TÜRKİYE CUMHURİYETİ'NİN YÜZÜNCÜ YILI

Medikal Görüntülerde Matlab Uygulamaları

Editörler:
Meltem Yavuz Çelikdemir
Soner Çelikdemir

BİDGE

BİDGE Yayınları

Medikal Görüntülerde Matlab Uygulamaları

Editörler: Dr. Meltem Yavuz Çelikdemir & Dr. Soner Çelikdemir

ISBN: 978-625-372-610-2

1. Baskı
Sayfa Düzeni: Gözde YÜCEL
Yayınlama Tarihi: 25.12.2024
BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374
Yayın hakları © BİDGE Yayınları
www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com
Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.
Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya / Ankara

Content

Medikal Görüntü İşleme Uygulamaları - MatLab 4
Meltem YAVUZ ÇELİKDEMİR 4
Ayhan AKBAL 4
Derin Öğrenme Uygulamaları 18
Meltem YAVUZ ÇELİKDEMİR 18
Soner ÇELİKDEMİR 18
Makine Öğrenme Uygulamaları 32
Meltem YAVUZ ÇELİKDEMİR 32
Soner ÇELİKDEMİR 32

BÖLÜM I

Medikal Görüntü İşleme Uygulamaları - Matlab

Meltem YAVUZ ÇELİKDEMİR[1]
Ayhan AKBAL[2]

Giriş

Bu kitap bölümü 3 alt başlıktan oluşmaktadır. Giriş bölümünde; amaç, kapsam, problemlerin tanımı, ortaya konulan çözüm önerileri ile birlikte literatür çalışması verilmiştir. İkinci bölümde; medikal görüntülerde işlem yapılması için gerekli beyin anevrizmalı bilgisayarlı tomografi görüntüleri açıklanmış ve beyin anevrizmaları detaylandırılmıştır. Ayrıca anevrizmalar için tanı yöntemleri detaylı olarak açıklanmıştır. Üçüncü bölümde ise; çalışmanın materyal ve metot yöntemleri açıklanmıştır. Beyin anevrizmalı hastalardan oluşan veri setleri oluşturulmuştur. Bu veri setlerindeki medikal görüntülere Matlab programlama dilinde görüntü filtreleme teknikleri uygulanmıştır.

[1] Dr. Meltem Yavuz Çelikdemir, Bitlis Eren Üniversitesi, Tatvan MYO, Elektrik ve Otomasyon Bölümü, Bitlis/Türkiye, Orcid: 0000-0003-0552-2601, meltem.ycd@gmail.com

[2] Doç. Dr. Ayhan Akbal Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Elazığ/Türkiye, Orcid: 0000-0001-5385-9781, ayhanakbal@gmail.com

Günümüz dünyasının nüfus artışına paralel olarak sağlık sorunları da gün geçtikçe yaygın hale gelmektedir. Bu kitap bölümünde insan hayatında ciddi tehlike oluşturan önemli sağlık sorunlarından biri olan serebral anevrizmalar ele alınmıştır. Hayati önem taşıyan beyin anevrizmaları tıp ve mühendislik alanında araştırmacılar tarafından sıklıkla ele alınan güncel bir konudur (Jin et al., 2019). Serebral anevrizmaların tespitinde ve oluşturabilecekleri risk faktörleri düşünüldüğünde erken teşhis çok önemlidir. Gelişen teknoloji ile birlikte anevrizma tanı yöntem ve tekniklerinde de ilerlemeler kaydedilmiştir. Bu bağlamda yapılan çalışmalar serebral anevrizmanın tespiti ve hastalığın teşhisinde hızlı sonuçların alındığı görüntü işleme ve yapay zekaya yönelimi artırmıştır.

Beyin anevrizmasının tespiti ve erken tedavisi için serebral BTA görüntülerinin incelenmesi önemli bir adımdır. Hastalık tanısının konulması ve uygun tedavi yönteminin belirlenmesi açısından dijital ortamlarda uygulanan işlem basamaklarının daha doğru sonuçlar üreteceği öngörülür. Bu doğrultuda serebral BTA görüntülerini içeren, literatürde mevcut olmayan bir veri setine gerekli ön işlem basamakları uygulanmıştır.

Literatür Taraması

Hastalıkların tespitinde görüntü işleme yöntemleri ile ilgili MR görüntülere filtre türleri uygulanarak gürültü bileşenleri giderilebilir. Bu filtrelerin başarı durumlarını değerlendirmek için PSNR (Peak Signal to Noisy Rate) ve SSIM (Structural Similarity Index) performans metrikleri seçilir. Uygulanan filtrelerin, tüm resimler için en iyi sonucu veren baskın bir algoritmanın olmadığı ve PSNR ya da SSIM skoru açısından net bir fark olmadığı gözlemlenebilir (Kutan & Aynur, 2020). Serebral anevrizmalar için CNN'e dayalı görüntü segmentasyon yöntemi değerlendirilebilir. BTA görüntülerine Gaussian ve Laplace filtreleri uygulanabilir. Hem orijinal hem de işlenmiş bu görüntüler ile çok modlu CNN eğitimi gerçekleştirilebilir. Eşik değeri 0,95 iken segmentasyon etkisinin performansının maksimum seviyede olduğu belirtilebilir

(Meng et al., 2021). Üç boyutlu T1 ağırlıklı manyetik rezonans görüntülerinde ön işlem yapılabilir. İşlem eksen dönüştürme, görüntü reoryantasyonu, normalizasyon, modülasyon, segmentasyon, gürültü giderme, yumuşatma adımları olarak incelenebilir (Öziç & Özşen, 2020).

Beyin Anevrizmaları

Anevrizmalar; atardamar duvarında oluşan baloncuk benzeri genişlemedir. En sık yerleşim bölgeleri ise beyin atardamarı ve aort damarı olarak gözlemlenir. Duvar yapılarına göre; gerçek ve yalancı (psödo) anevrizmalar olarak sınıflandırılır. Tıbbi kayıtlı hasta bilgileri incelendiğinde psödo anevrizmalar veri setinde hariç tutulmuştur. Anevrizma varlığında en belirgin özellik baş ağrısıdır. Bu durumdan dolayı uzmanlar tarafından geç tanı konulur. Anevrizmaların duvarları çok ince yapıda olduklarından zaman geçtikçe daha fazla incelir. İhmal edildiklerinde anevrizmalar, rüptür (yırtılma) ile birlikte subaraknoid kanamalara neden olur. Anevrizmaların tedavi yöntemleri uzmanlar tarafından endovasküler (kapalı anevrizma) tedavi ve klipleme (açık anevrizma) olarak uygulanabilir. Anevrizmalar morfolojilerine göre türleri bakımından sınıflandırılır. Beyin arterlerinde oluşan yuvarlak, kese biçimli sakküler anevrizma görüntüsü Şekil 1'de verilmiştir.

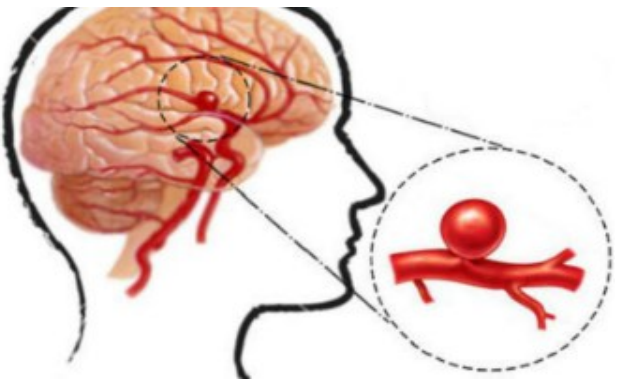

Şekil 1. Sakküler anevrizmalı beyin görüntüsü

Anevrizmalarda Tanı Yöntemleri

Anevrizma hastalığının tedavi yöntemini belirlemek ve prognozunu tayin etmek için hastalığa doğru ve kesin tanı konulması şarttır. Tanı tayin etmede farklı ve benzer hastalıkların ayrıştırılması için tıbbi görüntülemeye ihtiyaç vardır (Yang et al., 2023). Parankim ve beyin çevresindeki belirgin kanamalarda ilk başvurulacak yöntem BT'dir. Serebral damarları görebilmek için tercih edilen en iyi yöntem ise anjiyografidir. Anevrizmaları değerlendirirken kullanılan görüntü tanı yöntemleri Bilgisayarlı Tomografi Anjiyografi (BTA), Manyetik Rezonans Anjiyografi (MRI) ve Dijital Çıkarmalı Anjiyografi (DSA) olarak sınıflandırılır (Beaman et al., 2023; Din et al., 2023).

Bilgisayarlı Tomografi Anjiyografi

1990'lı yıllardan günümüze ulaşan anevrizma taramalarında tercih edilen en etkili görüntüleme yöntemlerinin başında Bilgisayarlı Tomografi Anjiyografi (BTA) gelir. BTA, ince kesit kontrastlı BT görüntülerin farklı yazılımlar kullanılarak 3 boyutlu görüntüler olarak yeniden yapılandırılmasıdır.

Materyal ve Metot

Bireylerde hastalıkların tespit edilebilmesi için medikal görüntü kalitesinin iyi olması gereklidir. Hastane ortamlarında çekilen bu görüntüler bazı durumlarda gerek gürültüden gerek cihaz problemlerinden kaynaklı görüntü netliğine engel olmaktadır. Bu durumlar göze alındığında hastalık tespit edilmeden önce görüntülerin iyileştirilmesi gerekliliğini doğurur. Bu bağlamda öncelikli hedef beyin BTA görüntü veri seti oluşturmaktır. Oluşturulan veri setindeki görüntülere gerekli ön işlemler yapılmıştır. Böylece görüntüde netlik elde edilmiştir. Matlab 2023a programında m-file olarak uygulanacak filtreler için kodlar yazılmıştır.

Veri seti

Veri seti Fırat Üniversitesi Hastanesi Beyin Cerrahi Polikliniği'ne başvuru yapan kişilerin BTA görüntülerini içermektedir. Farklı kesitlerden elde edilen anevrizmalı BTA görüntüleri, 911 hastalıklı ve 300 sağlıklı olmak üzere toplam 1211 adet görüntüyü içermektedir. Bu görüntüler için izlenen ön işlem adımları Şekil 2'de gösterilir.

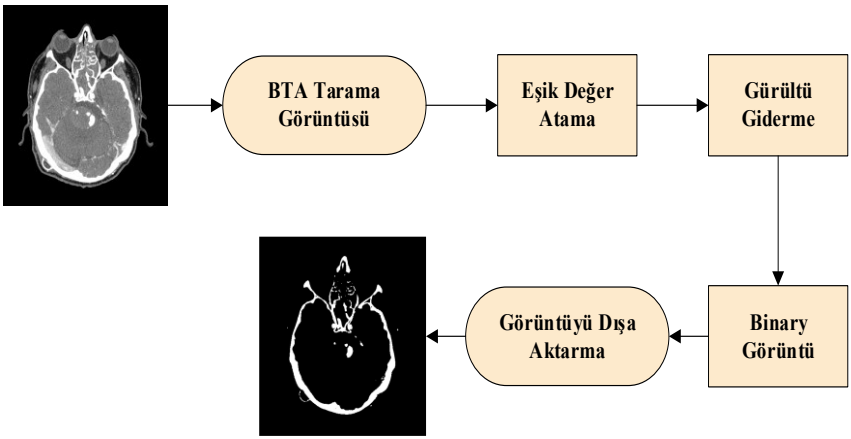

Şekil 2. Binary görüntü dönüşüm aşamaları

Görüntü Ön İşleme

Sağlıklı ve hastalıklı olmak üzere hastaların beyin BTA görüntüleri ön işlemden geçirilir. Görüntüler ilk aşamada ".dicom" uzantılıdır. Bu görüntüler veri seti oluşturulurken ".jpg" uzantılı olarak dönüştürülür. Daha sonra farklı piksel çözünürlüklerine sahip jpg uzantılı BTA görüntülerinin tamamı 512x512 piksel çözünürlüğünde boyutlandırılır. Görüntü üzerinde binary dönüşüm yapılmış ve 5 farklı filtreleme tekniği uygulanır. Bu filtreler canny, medyan, prewitt, sobel ve smoothing filtreleridir. Görüntü işlemede sıkça karşılaşılan Medyan ve Smoothing filtreleri gürültüleri azaltmak ve yumuşatma işlemi için, Sobel, Canny ve Prewitt filtreleri ise kenar tespit işlemi gerçekleştirmek için beyin BTA görüntülerine uygulanır.

Canny Filtre

Canny yönteminin zayıf kenarları tespit etme olasılığı yüksek, gürültüye aldanma olasılığı ise diğer filtrelere göre daha düşüktür. İlk aşamada gürültü ortadan kaldırılır. Yoğunluk gradyanları bulunur ve gradyan büyüklüğü eşiklemesi uygulanır. Daha sonra potansiyel kenarlar belirlenir. Son aşamada ise zayıf ve bağlantısız kenarlar azaltılarak kenar tespiti doğrulanır. Aşamalı yapısı gereği bu algoritmada hata oranı düşüktür (Wu et al., 2022). Şekil 3'te canny filtre uygulanmış örnek bir hasta için anevrizmalı beyin görüntüsü verilmiştir.

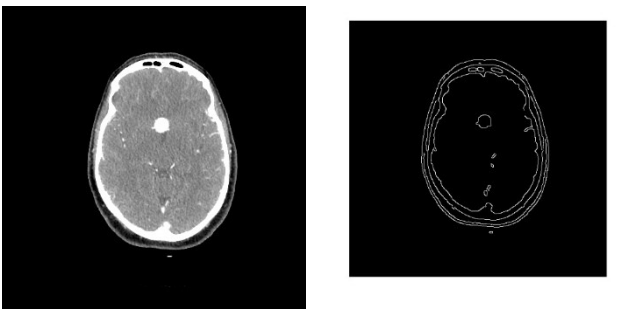

Şekil 3. Canny filtre uygulanan anevrizmalı beyin görüntüsü

Programda yazılan kodlar ile görüntüye canny filtresi uygulanır. Bu kodlar Şekil 4'te verilmiştir.

```
clear all
clc
inpict = imread('E:\.........dosya yolu....................jpg');
Ymask = rgb2gray(inpict)<128;
Ymask = ~imfill(Ymask,'holes');

inlevels = stretchlim(inpict).*[0; 1];
outpict = imadjust(inpict,inlevels);

outpict(repmat(Ymask,[1 1 3])) = 255;
figure(1)
imshow(outpict)
outpict = double(im2gray(outpict));
outpict = imresize(outpict,[512,512]);

figure(5)
outpict = edge(outpict,'Canny',[0 0.35]);
imshow(outpict,[])
```

Şekil 4. Canny filtre uygulama kodları

Medyan Filtre

Görüntülerde mevcut olan gürültü oranını azaltma ve ayrıntı kayıplarını önlemek için kullanılan filtreleme yöntemidir. Medyan filtreleme yaparken görüntü verisi üzerinde 3x3 ve 8x8 matris boyutlu istenilen bölgede komşu piksel değerleri sırasıyla dizilir ve ortada yer alan piksel değeri baz alınır. Orta değerin seçilmesi uç değerlerin varlığını yok ederek sapmayı azaltır. Böylece yeni elde edilen görüntüde gürültü giderilmiş olur. Retina fundus görüntü sınıflandırması için ön işlem basamağı olan gürültü giderme medyan filtreleme ile gerçekleştirilmiş olup derin evrişimli sinir ağı tekniğine dayalı yapay zeka tasarımı gerçekleştirilmiştir (Gupta et al., 2022). Görüntü işleme algoritmaları kullanılarak yapılan çalışmalarda medyan ve canny kenar algılama filtresi kullanılarak konveyör bant üzerinden geçen ürünlerin hatalı ve hatasız tespit durumları gerçekleştirilmiştir (Uzun & Boyacıgil, 2023). Hazırlanan veri setindeki beyin BTA görüntülerinden örnek bir hasta için medyan filtre uygulanmasına ait anevrizma görüntüsü Şekil 5'te verilmiştir.

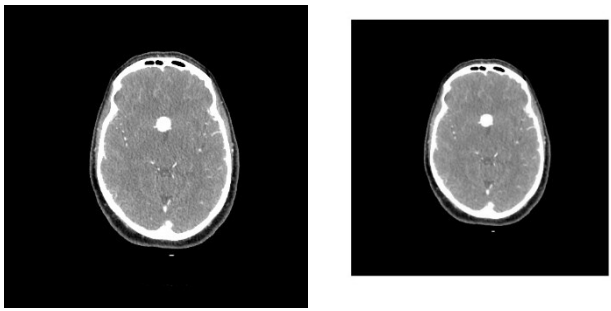

Şekil 5. Medyan filtre uygulanan anevrizmalı beyin görüntüsü

Programda yazılan kodlar ile görüntüye medyan filtresi uygulanır. Bu kodlar Şekil 6'da verilmiştir.

```
inpict = imread('E:\............dosya yolu.......................jpg');
Ymask = rgb2gray(inpict)<128;
Ymask = ~imfill(Ymask,'holes');
inlevels = stretchlim(inpict).*[0; 1];
outpict = imadjust(inpict,inlevels);
outpict(repmat(Ymask,[1 1 3])) = 255;
figure(1)
imshow(outpict)
outpict = double(im2gray(outpict));
outpict = imresize(outpict,[512,512])
m = 3; n = 3;
outpict = medfilt2(outpict,[m,n]);
figure(3)
imshow(outpict,[])
```

Şekil 6. Medyan filtre uygulama kodları

Prewitt Filtre

Prewitt yaklaşımı kullanılarak beyin BTA görüntülerinde gradyanın maksimum olduğu noktalardaki kenarlar tespit edilir. Görüntü gradyan büyüklüğüne yaklaşarak kenarları bulur. Giriş matris prewitt algoritmasının yatay ve dikey çekirdekleri ile evriştirilir. Elde edilen gradyan bileşeni çıktı olarak alınır. Prewitt, hesaplama açısından basit olsa da klasik kenar tespit algoritmalarına göre daha gürültülü sonuçlar verir (A S & Gopalan, 2022). Prewitt filtre uygulanan örnek bir hastanın beyin BTA'sına ait görüntü Şekil 7'de verilmiştir.

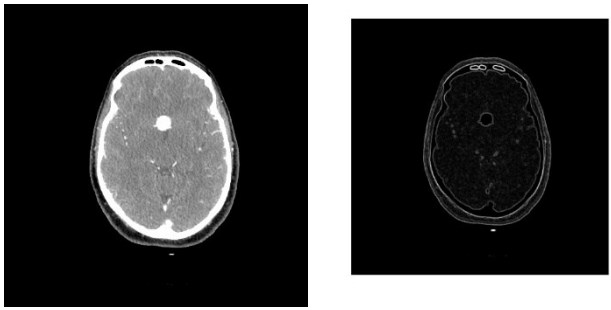

Şekil 7. Prewitt filtre uygulanan anevrizmalı beyin görüntüsü

Programda yazılan kodlar ile görüntüye prewitt filtresi uygulanır. Bu kodlar Şekil 8'de verilmiştir.

```
inpict = imread('E:\............dosya yolu...................jpg');
Ymask = rgb2gray(inpict)<128;
Ymask = ~imfill(Ymask,'holes');
outpict(repmat(Ymask,[1 1 3])) = 255;
figure(1)
imshow(outpict)
outpict = double(im2gray(outpict));
outpict = imresize(outpict,[512,512]);
figure(6)
outpict = imgradient(outpict,'prewitt');
imshow(outpict,[])
```

Şekil 8. Prewitt filtre uygulama kodları

Sobel Filtre

Sobel filtresi canny ve prewitt filtresinde olduğu gibi kenar tespitinde kullanılan klasik filtreme tekniğidir. Bu filtre görüntülerin gri seviyelerinde fark edilen yüksek aralık farklılıklarının frekanslarını verir (Padlia & Sharma, 2019). Komşu pikselleri işleyerek gradyanlar elde eden, yaygın kullanılan bir filtredir. Gradyanları elde etmek için "kenar tespit operatörü, çekirdek matrisi" adı verilen farklı boyutlardaki matrisler kullanılır. Gürültülü görüntülerde kenarlar yüksek frekansları içerir ve gürültüyü azaltmak kenarları bozarak bulanıklaştırabilir. Bu yüzden bu

görüntülerde kenar tespit işleminin gerçekleştirilmesi zordur (Bilal Macit & Koyun, 2023). Kenar çıkarma işleminin sobel filtresi ile gerçekleştirildiği anevrizmalı beyin BTA görüntüsü Şekil 9'da verilmiştir.

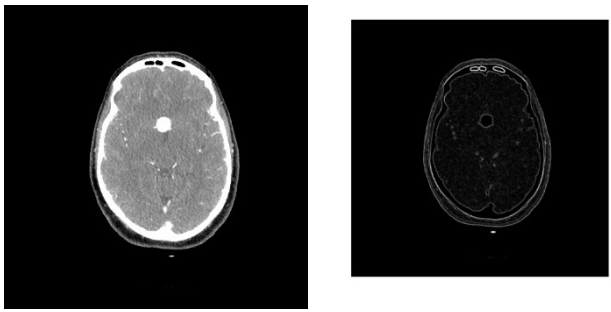

Şekil 9. Sobel filtre uygulanan anevrizmalı beyin görüntüsü

Programda yazılan kodlar ile görüntüye sobel filtresi uygulanır. Bu kodlar Şekil 10'da verilmiştir.

```
inpict = imread('E:\.........dosya yolu........jpg');
Ymask = rgb2gray(inpict)<128;
Ymask = ~imfill(Ymask,'holes');
inlevels = stretchlim(inpict).*[0; 1];
outpict = imadjust(inpict,inlevels);
outpict(repmat(Ymask,[1 1 3])) = 255;
figure(1)
imshow(outpict)
outpict = double(im2gray(outpict));
outpict = imresize(outpict,[512,512]);
figure(4)
outpict = imgradient(outpict,'sobel');
imshow(outpict,[])
```

Şekil 10. Sobel filtre uygulama kodları

Smoothing Filtre

Smoothing veri kümelerindeki gürültüyü azaltma işlemlerinde kullanılan yumuşatma filtresidir. Görüntü işleme uygulamaları arasında sıkça tercih edilen önemli filtrelerdendir. Yumuşatma işlemi ile elde edilen yeni görüntü kenarların

çıkarılması için uygun hale getirilir. Burada temel amaç eğimin yumuşatıldığı noktalarda Sobel, Prewitt, Canny filtreleri kullanılarak kenar çıkarma işleminin gerçekleştirilmesidir. Örnek bir hasta için beyin BTA'sına uygulanan yumuşatma işlemi sonucu yeni görüntü Şekil 11'de verilmiştir.

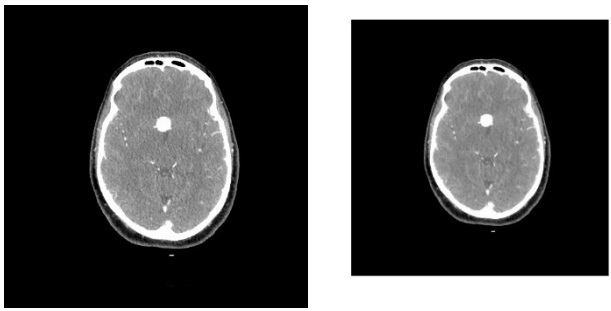

Şekil 11. Smoothing filtre uygulanan anevrizmalı beyin görüntüsü

Programda yazılan kodlar ile görüntüye smoothing filtresi uygulanır. Bu kodlar Şekil 12'de verilmiştir.

```
inpict = imread('E:\........dosya yolu.....jpg');
Ymask = rgb2gray(inpict)<128;
Ymask = ~imfill(Ymask,'holes');
inlevels = stretchlim(inpict).*[0; 1];
outpict = imadjust(inpict,inlevels);
outpict(repmat(Ymask,[1 1 3])) = 255;
figure(1)
imshow(outpict)
outpict = double(im2gray(outpict));
outpict = imresize(outpict,[512,512]);
figure(2)
DoS = 1000;
outpict = imbilatfilt(outpict,DoS);
imshow(outpict,[])
```

Şekil 12. Smoothing filtre uygulama kodları

Sonuç

Görüntü işlemenin tıp, savunma sanayi, güvenlik alanlarında yaygın bir şekilde uygulandığı söylenebilir. Bu bölümde medikal

görüntülerde görüntü işleme uygulamaları Matlab 2023a programlama dilinde açıklanmıştır. Görüntülerde ön işlem adımları olan boyutlandırma, filtreleme ve binary dönüşüm yapılabilirliği ayrıntılı olarak ele alınmıştır. Veri setlerindeki görüntülere canny, medyan, prewitt, sobel ve smoothing filtreleme tekniklerinin uygulanabilirliği verilen kodlar ile açıklanmıştır. Filtreli görüntülerin işlem görmeyen ham görüntülere göre farklılıkları şekillerle desteklenmiştir. Yumuşatma, gürültü giderme ve kenar algılama filtrelerinin uygulanması ile görüntü verilerinde netlik kazandıracağı öngörülür.

Kaynaklar

A S, R. A., & Gopalan, S. (2022). Comparative Analysis of Eight Direction Sobel Edge Detection Algorithm for Brain Tumor MRI Images. *Procedia Computer Science*, *201*, 487–494. https://doi.org/10.1016/j.procs.2022.03.063

Beaman, C., Patel, S. D., Nael, K., Colby, G. P., & Liebeskind, D. S. (2023). Imaging of Intracranial Saccular Aneurysms. *Stroke: Vascular and Interventional Neurology*, *3*(5). https://doi.org/10.1161/SVIN.122.000757

Bilal Macit, H., & Koyun, A. (2023). An Active Image Forgery Detection Approach Based on Edge Detection. *Computers, Materials & Continua*, *75*(1), 1603–1619. https://doi.org/10.32604/cmc.2023.036216

Din, M., Agarwal, S., Grzeda, M., Wood, D. A., Modat, M., & Booth, T. C. (2023). Detection of cerebral aneurysms using artificial intelligence: a systematic review and meta-analysis. *Journal of NeuroInterventional Surgery*, *15*(3), 262–271. https://doi.org/10.1136/jnis-2022-019456

Gupta, I. K., Choubey, A., & Choubey, S. (2022). Artifical intelligence with optimal deep learning enabled automated retinal fundus image classification model. *Expert Systems*, *39*(10). https://doi.org/10.1111/exsy.13028

Jin, H., Yin, Y., Hu, M., Yang, G., & Qin, L. (2019). *Fully automated unruptured intracranial aneurysm detection and segmentation from digital subtraction angiography series using an end-to-end spatiotemporal deep neural network*. https://doi.org/10.1117/12.2512623

Kutan, F., & Aynur, Ö. (2020). Gürültü Filtreleme Uygulamalarının Medikal Görüntüler Üzerindeki Performanslarının Değerlendirilmesi. *European Journal of Science and Technology*, 265–271. https://doi.org/10.31590/ejosat.779957

Meng, C., Yang, D., & Chen, D. (2021). Cerebral aneurysm image segmentation based on multi-modal convolutional neural network. *Computer Methods and Programs in Biomedicine*, *208*, 106285. https://doi.org/10.1016/j.cmpb.2021.106285

Öziç, M. Ü., & Özşen, S. (2020). Üç Boyutlu T1 Ağırlıklı Manyetik Rezonans Görüntülerinde Ön İşleme Yöntemleri. *European Journal of Science and Technology*, 227–240. https://doi.org/10.31590/ejosat.719062

Padlia, M., & Sharma, J. (2019). *Fractional Sobel Filter Based Brain Tumor Detection and Segmentation Using Statistical Features and SVM* (pp. 161–175). https://doi.org/10.1007/978-981-13-0776-8_15

Uzun, Y., & Boyacıgil, M. (2023). Raspberry PI Tabanlı Görüntü İşleme Uygulaması Geliştirilmesi. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *6(2)*, 1067–1078.

Wu, F., Zhu, C., Xu, J., Bhatt, M. W., & Sharma, A. (2022). Research on image text recognition based on canny edge detection algorithm and k-means algorithm. *International Journal of System Assurance Engineering and Management*, *13*(S1), 72–80. https://doi.org/10.1007/s13198-021-01262-0

Yang, G., Yan, C., Zhang, M., Li, J., Zhu, J., & Zhao, L. (2023). Application effect of multi-slice spiral CT angiography combined with MRI in the diagnosis of cerebral aneurysm. *Biotechnology and Genetic Engineering Reviews*, 1–14. https://doi.org/10.1080/02648725.2023.2202995

BÖLÜM II

Derin Öğrenme Uygulamaları

Meltem YAVUZ ÇELİKDEMİR[3]
Soner ÇELİKDEMİR[4]

Giriş

Bu kitap bölümü 3 alt başlıktan oluşmaktadır. Giriş bölümünde; amaç, kapsam, problemlerin tanımı, ortaya konulan çözüm önerileri ile birlikte literatür çalışması verilmiştir. İkinci bölümde derin öğrenme modelleri açıklanmıştır. Üçüncü bölümde ise model eğitimlerinin sınıflandırma bulguları açıklanmıştır.

Teknolojide kaydedilen hızlı ilerlemeler hastalık tespitlerinde de kendini göstermektedir. İnsan hayatına tehdit unsurları oluşturan hastalıkların teşhisi ve tespitinde derin öğrenme çalışmaları gün geçtikçe artış göstermektedir. Derin öğrenmenin tarihçesi, sinir sisteminin temel birimi olan nöronların yapay modelinin ortaya atılması ile 1943'lere kadar dayanır (Fitch, 1944). Yapay zeka terimi ilk olarak 1955 yılında kullanılmış, daha sonra

[3] Dr. Meltem Yavuz Çelikdemir, Bitlis Eren Üniversitesi, Tatvan MYO, Elektrik ve Otomasyon Bölümü, Bitlis/Türkiye, Orcid: 0000-0003-0552-2601, meltem.ycd@gmail.com

[4] Dr. Soner Çelikdemir, Bitlis Eren Üniversitesi, Adilcevaz MYO, Elektrik ve Otomasyon Bölümü, Bitlis/Türkiye, Orcid: 0000-0002-1419-3398, scelikdemir@gmail.com

geriye yayılım algoritması 1986 yılında ortaya atılmıştır. Deep Blue yazılımı Uluslararası İş Makineleri (IBM) tarafından 1997'de çıkmış ve Yann LeCun ekibi 1998'de 0-9 arası rakamları Evrişimli Sinir Ağı (CNN) ile sınıflandırmışlardır. IMAGENET görüntü veri kümesi 2009'da ücretsiz kullanıma açılmıştır. İlk yapay zeka asistanı SİRİ 2011'e orta çıkmıştır. AlexNet ismi 1998'de oluşturulan LeNet modeli ve 2009'da kullanımına izin verilen ImageNet veri seti ile beraber orta atılmıştır.

Bilgi işleme teknolojisi olan yapay sinir ağları bilgi işleme teknolojisinde adından sıkça söz ettirmektedir. Veri biliminde derin öğrenme çok katmanlı sinir ağlarından oluşmaktadır. Bu kitap bölümünde derin öğrenme mimarilerinden olan evrişimli sinir ağlarının görüntü veri setlerinde nasıl uygulanacağı açıklanmıştır.

Literatür Taraması

Hastalıkların tespitinde derin öğrenme yöntemleri ile ilgili açık erişimli 1252 COVID-19 ve 1230 COVID olmayan BT tarama görüntülerinden oluşan veri setinde, önceden eğitilmiş MobileNetV2 ve DarkNet19 derin öğrenme modelleri ve yeni tasarlanmış Derin Öğrenme Modeli (DLM) kullanılarak COVID-19'un otomatik taraması yapılabilir. Derin öğrenme modelinde eğitim, doğrulama ve test işlemi için tekrarlanan on kat uzatma doğrulama yöntemi kullanılabilir ve en yüksek sınıflandırma doğruluğu, %98,91 ile transfer öğrenimli DarkNet19 kullanılarak elde edilir. Bu durumda, daha fazla BT görüntüsünün test edilebileceği belirtilir (Gupta & Bajaj, 2023). CNN mimarisinden oluşan AlexNet ağında transfer öğrenme kullanılarak yüz tanıma gerçekleştirilir. Çalışma sekiz çekirdekli Intel i5 işlemcili NVIDIA GeForce RTX 3090 grafik kartı ve 8 GB bellek içeren ekipmanla ve Matlab programlama dilinde yapılabilir. Bu metodoloji ile yüz tanıma doğruluğunun %98 başarı gösterdiği belirtilir (Singh et al., 2022). Ürdün'deki Kral Hüseyin Tıp Merkezi Hastanesi'nden toplanan, hidrosefali ve hidrosefali olmayan bebekler için BT taramalarından oluşan yeni bir veri seti kullanılabilir. Verilere aynı zamanda kırpma, filtreleme, normalleştirme, bölümleme ve büyütme teknikleri uygulanabilir. Bu

veriler, ölüm oranını ve beyin hasarını azaltacak konjenital hidrosefalinin erken ve doğru teşhisinde hekimlere yardımcı olacak derin öğrenme ve makine öğrenimi oluşturmak için kullanılabilir. Modelin sonuçları, bebeklerin beyin BT görüntülerinde konjenital hidrosefali sınıflandırması için %98,5 doğrulukta hesaplanır (Rub et al., 2023). Ayrıca ABD'de bulunan 130 hastaneden 70000 kayda ait veri setleri düzenlenerek diyabet durumlarına göre sınıflandırmaları makine öğrenme algoritmaları ile yapılabilir. Performans olarak en iyi sonucu gösteren beş sınıflandırma algoritması (karar ağaçları, k en yakın komşu, lojistik regresyon, naive bayes ve rastgele orman) değerlendirilir. Rastgele orman algoritması 0,89 hassasiyet, 0,814 özgüllük, 0,793 duyarlılık ve 0,912 AUC değerleri ile en yüksek performansın elde edildiği belirtilir (Özlüer Başer et al., 2021). AlexNet ile diyabetik retinopati görüntülerinin sınıflandırma doğruluğu %96,6 olarak elde edilir (Shanthi & Sabeenian, 2019). Derin öğrenmenin anevrizma hastalığında rolü ve sınırları araştırılır. Moyamoya hastalığı ve serebral arteriyovenöz malformasyonlarda otomatik tespit uygulaması incelenebilir (Mensah et al., 2022). Hazır veri setlerinden alınan PCG sinyallerindeki anormalliği ayırt edebilmek için AlexNet kullanılarak %87 doğruluk elde edilir (Alaskar et al., 2019). AlexNet-Kuantum transfer öğrenme yöntemi ile MRI veri kümesi kullanılarak Parkinson ve Alzheimer hastalığı teşhis edilir. Sınıflandırma doğrulukları sırasıyla %97 ve %96 olarak elde edilir (Alsharabi et al., 2023).

Anevrizma hastalığının tespitinde derin öğrenme yöntemleri ile ilgili yapay zekanın BTA ile intrakraniyal anevrizma tespitinde doğruluğu artırılabilir. Bu bağlamda BTA ve Dijital Çıkarma Anjiyografi (DSA) yapılan 212 hasta çalışmaya dahil edilir. Anevrizma tespiti için yapay zeka, doktorlar, yapay zeka-doktorlar olmak üzere üç farklı yöntem değerlendirilir. Hastaların 179'u için DSA ile anevrizma tanısı konulmuş ve 224 anevrizma analiz edilir. Anevrizma tanısında yapay zekanın performans metrikleri; doğruluk %74,5 duyarlılık %84,9 ve özgüllük %18,2 oranında hesaplanır (Wei et al., 2022). İntrakraniyal anevrizma tespiti için farklı derin öğrenme modelleri geliştirilir. Fakat bu modellerin anevrizma tespitine dayalı performansları değerlendirilir. Performans

değerlendirme ve klinisyenlere sağlayacağı yardım gözetilerek modellerin etkisi meta-analiz ile ölçülebilir. Anevrizma tespitinin hasta düzeyinde duyarlılığı %92, özgüllüğü %96 ve lezyon düzeyinde duyarlılığı %92 olduğu özetlenir (Gu et al., 2022). Kafa içi anevrizmaların otomatik tespiti için DSA görüntüleri geliştirilen derin öğrenme algoritmasında kullanılabilir. Eğitim setinde 75, dahili test setinde 20 ve harici test setinde 35 vaka üç boyutlu U-Net'e dayalı değerlendirilir. Duyarlılık oranı eğitim ve dahili test setinde %94,4 harici test setinde %82,9 elde edilir. Kadınlarda %81,8 ve erkeklerde %84,6 oranı ile anevrizma saptandığı belirtilmiştir (Wang et al., 2022). Anevrizmaların tespitini kolaylaştırmak için, üç boyutlu DSA görüntüleri üzerinde anevrizmaların tespiti, morfoloji ölçümü ve konum sınıflandırması için kapsamlı bir sistem önerilmiş ve otomatik tanılama için olanak sağlayabilir. Anevrizma tespiti, morfoloji ölçümü ve anevrizma yerini belirlemek için üç sinir ağı kullanılır. Anevrizma tespitinde duyarlılık %85, beş kat çapraz doğrulamada anevrizma yeri sınıflandırmada doğruluk oranı %94, Serebral Anevrizma Tespiti ve Analizi (CADA) yarışmasında kullanılan test setinde ise %100 başarı elde edebilir (Ou et al., 2022). Serebral damarın tıkaması sonucu oluşan nörolojik bir hastalık olan 'İnme' için derin öğrenme tabanlı tespiti amaçlanır. Veri kümesindeki Manyetik Rezonans Görüntüleme (MRI) görüntüleri ön işlemden geçirilerek, önceden eğitilmiş Resnet101 ve DenseNet201 evrişimli sinir ağları aracılığıyla derin özellikleri çıkarılır. Çalışmada sunulan modelin doğruluğu 3 farklı veri kümesi için değerlendirilmiş olup sonuçları %97,56 %99,32 ve %99,16 olarak hesaplanabilir (Tasci & Tasci, 2022). TOF-MRA üzerinde anevrizmaları tespit etmek için tasarlanan yapay zeka tabanlı yazılım değerlendirilir. MR görüntüleme veri setinde 191 görüntü "mdbrain" yazılımı kullanılarak analiz edilir. Uzman okuyucu 54 anevrizma tespit ederken yazılımın duyarlılığı %72,6 özgüllüğü %87,2 ve doğruluğu %82,6 olarak hesaplanabilir. Pozitif öngörü değeri %67,9 ve negatif öngörü değeri %88,5 olarak bulunabilir. Fuziform ve tromboze anevrizmalar için sırasıyla %33,3 ve %16,7 ile düşük tespit oranına sahip olabilir. Fakat 5 mm'den büyük sakküler anevrizmalar için

duyarlılık %100 olarak hesaplanabilir (Lehnen et al., 2022). Ayrıca 1177 dijital kemik çıkarma BTA tarama görüntüleri intrakraniyal anevrizmaları otomatik saptamak üzere derin öğrenme tabanlı model ile eğitilebilir. Modelde sınıflandırma doğruluğu %99 olup radyologların iş yükünü azaltmak amacı ile gerçekleştirilir (Shi et al., 2020). Üç farklı kurumdan 2006-2019 tarihleri arasında serebral anevrizmaların TOF-MRA görüntüleri çalışma kapsamındadır. Dahili testte %80 eğitim %20 eğitim için görüntüler kullanılmıştır. Hariç tutulma kriterleri 15 mm'den büyük olan anevrizmalar ve anevrizması olmayan görüntülerdir. Voksel bazlı anevrizma tespiti için üç farklı derin öğrenme modeli eğitilebilir. Bu modeller 2D-CNN, 3D-CNN ve MD-CNN'dir. Çalışmaya dahil edilen 559 vakada 732 anevrizma mevcut olup en yüksek hassasiyetler sırasıyla %80,4, %87,4 ve %82,5 olarak bulunur. Vaka başına yanlış pozitifler sırasıyla 6,1 7,1 ve 5,0 olarak hesaplanabilir. Harici test işleminde ise hassasiyetler %82,1 %86,5 ve %89,1 iken vaka başına yanlış pozitifler 5,9 7,4 ve 4,2 olarak bulunabilir (Terasaki et al., 2022).

Evrişimli Sinir Ağları

Bilgi işleme teknolojisi olan yapay sinir ağları insan beyninin bilgileri işleme yeteneğinden geliştirilmiştir. Makine öğreniminin alt kümesi olan derin öğrenme ise, çok katmanlı sinir ağlarından oluşan veri biliminde önemli bir unsurdur. Veri biliminin temel yapıtaşları Şekil 1'de verilmiştir.

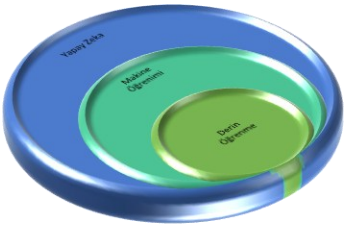

Şekil 13. Veri biliminde temel yapıtaşlar

Derin öğrenme mimarileri aşağıdaki gibi sınıflandırılabilir:

- Evrişimli Sinir Ağı (CNN)
- Tekrarlayan Sinir Ağı (RNN)
- Sınırlı Boltzman Makineleri (RBM)
- Derin İnanç Ağı (DBN)
- Derin Oto Kodlayıcılar (DAE)

Bu mimariler arasında CNN'de girdi verisi görüntülerden oluşmaktadır (Gurkan et al., 2021). Serebral anevrizması mevcut hastaları tespit edebilmek için kullanılan beyin BTA görüntülerinin derin özellikleri derin öğrenme ağları kullanılarak çıkarılmıştır. Derin öğrenme tabanlı CNN mimarileri arasından kullanılan bu ağlar Tablo 1'de verilmiştir.

Tablo.1. Öğrenmede kullanılan evrişimli sinir ağları

AlexNet	MobileNetV2	ShuffleNet
DenseNet201	NASNetMobile	SqueezeNet
GoogLeNet	ResNet18	VGG16
InceptionResNetV2	ResNet50	VGG19
InceptionV3	ResNet101	Xception

Bu evrişimleri sinir ağlarını öğrenmede kullanabilmek için Matlab2023a'da Şekil 2'de verilen transfer learning uygulması kullanılır.

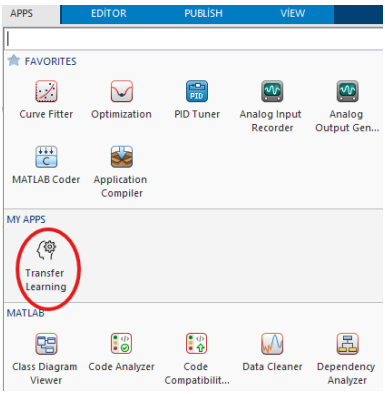

Şekil 14. Kullanılan uygulama

Transfer öğrenimi uygulamasında açılan pencere Şekil 3'te verilmiştir. Burada kırmızı ile gösterilen sınıflandırma işleminin seçimini yaparken, mavi renk ile gösterilen veri setinin içeri aktarılmasını ifade eder. Daha sonra önceden eğitilmiş ağların seçimi yapılır. Eğitim ve doğrulama % seçimleri gerçekleştirilir.

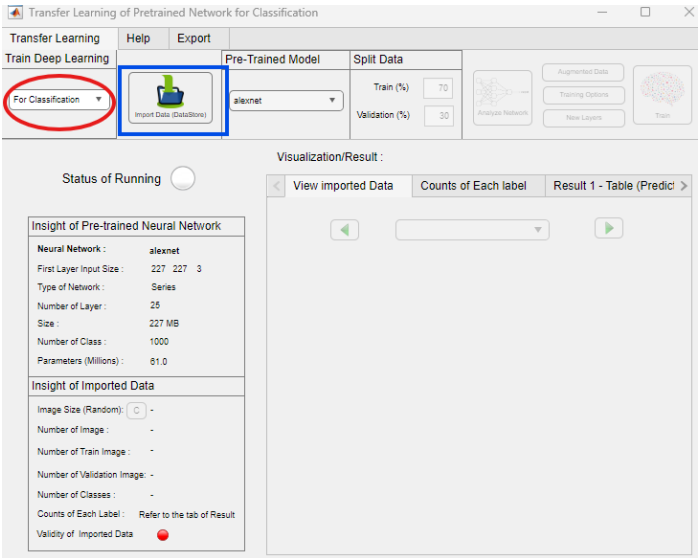

Şekil 15. Transfer öğrenme uygulaması

Ardından Şekil 4'te verilen Train seçeneği ile eğitim başlatılır. Eğitim sonucu export edilerek çalışma sayfasından gözlemlenir.

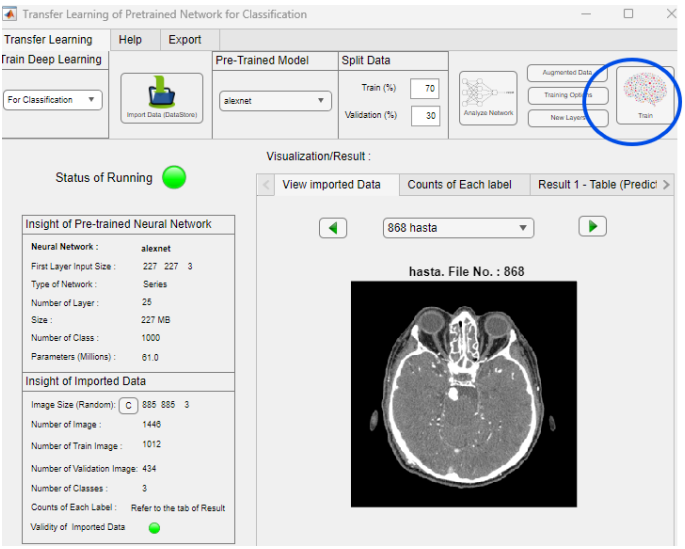

Şekil 16. Eğitimi başlatma

Ayrıca eğitim sürecine ait doğruluk grafiği Şekil 5'de verildiği gibi ekrana yansır. Eğitim doğruluğu % ifadesi kırmızı renkle gösterilen alanda verilir ve performans ölçümü olarak değerlendirilmesi gereken önemli bir kriterdir.

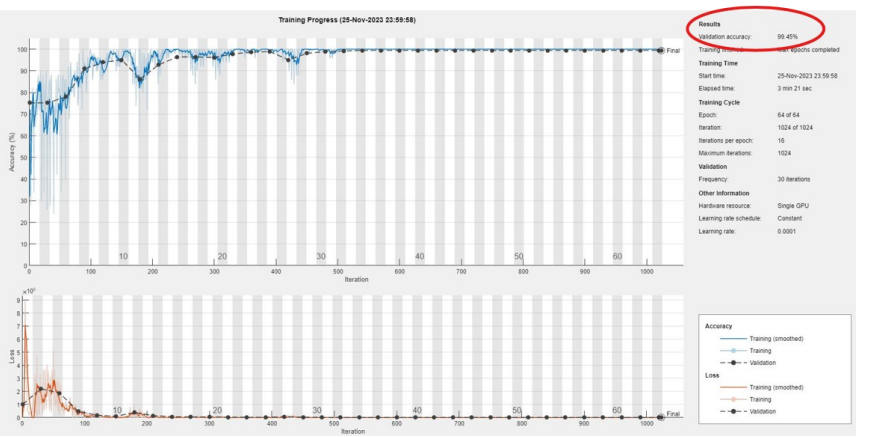

Şekil 17. Eğitim grafiği

Sınıflandırma Bulguları

Bilgi işleme teknolojisi olan yapay sinir ağları insan beyninin bilgileri işleme yeteneğinden geliştirilmiştir. Makine öğreniminin alt kümesi olan derin öğrenme ise, çok katmanlı sinir ağlarından oluşan veri biliminde önemli bir unsurdur. Derin öğrenme mimarilerinden biri olan CNN'de kullanılan beyin BTA görüntüleri farklı görüntü analizlerine sahip olmaktadır. Bu bağlamda 15 farklı CNN'de giriş görüntü tercihi olarak beyin BTA koronal görüntüleri kullanılır.

Derin öğrenme ağları arasında 15 adet CNN'e 200 hasta için ham ve filtreli görüntülerin beyin BTA görüntülerinden oluşan veri kümesi giriş katmanlarına uygulanır. Bu kümede görüntü boyutu 512x512x3 olan 1211 adet BTA görüntüsü ağların eğitiminde kullanılır. Görüntülerin %70'i eğitimde %30'u doğrulama işlemi için rastgele ayrılır. Eğitim seçenekleri olarak maksimum epochs sırasıyla 6, 32, 64, minimum batch size sırasıyla 10, 50, başlangıç öğrenme oranı 0,0001 ile SGDM optimizasyon kullanılarak gerçekleştirilir. Buna göre en yüksek doğruluk oranı Tablo 2'de verildiği üzere smoothing filtreli görüntülerin uygulandığı VGG19 evrişimli sinir ağı ile edilir.

Tablo 2. Farklı veri setlerine uygulanan CNN'lerin Doğruluk Değerleri

Uygulanan Ağlar	**Ham (%)**	**Canny (%)**	**Median (%)**	**Prewitt (%)**	**Smoothing (%)**	**Sobel (%)**
AlexNet	98.07	96.69	99.45	98.90	98.07	94.21
DenseNet201	97.52	92.29	98.35	98.90	98.62	95.04
GoogLeNet	92.84	84.3	86.5	91.18	98.62	89.26
InceptionResNetV2	88.15	84.3	83.2	97.80	96.97	81.82
Inceptionv3	94.4	92.56	90.63	96.42	96.42	85.67
MobileNetv2	92.84	90.08	89.26	97.52	99.17	86.78
NASNetMobile	87.05	84.02	82.64	92.01	93.11	91.46
ResNet18	94.77	94.49	92.56	96.69	97.80	91.46
ResNet50	96.69	95.32	96.14	99.17	98.07	94.21
ResNet101	95.59	92.84	98.35	98.35	95.59	97.25
ShuffleNet	92.84	91.74	95.04	97.80	99.17	84.85
SqueezeNet	87.33	85.12	87.05	93.39	90.91	88.15
VGG16	92.84	88.42	89.26	96.14	97.52	87.05
VGG19	90.08	93.66	84.85	98.90	**99.72**	91.18
Xception	88.71	83.20	77.96	90.08	88.98	80.72

Sonuç

Anevrizma hastalığı beyin kanaması riskine sebep olduğu için çok hızlı bir şekilde ve doğru tespit edilmesi gerekir. Gelişen teknoloji ile birlikte anevrizma tanısında BTA görüntüler kullanılarak derin öğrenme tabanlı teknolojiler uygulanmaktadır. Kullanılan BTA görüntüler serebral anevrizmalı ve anevrizmasız hasta görüntülerinden oluşmaktadır. Serebral anevrizmaların taranmasında bu görüntüleri sınıflandırmak için önceden eğitilmiş 15 farklı CNN ile derin öğrenme çalışması yapılır. Veri setinde 1211 adet ham ve filtreli beyin BTA görüntüsü ile CNN eğitimi gerçekleştirilir ve sonuçlar alınır. Derin sinir ağları arasında VGG19 %99,72 ile bilinen en yüksek doğruluk oranında sınıflandırma yapılır. Performans metrikleri değerlendirildiğinde; VGG19 ağında anevrizmanın tespit duyarlılığı %99,63 değerindedir. Bu ağ yapıları ile farklı hastalıkların taranması ve hızlı tanı konulmasında radyoloji uzmanlarına destek sağlayacağı öngörülür. Ayrıca farklı çalışma alanlarındaki görüntü verileri kullanılarak CNN ile sınıflandırma yüksek doğrulukla yapılabilir.

Kaynaklar

Alaskar, H., Alzhrani, N., Hussain, A., & Almarshed, F. (2019). *The Implementation of Pretrained AlexNet on PCG Classification* (pp. 784–794). https://doi.org/10.1007/978-3-030-26766-7_71

Alsharabi, N., Shahwar, T., Rehman, A. U., & Alharbi, Y. (2023). Implementing Magnetic Resonance Imaging Brain Disorder Classification via AlexNet–Quantum Learning. *Mathematics*, *11*(2), 376. https://doi.org/10.3390/math11020376

Fitch, F. B. (1944). Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, vol. 5 (1943), pp. 115–133. *Journal of Symbolic Logic*. https://doi.org/10.2307/2268029

Gu, F., Wu, X., Wu, W., Wang, Z., Yang, X., Chen, Z., Wang, Z., & Chen, G. (2022). Performance of deep learning in the detection of intracranial aneurysm: A systematic review and meta-analysis. *European Journal of Radiology*, *155*, 110457. https://doi.org/10.1016/j.ejrad.2022.110457

Gupta, K., & Bajaj, V. (2023). Deep learning models-based CT-scan image classification for automated screening of COVID-19. *Biomedical Signal Processing and Control*, *80*, 104268. https://doi.org/10.1016/j.bspc.2022.104268

Gurkan, C., Kozalioglu, S., & Palandoken, M. (2021). Real Time Mask Detection, Social Distance and Crowd Analysis using Convolutional Neural Networks and YOLO Architecture Designs. *Academic Perspective Procedia*, *4*(1), 195–204. https://doi.org/10.33793/acperpro.04.01.29

Lehnen, N. C., Haase, R., Schmeel, F. C., Vatter, H., Dorn, F., Radbruch, A., & Paech, D. (2022). Automated Detection of Cerebral Aneurysms on TOF-MRA Using a Deep Learning Approach: An External Validation Study. *American Journal of*

Neuroradiology, *43*(12), 1700–1705. https://doi.org/10.3174/ajnr.A7695

Mensah, E., Pringle, C., Roberts, G., Gurusinghe, N., Golash, A., & Alalade, A. F. (2022). Deep Learning in the Management of Intracranial Aneurysms and Cerebrovascular Diseases: A Review of the Current Literature. *World Neurosurgery*, *161*, 39–45. https://doi.org/10.1016/j.wneu.2022.02.006

Ou, C., Qian, Y., Chong, W., Hou, X., Zhang, M., Zhang, X., Si, W., & Duan, C. (2022). A deep learning–based automatic system for intracranial aneurysms diagnosis on three-dimensional digital subtraction angiographic images. *Medical Physics*. https://doi.org/10.1002/mp.15846

Özlüer Başer, B., Yangın, M., & Sarırdaş, E. S. (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. https://doi.org/10.19113/sdufenbed.842460

Rub, S. A. Al, Alaiad, A., Hmeidi, I., Quwaider, M., & Alzoubi, O. (2023). Hydrocephalus classification in brain computed tomography medical images using deep learning. *Simulation Modelling Practice and Theory*, *123*, 102705. https://doi.org/10.1016/j.simpat.2022.102705

Shanthi, T., & Sabeenian, R. S. (2019). Modified Alexnet architecture for classification of diabetic retinopathy images. *Computers & Electrical Engineering*, *76*, 56–64. https://doi.org/10.1016/j.compeleceng.2019.03.004

Shi, Z., Miao, C., Schoepf, U. J., Savage, R. H., Dargis, D. M., Pan, C., Chai, X., Li, X. L., Xia, S., Zhang, X., Gu, Y., Zhang, Y., Hu, B., Xu, W., Zhou, C., Luo, S., Wang, H., Mao, L., Liang, K., … Zhang, L. J. (2020). A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature Communications*. https://doi.org/10.1038/s41467-020-19527-w

Singh, S., Sharma, S., Jain, A., Singh, P., & Kudake, A. (2022). Transfer Learning: Convolutional Neural Network-AlexNet Achieving Face Recognition. *2022 2nd Asian Conference on Innovation in Technology (ASIANCON)*, 1–4. https://doi.org/10.1109/ASIANCON55314.2022.9908650

Tasci, B., & Tasci, I. (2022). Deep feature extraction based brain image classification model using preprocessed images: PDRNet. *Biomedical Signal Processing and Control*, *78*, 103948. https://doi.org/10.1016/j.bspc.2022.103948

Terasaki, Y., Yokota, H., Tashiro, K., Maejima, T., Takeuchi, T., Kurosawa, R., Yamauchi, S., Takada, A., Mukai, H., Ohira, K., Ota, J., Horikoshi, T., Mori, Y., Uno, T., & Suyari, H. (2022). Multidimensional Deep Learning Reduces False-Positives in the Automated Detection of Cerebral Aneurysms on Time-Of-Flight Magnetic Resonance Angiography: A Multi-Center Study. *Frontiers in Neurology*, *12*. https://doi.org/10.3389/fneur.2021.742126

Wang, J., Ti, L., Sun, X., Yang, R., Zhang, N., & Sun, K. (2022). DSA Image Analysis of Clinical Features and Nursing Care of Cerebral Aneurysm Patients Based on the Deep Learning Algorithm. *Scanning*, *2022*, 1–6. https://doi.org/10.1155/2022/8485651

Wei, X., Jiang, J., Cao, W., Yu, H., Deng, H., Chen, J., Bai, S., & Zhou, Z. (2022). Artificial intelligence assistance improves the accuracy and efficiency of intracranial aneurysm detection with CT angiography. *European Journal of Radiology*, *149*, 110169. https://doi.org/10.1016/j.ejrad.2022.110169

BÖLÜM III

Makine Öğrenme Uygulamaları

Meltem YAVUZ ÇELİKDEMİR[5]
Soner ÇELİKDEMİR[6]

Giriş

Bu kitap bölümü 3 alt başlıktan oluşmaktadır. Giriş bölümünde; amaç, kapsam, problemlerin tanımı, ortaya konulan çözüm önerileri ile birlikte literatür çalışması verilmiştir. İkinci bölümde makine öğrenme modelleri açıklanmıştır. Üçüncü bölümde ise hastalık sınıflandırması yapılmıştır.

Makine öğrenimi sınıflandırma işlemine başlamadan önce veri seti oluşturmak önemlidir. Veri seti tablo olarak excel dosyasında oluşturulur. Literatürde kullanılan hazır veri setleri mevcuttur fakat veri setinin içeriği güvenilir olmayabilir. Bu yüzden makine öğreniminde sınıflandırma yapmak isteyen bireyler öncelikle güvenilir kaynaktan elde ettikleri verileri tablo haline getirmelidirler. Daha sonra oluşturulan veri setinde eksik ifadeler

[5] Dr. Meltem Yavuz Çelikdemir, Bitlis Eren Üniversitesi, Tatvan MYO, Elektrik ve Otomasyon Bölümü, Bitlis/Türkiye, Orcid: 0000-0003-0552-2601, meltem.ycd@gmail.com
[6] Dr. Soner Çelikdemir, Bitlis Eren Üniversitesi, Adilcevaz MYO, Elektrik ve Otomasyon Bölümü, Bitlis/Türkiye, Orcid: 0000-0002-1419-3398, scelikdemir@gmail.com

kontrol edilmeli. Bazı durumlarda değişkenler kategorik ya da numerik değerlerden oluşabilir. Bu durumda Matlab 2023a'da verilen sınıflandırma teknikleri uygulandığı zaman doğruluk değerlendirmesinde değişkenler öenm arz eder.

Bu kitap bölümünde makine öğrenimi sınıflandırma algoritmalarının nasıl uygulanacağı açıklanmıştır.

Literatür Taraması

Hastalıkların tespitinde makine öğrenme yöntemleri ile ilgili biyomedikal veri kümelerinde, makine öğrenimi algoritmalarından 6 tanesi test edilerek başarımları ve istatistiksel sonuçları karşılaştırılmıştır. Çalışma zamanı açısından değerlendirildiğinde k-en yakın komşu algoritmasının başarılı olduğu vurgulanmıştır (Karakoyun & Hacıbeyoğlu, 2014). Yapılan çalışmada farklı çalışma koşullarında hemodinamik faktörlerin orta serebral arter anevrizmasının yırtılmasına olan etkisi araştırılmıştır. Ortalama duvar kayma gerilimi, basınç dağılımındaki hız ve kan viskozitesinin etkileri incelenmştir. Çalışma neticesinde ortalama duvar kayma geriliminin kan akış hızı ile orantılı arttığı ve 0,6'nın üzerine çıkması anevrizma rüptür riskini artırdığı gözlenmiştir. Ayrıca yapılan çalışma, kan hızındaki artışın anevrizmada kanama riskini artırdığını göstermiştir (Rostamian et al., 2023). Anevrizmaların varlığında orta serebral arter sık görülen bölge olup geniş boyunludurlar. Orta serebral arter anevrizmaları için anatomileri gereği kompleks yapıda olması, öncelikli tedavilerinin mikrocerrahi klipleme olması gerekliliği vurgulanmıştır (Koçak & Öztanır, 2012). Beyin anevrizmalarının otomatik tespitine dayalı çalışmada 284 hasta bilgisi içeren TOF-MRA görüntü verileri derin öğrenme modelinde çapraz doğrulama yapılarak eğitim gerçekleştirilmiştir. Anevrizmalı 157 ve anevrizmasız 127 görüntü veri setinde toplam 198 anevrizma ile 3B UNET öğrenimi yapılmıştır. Anevrizma lokasyonları ACA, MCA, ICA ve boyutları ≤7 mm, 7-9 mm, 10-19 mm ve ≥20 mm aralığında bulunan anevrizmalar ve hastanın yaş bilgisi de çalışmaya dahil edilmiştir. Eğitim ve değerlendirme, Tensorflow 2.4.0 ve 11 GB SDRAM'li GeForce RTX 2080TI GPU ile gerçekleştirilmiştir.

En iyi model için performans metrikleri hasta başına 0,8 yanlış pozitif oranı ve %83 hassasiyet elde etmiştir. Ayrıca anevrizmalar için PHASES skoru hesaplanarak risk grubu düşük, orta ve yüksek olmak üzere sınıflandırılmıştır. Düşük riskli anevrizmalar için izlem gerektirdiği, orta ve yüksek riskli olanlar için ise tedavi gerektirdiği kanısına varılmıştır. Anevrizma rüptüründe boyut ve konum bilgisinin duyarlılık açısından anlamlı bir etki yapmadığı gözlenmiştir (Di Noto et al., 2022). Çalışmada PHASES skoru hesaplaması için 230 hastaya ait prediktörler yaş, hipertansiyon, subaraknoid kanama öyküsü, anevrizma boyutu ve coğrafi bölge bilgisi değerlendirilmektedir. Buna göre Kuzey Amerika ve Finlandiya dışındaki Avrupa ülkelerinden gelen popülasyonlarla karşılaştırıldığında Finlandiyalılarda anevrizma yırtılması riski 3,6 kat, Japonlarda ise 2,8 kat daha fazla risk taşıdığı gözlenmiştir (Greving et al., 2014). Rüptür olmayan serebral anevrizmaların yaygınlığı değişkenlik göstermektedir. Bu bağlamda 35-75 yaş aralığında 4813 yetişkinde üç boyutlu Uçuş Zamanlı Manyetik Rezonans Anjiyografi (TOF-MRA) kullanılarak rüptür olmamış serebral anevrizmaların yaygınlığı değerlendirilmiştir. Çalışma kapsamında 4477 hastada herhangi bir rüptür olmayan serebral anevrizma belirtisi yok iken, 336 hastada 369 adet anevrizma tespit edilmiştir. Anevrizmalar %81 oranla ICA lokasyonunda, %90,2'si için maksimum çapları 5 mm'den küçük ve kadınlarda erkeklerden daha büyük olarak belirlenmiştir (Li et al., 2013). Rüptür olmamış intrakraniyal anevrizmaların yırtılması neticesinde ölüm oranı ve engelli olma durumu söz konusudur. Araştırmada rüptür olmayan bu anevrizmalarda yırtılma riskini tahmin etmek için yeni bir parametre sunulması amaçlanmıştır. Veri kümesinde birden fazla anevrizması mevcut 649 hasta için 964 anevrizma bulunmaktadır. Ortalama Arter Basıncı-Anevrizma Boynu Arasındaki Oran (MAPN) ile yeni bir parametre tanımlanmıştır. MAPN modelini oluşturmak için on iki anevrizma on temel klinik özelliği ve morfolojik özellikleri çıkarılmıştır. Model sonuçları PHASES ve UCAS skoru ile karşılaştırılmış ve eğri altında kalan alanın değerleri 0,799 0,763 ve 0,719 ile yüksek performans göstermiştir. Duyarlılıklar ise 0,849 0,758 ve 0,753 ile MAPN'nin anevrizma rüptür riskini

değerlendirmede klinik olarak karar verme sürecini artırdığı vurgulanmıştır (Shen et al., 2023). Rüptür olan intrakraniyal anevrizmaların çoğunluğunu küçük anevrizmaların oluşturduğunu ve rüptür riskine dahil olan faktörleri değerlendirmek için daha çok araştırmaya ihtiyaç duyulduğunu belirtmişlerdir (Mehkri et al., 2023). Anevrizmaların rüptür risk durumlarının belirlenmesinde PHASES, UCAS ve ELAPSS skorları hesaplanarak performansları karşılaştırılmıştır. Sonuçlara göre; ortalama PHASES, UCAS ve ELAPSS puanları sırasıyla 5,12 ± 3,08 5,09 ± 2,62 ve 15,88 ± 8,07 olarak bulunmuştur. Bu puan gözlemlerine dayanarak doktorların bu konuyu dikkate almaları düşünülmektedir (Sturiale et al., 2021). Bu çalışmada takip sırasında büyüme veya rüptür riski taşıyan anevrizmaları belirlemek için UIATS modelinin geçerliliğini değerlendirmiştir. Çalışmaya rüptür olmayan 277 anevrizmalı 214 hasta dahil edilmiş ve ortalama 1 yıl 4 ay takibi gerçekleştirilmiştir. UIATS modeli %80 duyarlılık ve %44 özgüllük göstermiştir. Bu sonuçlar UIATS modelinin takip sırasında anevrizma büyümesini veya rüptürü tahmin etme performansının düşük olduğunu göstermiştir (Molenberg et al., 2021). Rüptür olmamış intrakraniyal anevrizmaların rüptür riskini hesaplamada ISUIA, UCAS ve PHASES skoru kullanılmıştır. Sakküler anevrizma kaynaklı rüptür olan 246 hasta çalışmaya dahil edilmiştir. Bir yıllık rüptür riskini belirlemek için kullanılan skorlar her hastaya ve anevrizmaya uygulanmıştır. Anevrizmaların ortalama çapı 5,5 ± 3,1 mm olarak bulunmuştur. En sık rüptür olan anevrizma yerinin ACom olduğu belirtilmiştir. Sonuç olarak bir yıllık yırtılma riskleri ISUIA, UCAS ve PHASES için sırasıyla %0,46 %0,93 ve %0,32 olarak hesaplanmıştır. En yüksek riskli bölgenin vertebral arter ve süperior serebellar arter olduğu belirtilmiştir (Webb et al., 2022).

Makine Öğrenme

Makine öğrenme, insanlara doğal gelen şeyleri bilgisayarlara yaptırma işi olarak ifade edilir (*MATLAB for Machine Learning*, n.d.). Makine öğrenmede denetimli ve denetimsiz öğrenme olmak üzere iki teknik kullanılır. Denetimli öğrenmede veri seti; eğitim ve test seti olmak üzere ikiye ayrılır. Eğitim setinden program öğrenilir

ve bir algoritma geliştirilir. Daha sonra test seti kullanılarak algoritmanın doğruluğu değerlendirilir. Algoritmanın amacı yeni verilerin sonucunu tahmin edebilmek için geliştirilen algoritmayı kullanmaktır (Ley et al., 2022). Denetimsiz öğrenme ise tahmin edilecek herhangi bir doğruluk verisinin yardımı olmaksızın veri setindeki istenen gizli yapıyı bulmayı amaçlar (Parlett-Pelleriti et al., 2022). Makine öğrenmede genel yapı Şekil 1'de verilmiştir.

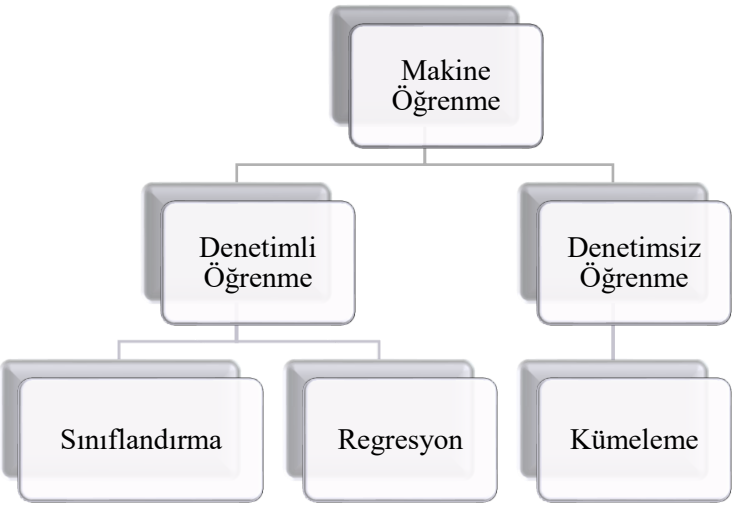

Şekil 18. Makine öğrenme teknikleri

Denetimli öğrenmede tahmini modeller geliştirmek için regresyon ve sınıflandırma teknikleri olmak üzere iki tür teknik kullanılır. Regresyon modeli, bir ya da daha fazla giriş değişkeni ile bir çıktı değişkeni arasında ilişkiyi tanımlar. Sınıflandırma ise, bir algoritmanın etiketli veri örneklerinden yeni gözlemleri sınıflandırmayı öğrendiği denetimli makine öğrenmedir.

Sınıflandırma Algoritmaları

Sınıflandırma algoritmaları girdi verilerini kategorilere ayırarak sınıflandırır. Bu yüzden doğru algoritma seçimi önemlidir. Algoritma seçiminde işlem süresi uzundur. Ayrıca her bir algoritma için öğrenme yöntemi farklıdır. Her sınıflandırmaya uyum sağlayan

tek bir algoritma türü yoktur. Algoritma deneme yanılma yöntemi ile doğruluğu en yüksek olanı tercih ederek seçimi gerçekleştirilir. Seçilen algoritma uygulandığında uygun işi yapmadığı düşünülüyorsa farklı sınıflandırma algoritmaları denenebilir. Matlab R2023a'da mevcut olan sınıflandırıcılar uygulamasında kullanılan algoritmaları aşağıdaki gibi sıralanabilir.

- Karar ağaçları,
- Destek vektör makineleri,
- Topluluk öğrenme,
- Lojistik regresyon,
- Naive bayes,
- Sinir ağı,
- Diskriminant analiz,
- En yakın komşu
- Çekirdek yaklaşımı
- Verimli eğitimli doğrusal

Matlab 2023a'da bulunan uygulamalar arasında makine öğrenme ve derin öğrenme uygulamalarının arasında bulunan sınıflandırma öğrenici uygulaması Şekil 2'de kırmızı renk ile gösterilmiştir.

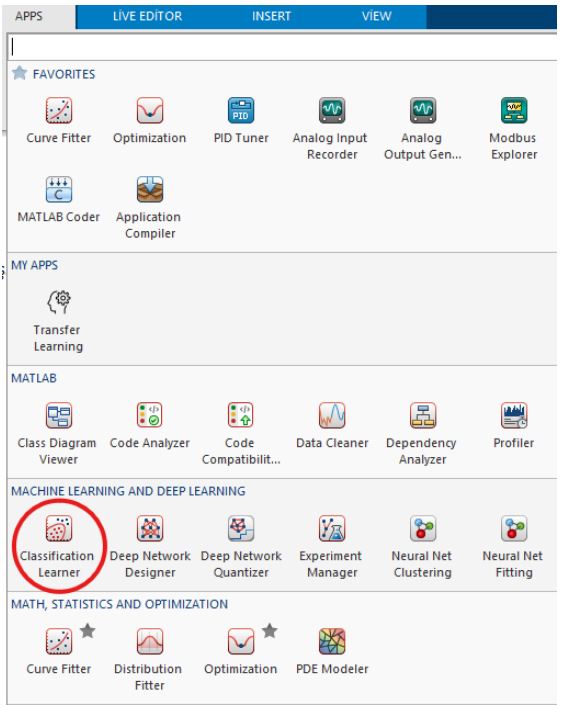

Şekil 19. Sınıflandırma uygulaması seçimi

Bu uygulama açıldıktan sonra çalışma alanında bulunan bir excel veri dosyası ya da kayıtlı herhangi bir dosyada bulunan veriler Şekil 3'te gösterildiği gibi seçim gerçekleştirilir.

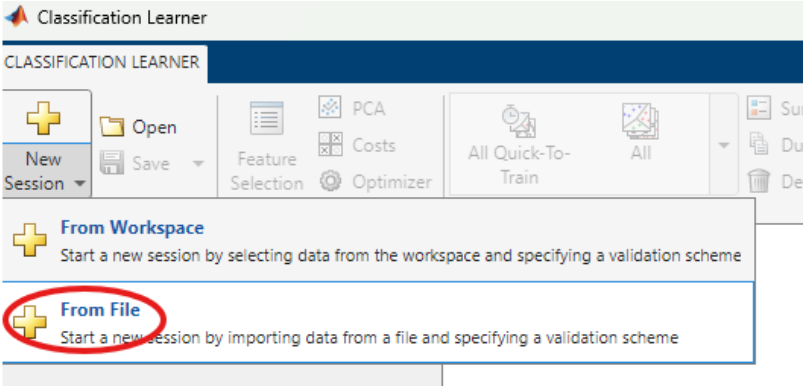

Şekil 20. Veri seçimi

Bu işlemden sonra açılan pencere Şekil 4'te verilmiştir. Excel dosyası birden fazla sayfa içerebilir. Hangi sayfadaki verileri eğitilecek ve sınıflandırılacak ise o sayfanın verileri içeriye aktarılır.

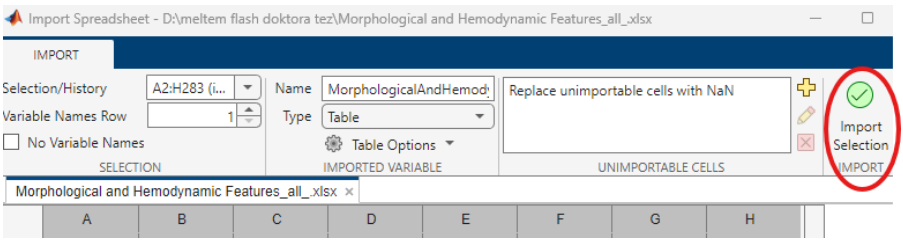

Şekil 21. Dosya verilerini içeri aktarma

Çapraz Doğrulama

Modelin değerlendirilmesinde önemli olan bir diğer parametre aşırı ya da eksik öğrenmeyi belirleyen çapraz doğrulama yöntemidir. En iyi performans gösteren model oluşturmaya dayalı olan çapraz doğrulama, eğitmek için kullanılmamış test veri setini kullanarak hatayı hesaplar. En yaygın kullanılan çapraz doğrulama teknikleri şunlardır:

- k-katlamalı
- Uzatma

- Ayrılma
- Tekrarlanan rastgele alt örnekleme
- Tabakalandırma
- Yeniden ikame

En çok tercih edilen çapraz doğrulama yöntemi k-katlamalıdır. Çalışmada da kullandığımız bu yöntem sayesinde veriler eşit boyutta rastgele seçilmiş k alt kümeye ayrılır. Bu alt kümeler kullanılarak eğitilen modeli doğrulamak için bir alt küme kullanılır. Her bir alt küme doğrulama için gerçekleşen bu işlem k kez tekrarlanır (*Cross-Validation*, n.d.).

Açılan yeni pencerede Şekil 5'te verildiği gibi çıkış seçimi 1 numarada gösterildiği gibi veri seti değişkenlerinden seçilir. Daha sonra 2 numarada belirtilen çapraz doğrulamanın kaç alt kümede gerçekleşeceği seçilir. Ardından 3 numarada verilen dahili test işlemine dahil veri setinin % ifadesi yazılır. Buna göre veri setinin %10'u test edilecektir. Son olarak 4 numarada başlatma komutu verilir.

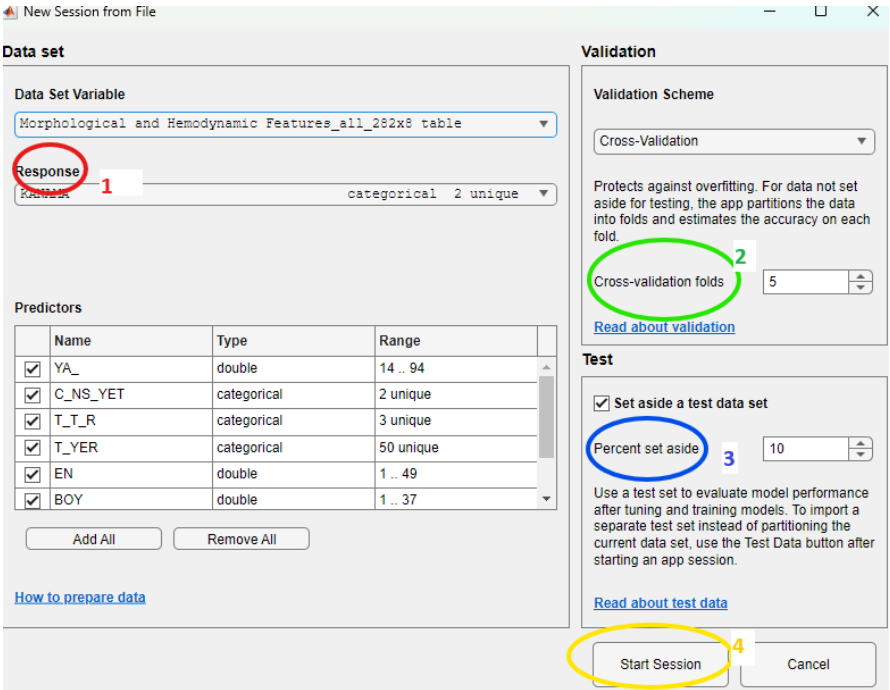

Şekil 22. Eğitim ve test işlemleri uygulaması

Bu işlemler neticesinde modellerin eğitimlerinin yapılması için Şekil 6'da kırmızı renk ile gösterilen işaret sekmesine basıldığında hangi model eğitimlerinin yapılacağı pencere açılır. Burada yeşil renk ile ifade edilen tüm modeller için seçimin yapılacağını gösterir. Bu aşamadan sonra mavi karede belirtilen eğitim sekmesi ile tüm modellerde eğitim başlatılır. Eğitim sonuçlarına ait doğruluk değerleri modeller başlığı altında verilir. En yüksek doğruluk değerine sahip algoritma modeli seçilir ve sarı karede gösterilen dışarıya aktarma işlemi ile çalışma alanına aktarılır. Harici test işlemi yapmak için aşağıdaki komutlar kullanılır.

```
>>testdata=readtable("testseti2.xlsx");
>>predictFcn = @(x) extractPredictorsFromTableFcn(testdata);
>>yfit = trainedModel.predictFcn(testdata)
```

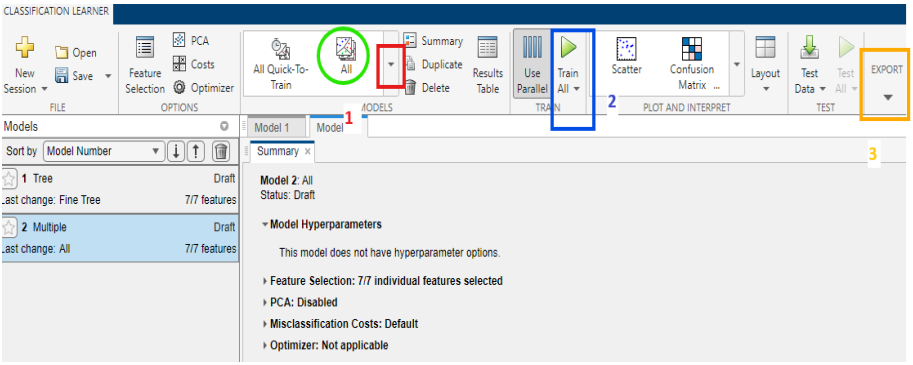

Şekil 23. Sınıflandırma işlem basamakları

Eğri Altında Kalan Alan (AUC)

Sınıflandırma modellerinde sınıfları ayırt etme başarısını göstermektedir. AUC, Alıcı İşletim Karakteristiği (ROC) eğrisi altında kalan alanı ifade eder. ROC eğrisi (0,0) ile (1,1) arasında artan fonksiyon olup AUC değeri ne kadar yüksek olursa modelin de sınıflandırma başarısının o kadar arttığını gösterir. AUC değeri için "0,5" olma durumu modelin başarısız olduğunu gösterirken, en büyük olan "1" değerini alması maksimum başarıyı ifade eder.

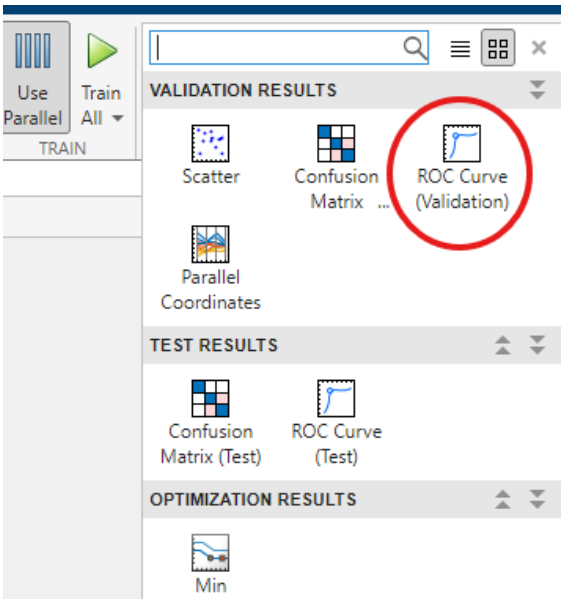

Şekil 24. ROC eğrisi çizimi

Modellerde gerçek pozitif oranı ve yanlış pozitif oranı arasındaki ilişkiyi Şekil 7'de kırmızı renk ile gösterildiği gibi seçimi yapılarak ROC eğrileri çizdirilir. Model başarısı eğri grafiğine yorumlanabilir.

Sonuç

Bu bölümde makine öğrenmede sınıflandırma algoritmalarının kullanımı açıklanmıştır. Sınıflandırma işlemi yapılmadan önce veri setinin nasıl oluşturulacağı hakkında bilgiler verilmiştir. Medikal kayıtlar içeren uygulamada kullanılan veri setine, anevrizmalarda oluşan kanama durumlarının incelenmesi için hastalara ait bilgiler dahil edilmiştir. Makine öğrenme sınıflandırma algoritmaları ile kanama oluşma ihtimalleri değerlendirilmiştir. Bu bölüm kategorik ve nümerik değişkenler içeren giriş ve çıkış değişkenleri belirlenmiş veri setleri kullanılarak makine öğrenme ile sınıflandırma işlemi yapılmasına olanak tanımaktadır. Matlab 2023a programında işlem yapacak kullanıcılar ve araştırmacılar için destekleyici ve yol gösterici nitelik taşımaktadır.

Kaynaklar

Cross-Validation. (n.d.). Retrieved April 4, 2023, from https://www.mathworks.com/discovery/cross-validation.html?s_tid=srchtitle_cross validation_1

Di Noto, T., Marie, G., Tourbier, S., Alemán-Gómez, Y., Esteban, O., Saliou, G., Cuadra, M. B., Hagmann, P., & Richiardi, J. (2022). Towards Automated Brain Aneurysm Detection in TOF-MRA: Open Data, Weak Labels, and Anatomical Knowledge. *Neuroinformatics*. https://doi.org/10.1007/s12021-022-09597-0

Greving, J. P., Wermer, M. J. H., Brown, R. D., Morita, A., Juvela, S., Yonekura, M., Ishibashi, T., Torner, J. C., Nakayama, T., Rinkel, G. J. E., & Algra, A. (2014). Development of the PHASES score for prediction of risk of rupture of intracranial aneurysms: a pooled analysis of six prospective cohort studies. *The Lancet Neurology*, *13*(1), 59–66. https://doi.org/10.1016/S1474-4422(13)70263-1

Karakoyun, M., & Hacıbeyoğlu, M. (2014). Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*.

Koçak, A., & Öztanır, M. N. (2012). Middle Cerebral Artery Aneurysms. *Türk Nöroşirürji Dergisi*, *22*(3), 206–211.

Ley, C., Martin, R. K., Pareek, A., Groll, A., Seil, R., & Tischer, T. (2022). Machine learning and conventional statistics: making sense of the differences. *Knee Surgery, Sports Traumatology, Arthroscopy*, *30*(3), 753–757. https://doi.org/10.1007/s00167-022-06896-6

Li, M. H., Chen, S. W., Li, Y. D., Chen, Y. C., Cheng, Y. S., Hu, D. J., Tan, H. Q., Wu, Q., Wang, W., Sun, Z. K., Wei, X. E., Zhang, J. Y., Qiao, R. H., Zong, W. H., Zhang, Y., Lou, W., Chen, Z. Y., Zhu, Y., Peng, D. R., … Jia, W. P. (2013). Prevalence of unruptured cerebral aneurysms in Chinese adults aged 35 to 75

years: A cross-sectional study. *Annals of Internal Medicine*. https://doi.org/10.7326/0003-4819-159-8-201310150-00004

MATLAB for Machine Learning. (n.d.). https://www.mathworks.com/solutions/machine-learning.html?s_tid=srchtitle_site_search_1_machine learning

Mehkri, Y., Reilly, T., Sharaf, R., & Shalom, M. (2023). Letter to the editor regarding "The majority of ruptured aneurysms are small with low rupture risk scores." *Journal of Clinical Neuroscience*, *107*, 192. https://doi.org/10.1016/j.jocn.2022.09.008

Molenberg, R., Aalbers, M. W., Mazuri, A., Luijckx, G. J., Metzemaekers, J. D. M., Groen, R. J. M., Uyttenboogaart, M., & van Dijk, J. M. C. (2021). The Unruptured Intracranial Aneurysm Treatment Score as a predictor of aneurysm growth or rupture. *European Journal of Neurology*, *28*(3), 837–843. https://doi.org/10.1111/ene.14636

Parlett-Pelleriti, C. M., Stevens, E., Dixon, D., & Linstead, E. J. (2022). Applications of Unsupervised Machine Learning in Autism Spectrum Disorder Research: a Review. *Review Journal of Autism and Developmental Disorders*. https://doi.org/10.1007/s40489-021-00299-y

Rostamian, A., Fallah, K., Rostamiyan, Y., & Alinejad, J. (2023). Application of computational fluid dynamics for detection of high risk region in middle cerebral artery (MCA) aneurysm. *International Journal of Modern Physics C*, *34*(02). https://doi.org/10.1142/S0129183123500195

Shen, J., Huang, K., Zhu, Y., Weng, Y., Xiao, F., Mungur, R., Wu, F., Pan, J., & Zhan, R. (2023). Mean arterial pressure-aneurysm neck ratio predicts the rupture risk of intracranial aneurysm by reflecting pressure at the dome. *Frontiers in Aging Neuroscience*, *15*. https://doi.org/10.3389/fnagi.2023.1082800

Sturiale, C. L., Stumpo, V., Ricciardi, L., Trevisi, G., Valente, I., D'Arrigo, S., Latour, K., Barbone, P., & Albanese, A. (2021). Retrospective application of risk scores to ruptured intracranial

aneurysms: would they have predicted the risk of bleeding? *Neurosurgical Review*, *44*(3), 1655–1663. https://doi.org/10.1007/s10143-020-01352-w

Webb, M., Fischer, V., Farrell, R., Towne, J., Birnbaum, L., Rodriguez, P., & Mascitelli, J. (2022). The majority of ruptured aneurysms are small with low rupture risk scores. *Journal of Clinical Neuroscience*, *103*, 148–152. https://doi.org/10.1016/j.jocn.2022.06.015

RFP
5cm
R
TP 0
SP H16.5 TR 6300.0
SL 5.0 TE 124.0
FoV 199*220 TA 04:24
256*512a M
>Cor(6.1)>Sag(1.5)
W 1288 A3/SAT1
C 667 *tse2d1_23 / 180
AF
1170
4VA12B 28/08/63
HFS
+LPH STUDY 1
09/11/01
16:41:56
2 IMA 18
RFP
5cm
R
TP 0
SP H44.5 TR 6300.0
SL 5.0 TE 124.0
FoV 199*220 TA 04:24
256*512a M
Tra>Cor(6.1)>Sag(1.5)
A3/SAT1
RFP
5cm
R
TP 0
SP H51.5 TR 6300.0
SL 5.0 TE 124.0
FoV 199*220 TA 04:24
256*512a M
Tra>Cor(6.1)>Sag(1.5)
A3/SAT1
23 / 180

BIDGE