BT Görüntülerinde İnme Tespiti ve Segmentasyonu Sistem Mimarisi

Sisteme ilk olarak png formatında görüntü alınır. Eğer görüntü dicom formatında ise pencereleme tekniği kullanılarak png formatına dönüştürülür. Görüntü işleme teknikleri uygulandıktan sonra elde edilen görüntüler ResNet50 sınıflandırma modeline yüklenir. Modelde sınıflar iskemi, kanama ve diğer şeklinde tanımlanmıştır. ResNet modeline, ilk olarak imagenet ağırlıkları kullanılarak ön eğitim yapılır ve daha sonra işlenen görüntüler ile modelin tamamı eğitilir. Model test için ayrılan görüntülerle test edilir. Tahmin için sisteme BT görüntüleri yüklendiği zaman sınıflandırma bloğunun çıkışında görüntülerinde inme olup olmadığı tespiti yapılmış olur.

Sistemin ikinci aşamasında segmentasyonun çoklu sınıflandırma versiyonu kullanılmıştır. Sistemdeki U-Net segmentasyon modeli, iskemi ve kanama tipi inme görüntüleri ve görüntülerin maskeleri ile eğitilir. Eğitilen modelin testi gerçekleştirildikten sonra tahmin için bir önceki bloktan alınan iskemi ve kanama görüntüleri, segmentasyon bloğunda hastalıklı bölge tespiti için kullanılır. Sistemin çıkışında inme olmayan görüntülerin 'diğer' şeklinde etiketlendiği ve inme olan görüntülerin ise hastalıklı bölge işaretlemesi yapılmış maske görüntüleri elde edilir. Maske görüntülerinin işaretlendiği renge göre (iskemi : mavi, kanama : yeşil) olup olmadığı anlaşılır.

2.1. Görüntü İşleme

BT görüntülerinde görüntü işleme teknikleri aşağıdaki altı adıma göre uygulanmıştır:

I. **Gri Tonlama:** Siyahtan beyaza kadar bir dizi tek renkli tondur. Bu nedenle, gri tonlamalı bir görüntü yalnızca gri tonlarını içerir ve renk içermez.Radyografik dijital görüntü değeri yalnızca 0-255 piksel değerine sahip olacaktır, bu nedenle görüntü ölçekleme işleminden, 0 ile temsil edilen minimum renk olarak siyahı ve 1 ile temsil edilen maksimum renk olarak beyazı kullanan bir gri tonlama işlemi kullanılacaktır. OpenCV, görüntüyü BGR modunda okuduğundan dolayı BGR2GRAY bayrağı ile dönüştürülerek işlem yapılır.

II. **Gauss Bulanıklığı:** Yüksek frekanslı bileşenleri azaltan düşük geçişli bir filtredir. Keskinliği azaltarak görüntünün işlenmesi sırasında gürültülerden daha az etkilenmesi sağlar.

III. **Eşikleme:** Görüntü segmentasyonu elde etmenin basit bir yoludur. Görüntüyü eşiklemenin ana fikri, gri skaladaki piksel değerleri için bir sınır belirlemektir. Her piksel için aynı eşik değeri uygulanır. Piksel değeri eşikten küçükse 0, aksi halde maksimum değere ayarlanır.

IV. **Erozyon ve Genişleme:** İkili ve gri tonlamalı dijital görüntü işlemede yer alan iki temel algoritmayı oluşturur. Bu işlemler, parazit giderme, özellik tanımlama, nesne ölçümü ve sayma ve gerçek bir ölçüm gerçekleştirmeden dijital bir görüntüdeki özelliklerin boyut dağılımını tahmin etme gibi uygulamalar için kullanışlıdır.

V. **Görüntü Şekillendirme:** Bir görüntüdeki nesnelerin yapısal ana hatlarını belirleme sürecidir ve bu da nesnenin şeklini belirlememize yardımcı olabilir.

VI. **Kırpma İşlemi:** Biraz siyah arka plan bırakarak mevcut BT taramada belirlenmesi istenilen bölgenin daha fazla odaklanması sağlanır [2].

2.2. Sınıflandırma

Sınıflandırma işlemi için ResNet50 modeli tercih edilmiştir.

ResNet50, ResNet modelinin bir çeşididir. 48 tane convolution , 1 max pool ve 1 average pool katmanından oluşur. Ağ mimarilerinde kullanılan düz ağ yerine ResNet mimarisinde kısayol bağlantıları kullanılır. Bu kimlik kısayolları (Identity Shortcuts) giriş ve çıkış aynı boyutta olduğunda doğrudan kullanılabilir. Kısayol kimlik eşleşmesinin yararı, modele ek parametre eklenmemesi ve ayrıca hesaplama süresinin kontrol altında tutulmasıdır [3].

$$F(x, \{w_i\}) + x$$

Boyutlar arttığında iki seçeneği göz önünde bulundurulur [3]:

1. Kısayol, artan boyutlar için fazladan sıfır girişleri ile birlikte kimlik eşleşmesi gerçekleştirir. Bu seçenek fazladan parametre getirmez.
2. $F(x, \{w_i\}) + x + w_s x$ 'deki projeksiyon kısayolu boyutları eşleştirmek için kullanılır. (1*1 convolution yapılır.)

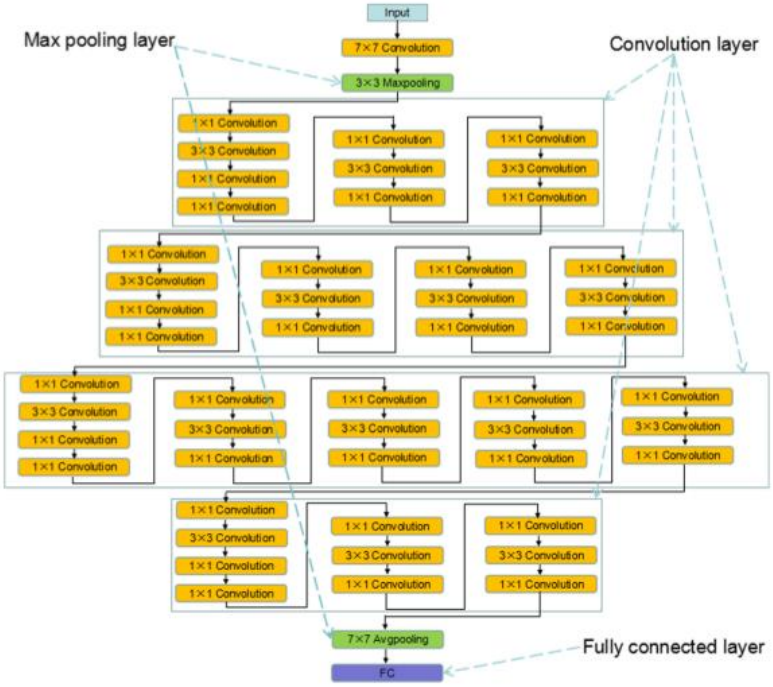

Şekil 2. ResNet50 Mimarisi [4].

ResNet50 mimarisinin çalışma sistemi şu şekildedir [3]:

1. 7x7 çekirdek boyutlu 64 farklı çekirdek ile 2 boyutlu adımla bir convolution katmanı uygulanır.
2. Ardından adım boyutu 2 olan maksimum havuzlama (max pool) yapılır.
3. Bir sonraki evrişimde 1x1 çekirdek boyutlu, 64 çekirdek, ardından 3x3 çekirdek boyutlu, 64 çekirdek ve son olarak 1x1 çekirdek boyutlu 256 çekirdek vardır, Bu üç katman toplam 3 kez tekrarlanır ve bu adımda bize 9 katman verir .
4. Daha sonra 1x1 çekirdek boyutlu 128 çekirdek görülür, ardından 3x3'lük 128 çekirdek ve sonunda 1x1'lik 512 çekirdek bu adımda 4 kez tekrarlanır ve bu adım böylece 12 katmana sahip olur.
5. Bundan sonra 1x1'lik 256'lık bir çekirdek ve 3x3'lük 256 çekirdek ve 1x1.1024'lük iki çekirdek uygulanır ve bu 6 kez tekrarlanarak toplam 18 katman bulundurur .
6. Ve sonra yine 3x3'lük 512 ve 1x1'lik 2048'den iki tane daha içeren 1x1'lik 512 çekirdek 3 kez tekrarlanır ve toplam 9 katman'dan oluşur .
7. Bundan sonra ortalama havuz (average pool) yapılır ve 1000 düğüm içeren tam bağlantılı katman (fully connected layer) uygulanır. En son olarak softmax işlevi kullanılır.

2.3. Segmentasyon

Segmentasyon işlemi için U-Net modeli tercih edilmiştir.

Görüntülerde nesnenin bulunduğu ilgili bölgenin doku, şekil veya renk gibi yöntemlerle ayrıştırılmasına segmentasyon denir. U-Net, biyomedikal görüntüler için segmentasyon tekniği kullanan evrişimsel bir ağ modelidir. Uluslararası Biyomedikal Görüntüleme Sempozyumu (International Symposium on Biomedical Imaging – ISBI) tarafından, elektron mikroskobu üzerinden alınan görüntülerin segmentasyonu konulu 2015 yılında düzenlenen yarışmada U-Net modeli birinci olmuştur [5]. 2015'ten günümüze bu modeli temel alan başka modeller de tasarlanmıştır. U-Net, biyomedikal görüntüleme dışında nesne tanıma ve haritalama gibi farklı alanlarda da kullanılmaktadır [6].

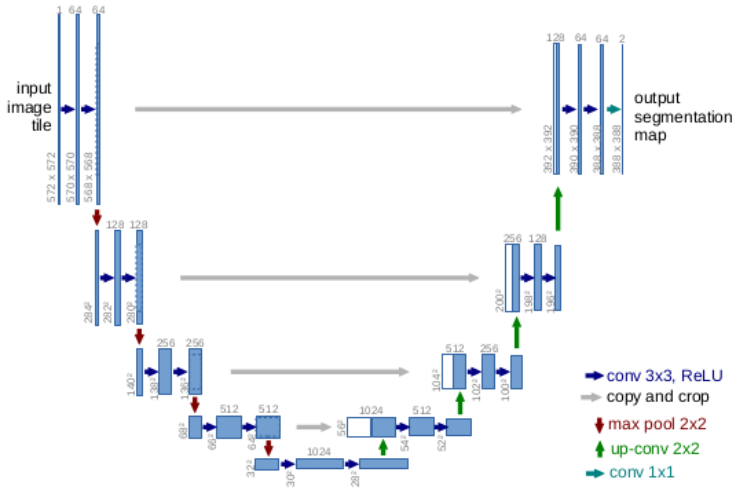

Şekil 3. U-Net Mimarisi [7].

U-Net diğer modellere göre daha az veri ile daha doğru segmentasyon sonucu sağlayan bir mimaridir. Mimarinin temelinde tamamen evrişimli ağ bulunmaktadır. Modelde alınan görüntüye ilk olarak 3x3 boyutunda bir konvolüsyon filtresi 64 kere uygulanarak görüntünün boyutlarına ek 64 derinliğinde 3. bir boyut eklenir. Ardından ReLu yani doğrultulmuş lineer birim fonksiyonu uygulanır. Zero padding olarak bilinen görüntünün kenarlarına sıfır ekleme yöntemi uygulanmadığı için görüntünün yükseklik ve genişliğinde kayıp görülür. Ard arda tekrarlanan konvolüsyon ve ReLu uygulamasından sonra 2x2 boyutundaki filtre ile max pooling olarak ifade edilen maksimum havuzlama yöntemi uygulanır. Bunun sonucunda boyut düşürülerek hesaplama yükü

hafifletilir. Mimarinin yarısında bu üç işlem belirli sıralamalarla uygulanır. Düşen boyut, 2x2 boyutunda 'up-convolution' yani yukarı konvolüsyon filtreleri kullanılarak arttırılır; 3x3 konvolüsyon ve ReLU ile birlikte simetrik olan mimarinin kalanı tamamlanmış olur. U-Net görüntülerde meydana gelen bozulmalara rağmen doğru sonuç verebilen elastik bir yapıya sahiptir [7].

Ayrıca U-Net modelinde segmentasyon için girdi olarak kullanılan maskelerin renk değerleri farklı kodlanarak, çoklu sınıflandırma yapılabilir.

3. Deney ve Eğitim Aşamalarında Kullanılan Veri Setleri

Modelin eğitimi için kullanılacak veri setleri Tablo 1.'de görülmektedir. Tabloda analiz edilen veri setlerinin sayısı, sınıf dağılımı ve biçimi, verideki görüntülerin elde edilme tekniği ve formatı, verinin izinli veya açık kaynak olarak erişildiği gibi özellikler bulunmaktadır.

Tablo 1. BT Görüntüleri Veri Setleri ve Özellikleri

Veri Setleri	Veri Sayısı	Sınıflar	Sınıflama Biçimi	Görüntüleme Tekniği	Görüntü Formatı	Veri Erişimi
1. Sağlık Bakanlığı Yarışma Veri Seti	Toplam : 6650 İskemi: 1130 Kanama : 1093 Diğer : 4427	İskemi Kanama Diğer	Maskeleme	BT	PNG - DICOM	İzinli
2. RSNI Veri Seti [8]	Toplam: 874 bin	Kanama	Etiketleme	BT	DICOM	Açık Kaynak
3. CQ500 [9]	Toplam : 491	Kanama	Etiketleme	BT	DICOM	Açık Kaynak

4. Elde Edilen Deneysel Sonuçların Sunumu

Tasarlanan sistemde ilk olarak Bölüm 2.1'de açıklanan görüntü işleme yöntemleri uygulanmıştır. Örnek olarak iskemi, kanama ve diğer veri sınıfından alınan 5 adet BT görüntüsü Şekil 4'te ve bu BT görüntülerine uygulanan görüntü işleme yöntemleri sonucunda elde edilen işlenmiş görüntüler Şekil 5'te verilmiştir.

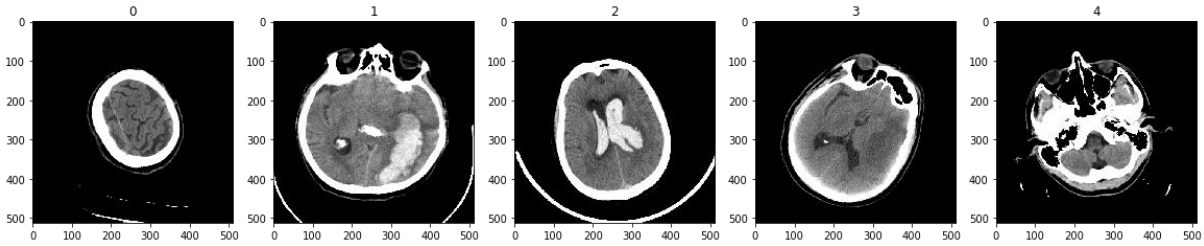

Şekil 4. BT Görüntü Örnekleri

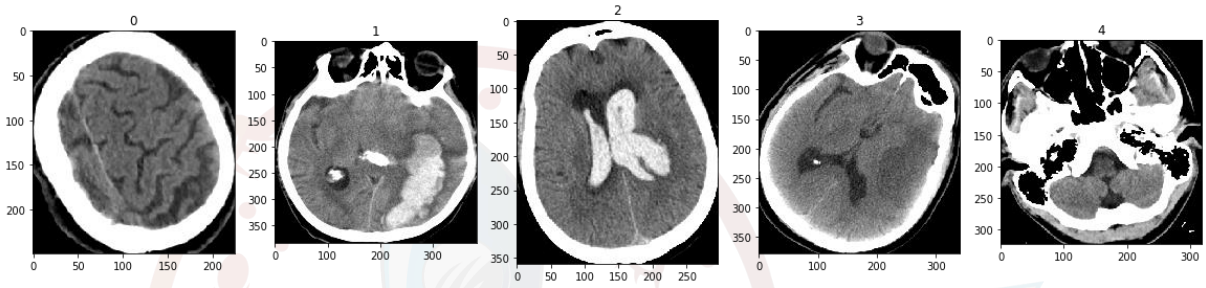

Şekil 5. Görüntü İşleme Uygulanan BT Görüntü Örnekleri

Sınıflandırma bloğunda kullanılan ResNet50 modeli, ön eğitimde imagenet ağırlıkları ile eğitilmiş daha sonra 500 iskemi, 500 kanama verisi ve 1000 adet diğer veri ile eğitilmiştir. Verinin %80'i eğitim ve %20'si validasyon için ayrılmıştır. Modelde batch validasyon için 10 olarak ayarlanmıştır. Modelde kullanılan optimizasyon algoritması RMSprop, loss fonksiyonu olarak da categorical cross entropy kullanılmıştır. Verinin eğitimi sonucunda elde edilen doğruluk ve hata grafikleri (accuracy and loss) Şekil 6'da batch size 16, epoch 50, her epoch boyunca uygulanan adım epoch değeri eğitim için 100 verilmiştir.

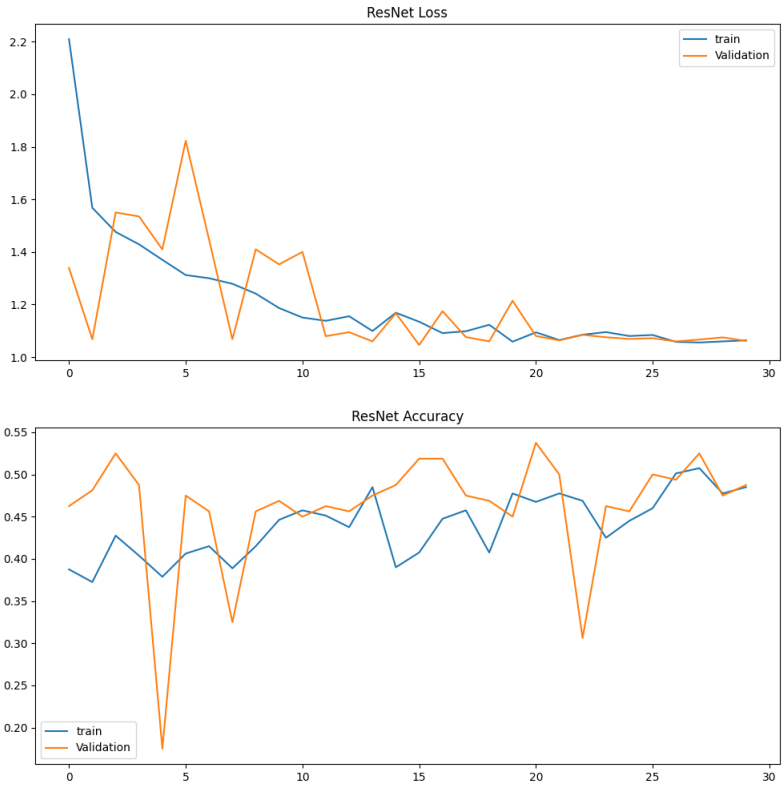

Şekil 6. ResNet Doğruluk ve Hata Grafikleri

Segmentasyon bloğunda kullanılan U-Net model çoklu sınıf segmentasyonu için 500 iskemi, 500 kanama verisi kullanılarak eğitim gerçekleştirilmiştir. Verinin %80'i eğitim ve %20'si validasyon için ayrılmıştır. Modelde kullanılan optimizasyon algoritması Adam, loss fonksiyonu olarak da binary cross entropy kullanılmıştır. Batch size 32, epochs 4 olarak ayarlanmıştır. Verinin eğitimi sonucunda elde edilen doğruluk ve hata grafikleri (accuracy and loss) Şekil 7'de verilmiştir.

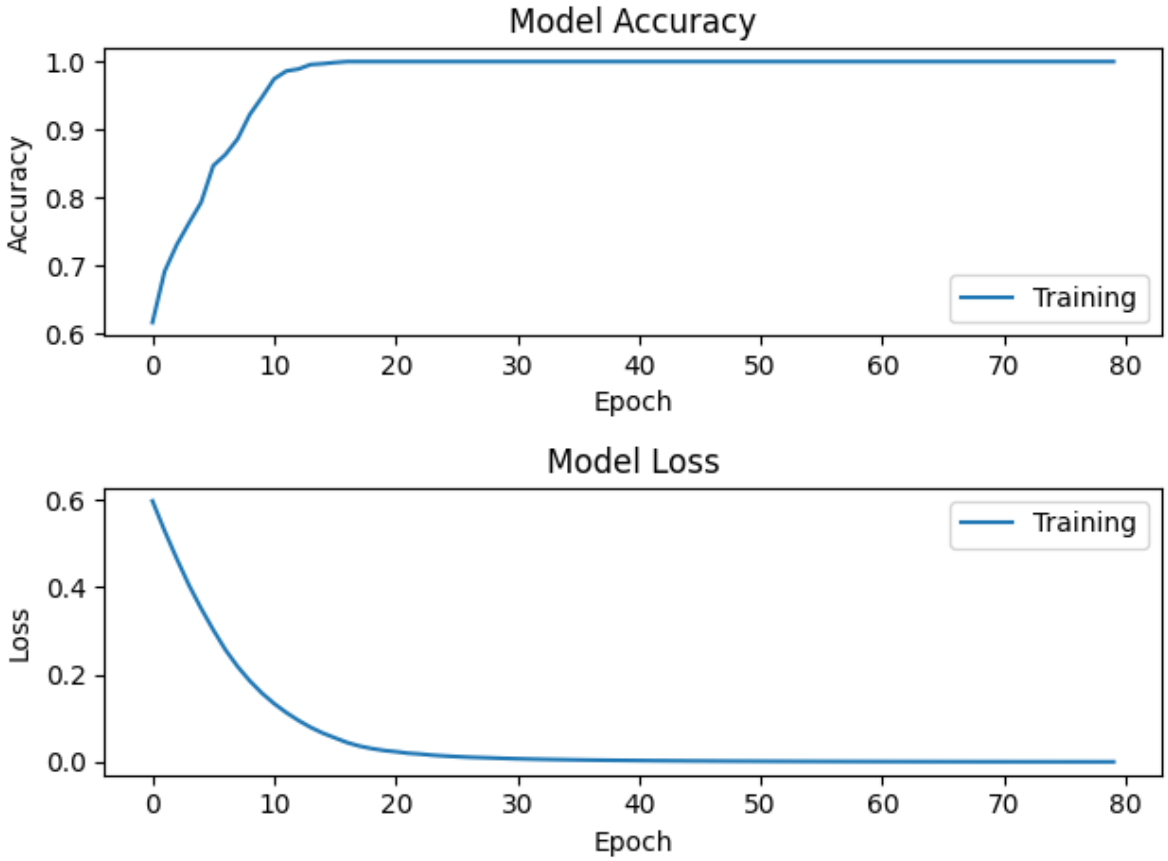

Şekil 7. U-NET Doğruluk ve Hata Grafikleri

ResNet ve U-Net modellerinin eğitimi için kullanılan donanım birimleri yeterli olmadığından, mevcut verilerin sadece bir kısmı kullanılmıştır. Eğitime, uygun donanım kullanılarak, veri setlerinin tamamı ile devam edilecektir.

5. Referanslar

[1] Google Colab ile Ücretsiz GPU Kullanımı | by fuat | Deep Learning Türkiye | Medium, https://medium.com/deep-learning-turkiye/google-colab-ile-%C3%BCcretsiz-gpu-kullan%C4%B1m%C4%B1-30fdb7dd822e, Erişildi: Haziran 2021

[2] Gonzalez Rafael C., Richard E woods, "Digital Image Processing", 2nd Edition

[3] HE, Kaiming, et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 770-778.

[4]PENG, Jie, et al. Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging. *European radiology*, 2020, 30.1: 413-424.

[5] U-Net: Convolutional Networks for Biomedical Image Segmentation, https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/, Erişildi: Haziran 2021

[6] KARCHEVSKIY, Mikhail; ASHRAPOV, Insaf; KOZINKIN, Leonid. Automatic salt deposits segmentation: A deep learning approach. *arXiv preprint arXiv:1812.01429*, 2018.

[7] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: Convolutional networks for biomedical image segmentation. In: *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015. p. 234-241.

[8] RSNA Intracranial Hemorrhage Detection | Kaggle, https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/data, Erişildi: Haziran 2021

[9] Download Head CT CQ500 dataset, http://headctstudy.qure.ai/dataset, Erişildi: Haziran 2021