

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

TOMOGRAFİDE TEMEL BEYİN TANILARININ OTOMATİK TESPİTİ



YÜKSEK LİSANS TEZİ

Serdar KÜPLÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

Temmuz 2017

BURSA TEKNİK ÜNİVERSİTESİ ❖ FEN BİLİMLERİ ENSTİTÜSÜ

TOMOGRAFİDE TEMEL BEYİN TANILARININ OTOMATİK TESPİTİ

YÜKSEK LİSANS TEZİ

**Serdar KÜPLÜ
161082324**

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı

Tez Danışmanı: Yrd. Doç. Dr. Cemal HANILÇI

Temmuz 2017

BTÜ, Fen Bilimleri Enstitüsü'nün 161082324 numaralı Yüksek Lisans Öğrencisi Serdar KÜPLÜ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "TOMOGRAFİDE TEMEL BEYİN TANILARININ OTOMATİK TESPİTİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Yrd. Doç. Dr. Cemal HANILÇI**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Yrd. Doç. Dr. M. Barış TABAKÇIOĞLU**
Bursa Teknik Üniversitesi

Doç. Dr. Fahri VATANSEVER
Uludağ Üniversitesi

Savunma Tarihi :

FBE Müdürü : **Doç. Dr. Murat ERTAŞ**
Bursa Teknik Üniversitesi/...../.....

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı : Serdar KÜPLÜ

İmzası :

X X X X



Çok değerli aileme,

ÖNSÖZ

Hayatım boyunca bana destek olan annem ve babama, her zaman yanımda ve yardımcım olan dayıma, bu tezin hazırlanmasında büyük desteği olan ve tez boyunca beraber çalıştığımız değerli hocam Yrd. Doç. Dr. Cemal HANİLÇİ'ye, çalışma süresince tıbbi tarafta bilgi ve desteklerini esirgemeyen Dr. Ramazan YALÇIN'a ve Vefa ORUÇ'a, bu süreçte bana moral desteği veren müstakbel eşime teşekkürü bir borç bilirim.

Temmuz 2017

Serdar KÜPLÜ

İÇİNDEKİLER

Sayfa

| | |
|--|-----------|
| ÖNSÖZ | v |
| İÇİNDEKİLER | vi |
| KISALTMALAR | viii |
| SEMBOLLER | ix |
| ÇİZELGE LİSTESİ..... | x |
| ŞEKİL LİSTESİ..... | xi |
| ÖZET | xii |
| SUMMARY | xiii |
| 1. GİRİŞ | 1 |
| 1.1 Tezin Amacı | 2 |
| 1.2 Literatür Araştırması | 3 |
| 1.2.1 Görüntü işleme kullanan otomatik tanı sistemleri | 3 |
| 1.2.2 Akciğerlerin bilgisayarlı tomografi görüntüsü otomatik segmentasyonu... 3 | 3 |
| 1.2.3 Bilgisayarlı beyin tomografi taramasında bilgisayar destekli tanı | 4 |
| 1.2.4 Tümörlerin wavelet tabanlı doku özellikleri ile otomatik tanılanması | 5 |
| 1.2.5 Romatoid artrit optik tomografi ile bilgisayar destekli tanısı | 5 |
| 1.2.6 Bilgisayarlı beyin tomografide inme hasarının otomatik nicemlemesi | 7 |
| 1.2.7 BT görüntülerinde otomatik kanama segmentasyonu ve sınıflandırılması | 8 |
| 1.2.8 Dokusal analiz yöntemiyle hemorajik inme algılama ve segmentasyon .. | 10 |
| 1.2.9 Yapay sinir ağı kullanarak beyin kanamasının tanısı konusunda çalışma | 11 |
| 1.2.10 Hemoraji içeren bölgenin bilgisayar destekli saptama sistemi | 11 |
| 1.2.11 Dokusal analiz yöntemiyle iskemik inme algılama ve segmentasyon | 12 |
| 1.2.12 Genetik algoritma kullanarak beyin tümörü segmentasyonu..... | 13 |
| 1.2.13 Beyin tümörü segmentasyonu için çerçeve tespiti | 14 |
| 1.2.14 Akıllı akut beyin kanaması teşhis sistemi | 15 |
| 1.2.15 Beyin kanamalarının otomatik algılanması ve sınıflandırılması..... | 15 |
| 1.2.16 Çok katmanlı perceptron ile beyin stroke sınıflama | 17 |
| 1.2.17 Beyin kanamasının CAD sistemleri ile tanısı ve sınıflandırılması | 18 |
| 1.2.18 Sinir ağı yaklaşımı ile otomatik görüntü sınıflaması | 19 |
| 1.2.19 Sinir ağı tabanlı yöntemlerle beyin tümörü sınıflandırma | 20 |
| 1.3 Hipotez | 21 |
| 2. MATERYAL VE YÖNTEM..... | 22 |
| 2.1 Bilgisayarlı Tomografi | 22 |
| 2.1.1 Bilgisayarlı tomografların genel yapısı..... | 23 |
| 2.1.2 Bilgisayarlı tomografinin tıbbi uygulamaları..... | 25 |
| 2.1.3 Görüntü oluşturma | 27 |
| 2.2 Beyin Kanaması | 29 |
| 2.2.1 İntraserebral kanama | 31 |
| 2.2.2 İntraventricüler kanama | 31 |
| 2.2.3 Epidural kanama | 31 |

| | |
|---|-----------|
| 2.2.4 Subdural kanama | 31 |
| 2.2.5 Subaraknoid Kanama | 31 |
| 2.3 İnme ve Beyin Enfarktüsü | 32 |
| 2.4 Görüntü İyileştirme Yöntemleri | 33 |
| 2.4.1 Median filtreleme | 34 |
| 2.4.2 Ortalama filtreleme | 35 |
| 2.4.3 Dönüşümler | 36 |
| 2.4.3.1 Logaritmik dönüşüm | 38 |
| 2.4.3.2 Power law dönüşüm | 38 |
| 2.4.4 Histogram eşitleme | 40 |
| 2.4.5 Kontrast iyileştirme | 41 |
| 2.4.6 Gamma düzeltme | 42 |
| 2.5 Yerel İkili Örüntü | 44 |
| 2.5.1 Temel yerel ikili örüntü | 44 |
| 2.5.2 Genel LBP operatörünün türetilmesi | 45 |
| 2.5.3 LBP etiketlerinin eşlemeleri: uniform örüntüler | 46 |
| 2.5.4 Çok ölçekli LBP | 49 |
| 2.5.5 Merkezi simetrik LBP | 49 |
| 2.6 Destek Vektör Makineleri | 51 |
| 2.6.1 Mükemmel eğitim görmüş SVM'lerin genelleştirilmesi yeteneği | 53 |
| 2.6.2 Girişleri diğer boyutlara eşleme - çekirdeklerin kullanımı | 53 |
| 2.6.3 SVM'lerin uygulanması | 55 |
| 3. BULGULAR VE TARTIŞMA | 56 |
| 3.1 LBP Parametre Optimizasyonu | 57 |
| 3.2 Görüntü İyileştirme Yöntemleri Parametre Optimizasyonu | 58 |
| 3.2.1 Gamma düzeltme yöntemi için gamma seçimi | 59 |
| 3.2.2 Power-law dönüşüm yöntemi için kuvvet seçimi | 60 |
| 3.3 Görüntü İyileştirme Yöntemleri Uygulama Sonuçları | 61 |
| 4. SONUÇLAR | 65 |
| KAYNAKLAR | 67 |
| ÖZGEÇMİŞ | 73 |

KISALTMALAR

| | |
|----------------|--|
| ACR | : Amerikan Radyoloji Koleji |
| ASPECTS | : Alberta İnme Programı Erken BT Puanlaması |
| AUC | : Alıcı İşlev Karakteristiği Eğrisi Altında Kalan Alan |
| BPN | : Geriye Yayılımlı Sinir Ağı Sınıflandırıcısı |
| BT | : Bilgisayarlı Tomografi |
| CAD | : Bilgisayar Destekli Tasarım |
| CE | : Conformance European (Avrupa Normlarına Uygunluk) |
| CS-LBP | : Merkezi-Simetrik Yerel İkili Örüntüler |
| DOT | : Diffüz Optik Tomografi |
| DWT | : Ayrık Dalgacık Dönüşümü |
| EDH | : Epidural Kanama |
| GA | : Genetik Algoritma |
| GD | : Gamma Düzeltme |
| GLCM | : Gri Düzeyli Eşdizliliklilik Matrisi |
| HE | : Histogram Eşitleme |
| HTN | : Hipertansif Kanama |
| ICH | : İntraserebral Kanama |
| IVH | : İntraventricüler Kanama |
| Kİ | : Kontrast İyileştirme |
| KNN | : K-En Yakın Komşuluk |
| LBP | : Yerel İkili Örüntü |
| MF | : Medyan Filtreleme |
| MLP | : Çok Katmanlı Perceptron |
| MR | : Manyetik Rezonans |
| MRG | : Manyetik Rezonans Görüntüleme |
| NN | : Sinir Ağı |
| OF | : Ortalama Filtreleme |
| PCA | : İlke Bileşeni Analizi |
| PD | : Power-Law Dönüşümü |
| PIP | : Proksimal Interfalangeal Eklem |
| PNN-RBF | : Olasılıksal Sinir Ağı-Radyal Tabanlı Fonksiyon |
| RA | : Romatoid Artrit |
| RBF | : Radyal Tabanlı Fonksiyon |
| ROC | : Alıcı İşlev Karakteristiği |
| ROI | : İlgi Alanı |
| SAH | : Subaraknoid Kanama |
| SDH | : Subdural Kanama |
| SFCM | : Uzaysal Bulanık C-Ortalama |
| SGLDM | : Uzaysal Gri Seviye Bağımlılığı Yöntemi |
| SVM | : Destek Vektör Makineleri |
| USG | : Ultrasonografi |

SEMBOLLER

| | |
|---|---------------------------------------|
| F | : Kontrast Düzeltme Faktörü |
| K(x_a,x_b) | : Kernel Fonksiyonu |
| kV | : Kilovolt |
| p_r(r), p_s(s) | : Olasılık Yoğunluk Fonksiyonları |
| γ | : Düzeltme Katsayısı |
| μ | : Hacimsel Eleman Zayıflama Katsayısı |
| Π | : Örnek Dışı Hata |



ÇİZELGE LİSTESİ

| | <u>Sayfa</u> |
|---|---------------------|
| Çizelge 3.1 : LBP komşuluk sayısı seçimine göre test sonuçları. | 57 |
| Çizelge 3.2 : LBP yarıçap seçimine göre test sonuçları. | 58 |
| Çizelge 3.3 : Seçilen gamma değerleriyle yapılan gamma düzeltme işlemi sonucu elde edilen test sonuçları. | 59 |
| Çizelge 3.4 : Seçilen kuvvet (n) değerleriyle yapılan power-law dönüşüm işlemi sonucu elde edilen test sonuçları. | 60 |
| Çizelge 3.5 : Sadece bir görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları. | 62 |
| Çizelge 3.6 : Aynı anda iki farklı görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları. | 63 |
| Çizelge 3.7 : Aynı anda üç farklı görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları. | 64 |

ŞEKİL LİSTESİ

Sayfa

| | |
|--|----|
| Şekil 1.1 : Tomografi tanı süreci. | 1 |
| Şekil 1.2 : Normal beyin ile birlikte bu çalışmada baz alınan sırasıyla subdural, intraparakimal ve epidural kanamalar. | 16 |
| Şekil 1.3 : Çalışmanın blok diyagramı. | 20 |
| Şekil 2.1 : Siretom beyin tarayıcısı, 1974. | 22 |
| Şekil 2.2 : 512x512'lik beyin tomografi görüntüsü. | 23 |
| Şekil 2.3 : Tarama sonucu elde edilen dataların işlenmesi. | 24 |
| Şekil 2.4 : Bilgisayarın BT görüntüleme sistemindeki yeri. | 25 |
| Şekil 2.5 : BT bel vertebra görüntüsü. | 26 |
| Şekil 2.6 : BT anjio görüntüsü. | 27 |
| Şekil 2.7 : Hacimsel eleman boyutunun bağlı olduğu parametreler. | 28 |
| Şekil 2.8 : Hacimsel eleman zayıflama katsayısı μ ile piksel (BT numarası) arasındaki ilişki. | 29 |
| Şekil 2.9 : Beyin kanamasına ait örnek BT görüntüsü. | 30 |
| Şekil 2.10 : Beyin enfarktüsüne ait örnek BT görüntüsü. | 33 |
| Şekil 2.11 : Median filtreleme örnek hesaplama. | 34 |
| Şekil 2.12 : Sırasıyla filtresiz ve median filtreli BT görüntüsü. | 35 |
| Şekil 2.13 : Ortalama filtreleme örnek hesaplama. | 35 |
| Şekil 2.14 : Tek boyutlu sinyalin median ve ortalama filtreleme sonuçları. | 36 |
| Şekil 2.15 : Sırasıyla filtresiz ve ortalama filtreli BT görüntüsü. | 36 |
| Şekil 2.16 : Gri seviye dönüşümleri. | 37 |
| Şekil 2.17 : Farklı γ değerleri için power law dönüşümleri. | 39 |
| Şekil 2.18 : Sırasıyla dönüşümsüz ve $\gamma = 0,5$ power law dönüşümlü BT görüntüsü. | 40 |
| Şekil 2.19 : Histogram eşitleme öncesi ve sonrası olasılık yoğunluk fonksiyonları. | 41 |
| Şekil 2.20 : Histogram eşitleme öncesi ve sonrası BT görüntüsü. | 41 |
| Şekil 2.21 : Kontrast iyileştirme öncesi ve sonrası BT görüntüsü. | 42 |
| Şekil 2.22 : Farklı γ değerleri için gamma düzeltmeleri. | 43 |
| Şekil 2.23 : Gamma düzeltme ($\gamma = 0,3$) öncesi ve sonrası BT görüntüsü. | 44 |
| Şekil 2.24 : Örnek bir giriş görüntünün LBP görüntüsü ve histogramı. | 45 |
| Şekil 2.25 : (8,R) komşuluk için 58 farklı uniform örüntü. | 47 |
| Şekil 2.26 : LBP tarafından tespit edilen farklı doku kökleri. | 48 |
| Şekil 2.27 : Üç bitişik LBP4,R komşuluk ve imkansız bir kod kombinasyonu. | 49 |
| Şekil 2.28 : 8 piksel komşuluk için LBP ve CS-LBP özellikleri. | 50 |
| Şekil 2.29 : Marjı maksimize eden hiper düzlemin seçilmesi. | 52 |
| Şekil 2.30 : Veriyi özellik uzayında ayırma [67]. | 54 |
| Şekil 3.1 : Otomatik tanı sisteminin genel yapısı. | 56 |
| Şekil 3.2 : Kanama ve enfarkt tespit başarı oranlarının gamma değerine bağlı değişimi. | 59 |
| Şekil 3.3 : Kanama ve enfarkt tespit başarı oranlarının kuvvet (n) değerine bağlı değişimi. | 61 |

TOMOGRAFİDE TEMEL BEYİN TANILARININ OTOMATİK TESPİTİ

ÖZET

Bilgisayarlı tomografi (BT) sağlık kuruluşlarının görüntüleme bölümlerinde manyetik rezonans (MR) ile beraber en sık kullanılan kesitsel tanı ünitesidir. Tomografi ve MR cihazlarının şüphe edilen hastalık türüne göre tanı koymada birbirlerine göre üstünlükleri mevcuttur. Bu nedenle hekimler tanılama için cihaz seçimlerini ön bulgulara göre yapmaktadır. Tomografi cihazının özellikle kanama durumlarında ve kemik kırıklarında üstünlüğü mevcuttur. Buna bağlı olarak acil servis hizmetlerde tomografi ünitesi MR ünitesine göre daha yoğun kullanılmaktadır. Tanı süreci; hastanın ilgili üniteye yönlendirilmesi ile başlar, sonrasında ilgili ünite radyoloji teknikerleri tarafından çekim gerçekleştirilir. En sonunda oluşan görüntüler radyoloji uzmanı tarafından yorumlanır ve yorumların diktasyonu sağlanır. Diktasyon sonucu oluşan rapor, tanılama sürecinin neticesidir. Her bir hasta için geçerli olan bu tanılama sürecinin hızı ve doğruluğu hayati önem arz etmektedir.

Bu tezde, bilgisayarlı tomografi cihazında elde edilen beyin görüntülerinin otomatik olarak işlenmesi ve acil serviste en sık görülen temel tanılar olan kanama ve enfarkt tanılarının otomatik olarak tespitini sağlayacak bir yazılım oluşturulması üzerinde çalışılmıştır. Çalışmada, mevcut görüntü işleme ve makine öğrenmesi algoritmaları kullanılarak tomografi görüntülerinden tanı yapılabilmesi incelenmiştir.

Temel olarak, ilk aşamada tomografi görüntülerinin, sayısal görüntü işleme teknikleri ile öncelikle iyileştirilmesi ele alınmıştır. İyileştiren görüntülerden daha sonra yine farklı görüntü işleme yöntemleri ile tanı yapılabilmesi amacı ile öznelilik çıkarma yöntemleri incelenmiştir ve otomatik tanı yapılabilmesine en uygun öznelilik parametrelerinin seçilmesi gerçekleştirilmiştir. Son aşamada ise elde edilen öznelilikler ile sınıflandırma işlemi uygulanarak bilgisayarın otomatik olarak karar vermesi sağlanmıştır. Bu noktada, literatürde en sık kullanılan destek vektör makinelerinden (SVM) yararlanılmıştır.

Deneyler sırasında tamamen normal beyin bilgisayarlı tomografi görüntülerinin yanı sıra kanama ve enfarkt tanılarına sahip gerçek görüntüler veritabanı olarak kullanılmıştır. Öznelilik belirleme için yerel ikili örüntü (LBP) yöntemi tercih edilmiştir. Görüntü işlemede kullanılacak dönüşümler ve öznelilikler için optimal parametreler belirlenmiştir. Tüm test ve işlemler MATLAB programı vasıtasıyla yapılmıştır. Testler kapsamında görüntü iyileştirme yöntemlerinin uygulanmadığı ve her birinin tekil ve farklı kombinasyonlarının uygulandığı tüm durumlar ele alınmıştır. Gerçekleştirilen testlerde kanama vakaları için en yüksek %67 doğru tespit oranına, enfarkt vakaları için ise en yüksek %81 doğru tespit oranına erişilmiştir.

Anahtar kelimeler: otomatik beyin kanama tespiti, otomatik beyin enfarkt tespiti, bilgisayarlı tomografi otomatik tanı koyma, lbp öznelilikleri.

AUTOMATIC DIAGNOSIS OF FUNDENTAL BRAIN DISEASES IN COMPUTED TOMOGRAPHY

SUMMARY

Computed tomography (CT) is the most commonly used sequential diagnostic unit with magnetic resonance imaging (MR) in imaging sections of healthcare facilities. Tomography and MR devices have superiority in diagnosing each other according to the suspected disease type. For this reason, clinicians make device selection for diagnosis according to preliminary findings. The tomography device is particularly advantageous in cases of bleeding and bone fractures. Therefore, in emergency services, the tomography unit is used more intensely than the MR unit. The diagnostic process begins with the patient being directed to the relevant unit. Subsequently, the radiology technicians do the scan in the relevant unit. Finally, the images are interpreted by the radiologist and the dictation of the interpretation is provided. The result of the dictation is the result of the diagnostic process. For each patient, the process is thus completed from the beginning to the end. The speed and accuracy of the diagnostic process is vital for patients.

In this thesis, automatic processing of brain images obtained from a computed tomography device and creation of a software that will automatically detect the most common basic diagnoses, hemorrhage and infarct, are studied. In the study, the ability to make an automatic diagnosis from tomography images using existing image processing and machine learning algorithms has been investigated.

Basically, first of all, the improvement of the tomography images with digital image processing techniques is discussed. Then, the methods of extracting features with the aim of diagnosing with different image processing methods have been examined from the improving images and the most suitable parameters have been selected for automatic diagnosis. At the last stage, classification is performed with the obtained attributes and the computer is automatically decided. At this point, the support vector machines (SVM) classifier, which is the most frequently used classification algorithm in the literature, is used.

During the experiments, true brain computed tomography images as well as actual images with hemorrhage and infarcts were used as a database. The local binary örüntü (LBP) method is preferred for feature extraction. Optimal parameters are specified for the transformations and features to be used in image processing. All tests and operations were done by the MATLAB program.

Histogram equalization, contrast adjustment, median filtering, average filtering, gamma correction and power-law transform are used as image enhancement methods in the tests. For gamma correction and power-law transform, the application results for different gamma and n values were examined, optimal gamma and n values were determined and these values were used in the tests.


Optimal neighborhood method and parameter for LBP are determined by accuracy of results with applying different methods and parameters for LBP. Tests are performed by turns. For each turn, 25 images were selected randomly for training and the remainder were divided into test. After 2000 turns, average of detection accuracy of turns is taken as a result. The tests covered all cases in which image enhancement methods were not applied and the singular and different combinations of each were applied. In the tests performed, the highest detection rate was reached at 67% for hemorrhage cases and at 81% for infarct cases.

Key Words: automatic brain hemorrhage detection, automatic brain infarct detection, computed tomography automatic diagnosis, lbp features.



1. GİRİŞ

Sağlık sorunlarının teşhisi ve konan tanıya göre tedavisinin sağlanması açısından görüntüleme cihazları gelişen teknolojiyle beraber yüksek önem arz etmektedir. Kullandığı teknik, vücutta kullanılacağı bölge ve araştırılan hastalık türlerine göre çeşitli görüntüleme cihazları bulunmaktadır. Manyetik rezonans [1], bilgisayarlı tomografi [1], röntgen [1], mammografi [2], kemik dansitometre [3], ultrasonografi [1] başlıca görüntüleme cihazlarıdır. Kesitsel görüntülemede manyetik rezonans ve bilgisayarlı tomografi kullanılmaktadır [4]. Bu cihazlarda hastaya ait ilgili bölge taranmakta ve tarama neticesinde bölgenin kesitler bir başka deyişle dilimler halinde görüntüleri oluşmaktadır [5]. Bu kesitler ardışıl olarak incelenerek radyoloji uzmanları tarafından yorumlanmaktadır. Bu yorumlama neticesinde tanı konmakta ve hasta, tedavi süreci için klinisyene yönlendirilmektedir. Görüldüğü üzere radyoloji uzmanının yorumu doğru tedavi için kritiktir. Şekil 1.1’de tomografi tanı süreci gösterilmektedir.



Şekil 1.1 : Tomografi tanı süreci.

Yapay zeka konusundaki çalışmalar günümüzde tüm hızıyla devam etmektedir. Yapay zeka, hem sıradan, hem de uzmanlık gerektiren işlerin otomatikleştirilmesi ile ilgilidir. Yapay zekada temel amaç, insanların zor yaptığı işleri yapabilecek sistemler üretmektir. Tıp alanında uzmanlık gerektiren işlerin çokluğu yapay zeka konusunda

çok çeşitli çalışmaların yapılmasına imkan sağlamaktadır. Bu çalışmada benzer olarak uzmanlık gerektiren raporlama yani tanılama sürecinin bilgisayara alınması üzerinde durulacaktır.

Bilgisayar tomografi ünitesi, poliklinik hizmetlerin yanı sıra özellikle acil serviste yoğun olarak kullanılmasından dolayı çalışmada tercih edilmiştir. Beyin kanaması ve enfarkt vakalarına hastanelerin tomografi çekimleri esnasında sıklıkla karşılaşılmaktadır. Ayrıca bu vakaların hızlı teşhisi insan hayatı açısından yüksek ehemmiyete sahiptir. Bu nedenlerle, bu vakaların bilgisayar vasıtasıyla hızlı ve doğru tespiti son derece önemlidir.

1.1 Tezin Amacı

Çalışmayla beraber doktordan (radyoloji uzmanından) bağımsız bir tanılama yapabilecek sistemin oluşturulması amaçlanmıştır. Otomatize edilmiş bir işlem öncelikle insani faktörlere bağlı yanlış tanı olasılığını ortadan kaldıracaktır. Çıplak gözle seçilemeyecek ya da atlanacak ince ayrıntılar sorunsuz bir şekilde yakalanabilecektir. Bilgi ve tecrübeye bağlı uzmandan uzmana değişen yorum farklılıkları ya da yanlış tanı riski bertaraf edilecektir. Çekim sonrası görüntüyle ilgili yorumun ivedilikle yapılması sağlanmış olacak, uzmanın inceleme yapmasının beklenmesiyle zaman kaybedilmeyecek ve tanı konulma süresi kısıllacaktır. Tanının hızlı konması, tedavi sürecinin zaman kaybedilmeden başlatılmasını sağlayacaktır.

Radyoloji alanında uzman ihtiyacı oldukça fazladır. Buna bağlı radyoloji uzmanlarının ciddi iş yükü bulunmaktadır. Özellikle kamu hastanelerinde uzman azlığından uzun randevu ve sonuç verme süreleri söz konusu olmaktadır. Sonuç verme sürelerinin uzunluğu, hastanın tedaviye başlamasını geciktirmektedir. Yapay zeka çözümleriyle uzmana olan ihtiyaç azalabilecek ya da tamamen ortadan kalkabilecektir. İş yükünün bu sayede azaltılmasıyla hem bu tarz mağduriyetlerin önüne geçilebilecek hem de uzman boşluğu azaltılmış olacaktır.

Hastaya yapılacak tomografi çekimi, bazı parametrelerin; bölge, hasta ve ön bulgular gibi faktörlerle ilintili olarak belirlenmesi suretiyle gerçekleştirilmektedir. Parametreler; görüntü kalitesini belirlemelerinin yanı sıra hastaya verilen radyasyon miktarına da etki etmektedir. Özellikle görüntüyü yorumlayacak uzmanlar imajların istedikleri veya alışageldikleri formatta olması için parametreler değişkenlik

göstermektedir. Bu da hastaya deęişken radyasyonların verilmesine sebebiyet vermekte ve hasta saęlığını tehdit etmektedir. Yorumun bilgisayara taşınması, parametrelerin bilgisayarın doęru yorum yapacağı en alt seviyede belirlenmesini saęlayacaktır. Bu durum çekimlerin hastaya en az düzeyde radyasyon verilecek şekilde gerçekleşmesini mümkün kılacaktır. Ayrıca tüm kuruluşlar için çekim aynı standartta yapılabilecektir.

1.2 Literatür Araştırması

1.2.1 Görüntü işleme kullanan otomatik tanı sistemleri

Dijital görüntü işlemeyi kullanan bilgisayar destekli tasarım (CAD) otomatik tanı tekniklerini yararlarını ve bu sistemlerle teşhis edilen hastalık çeşitlerini ele alan bir çalışma yapılmıştır [6]. CAD sisteminin birçok problem yaşadığı, bu yüzden diğer yöntemlerin avantajlarının CAD ile birleştirilerek yeni yöntemler getirilmesi gerektiği belirtilmiştir. Bilgisayarlı otomatik teşhisin avantajları ve yaşadığı problemler maddeler halinde incelenmiştir [6].

Çalışmanın sonucunda, idiopatik pulmoner fibroz, beyin tümörleri, meme kanseri gibi ağır hastalıklar için CAD sistemlerinin gelecekte objektif uygulamada hekimler için daha da önemli hale geleceği saptanmıştır [6]. CAD sistemlerinin hala zorlayıcı ve doğruluğunun endişe verici olduğu görülmüştür. Bu nedenle, yeni teknikler ve çeşitli sınıflandırıcılar gibi gelişmiş yöntemler CAD ile birleştirilmesinin daha iyi ve doğru sonuçlar verebileceği belirtilmiştir [6].

1.2.2 Akciğerlerin bilgisayarlı tomografi görüntüsü otomatik segmentasyonu

Çalışmada, tıbbi görüntü analizi için bilgisayar destekli tanı koymanın en iyi yöntemi ilk önce görüntüyü parçalara ayırmak için ön işleme koymak olduğu söylenmiş ve akciğer bilgisayarlı tomografi (BT) hasta görüntüsünün bilgisayar destekli tanı konusundaki ilk adım genel olarak ilgilenilen bölgeyi (bu durumda akciğer) segmentize etmek ve daha sonra, tümör, kanser, düğüm tespiti veya tanı için diğer patoloji için elde edilen her alanı ayrı ayrı analiz etmek olduğu belirtilmiştir [7]. Bu, genellikle daha kolay bir yaklaşımdır, çünkü doğru teşhisi koymak için kullanılan alan, bölümlenme işlemi ile daha da küçülmekte ve radyolog gözlemine yalnızca belirli bölge içindeki belirli verilere odaklanabilmektedir.

Segmentasyon algoritması, resmin karanlık yüzünden tohum pikselini seçmekle başlar [7]. Göğüs görüntünün kenarlarına dokunursa, segmentasyon işleminin tam olarak tamamlanmasını sağlamak için görüntünün kenarına sınır olarak bir piksel eklenir. Başka bir durumda, sınırın altına dokunan her arka plan bölgesi için bölge büyütme algoritması için bir tohum pikseli seçilmelidir. Her bir hasta BT seti için optimum eşik; doku ve hava hacmine, dokudaki yoğunluk birimlerine, görüntü toplama metodolojisine ve akciğer parankimi görüntüsündeki kontrasta bağlıdır. Ayrıca, optimum eşik seçilen seriden her bir resim için seçilir.

Toraks BT görüntülerinden akciğerlerin segmentasyon sürecinin radyologa yararlı olduğu ortaya konmuştur, çünkü görüntü analizinin odak noktası sadece akciğerlere ayarlandığından kullanıcılar sadece ilgilenilen bölgeye kanalize edilebilir. Bununla birlikte, lezyonun plevraya dokunduğu bölgede, algoritmanın daha hassas olabileceği gösterilir, böylece bütün pikseller ilgi alanına dahil edilir. Bu yaklaşım gelecekteki çalışmalarda değerlendirilebilir.

1.2.3 Bilgisayarlı beyin tomografi taramasında bilgisayar destekli tanı

Makine öğrenme algoritmalarının, beyin bilgisayarlı tomografisindeki normal okumalar ile tüm varyasyonlarını ayırt etmeye nasıl yardımcı olabileceğini [8] çalışması açıklamaktadır. Amaç, normal görünen yapıları tespit edebilen bir sisteme sahip olmak ve bu sayede radyolog tarafından beyin bilgisayarlı tomografi taramalarının büyük bir kısmı için gereksiz bir okuma yapılmasını sağlayarak normal çalışmaları belirlemektir [8].

Çalışmada görüntülerin histogram analizleri yapılmış, bazı parametrelerin tespiti ve tanıyla ilintisi incelenmiş olup bilgi çıkarımı için ilgili parametrelerin tanımlandığı söylenmiştir [8]. En kararlı algoritmanın oylama özellik aralığı VFI isimli sınıflandırma algoritması olduğu tespit edilmiştir [8]. Daha yüksek sayıdaki çalışmaların daha iyi sonuçlara yol açabileceğini belirtmek zorunluluktur. Beyin BT muayenelerinde patolojinin varlığını veya yokluğunu belirlemek için gerekli olan bilgi çıkarımı için öğrenme algoritmalarının daha iyi değerlendirilmesine izin vermek için daha büyük sayıdaki vakalarla sağlanan öğrenme süreci gerçekleştirilmesi gerektiği bildirilmiştir.

1.2.4 Tümörlerin wavelet tabanlı doku özellikleri ile otomatik tanınması

Doku sınıflandırmasını gerçekleştirme ve dalgacık tabanlı istatistiksel doku analiz yöntemini kullanarak bilgisayarlı tomografi (BT) görüntülerinde mevcut olan anormal tümör bölgesini otomatik olarak teşhis etme konuları [9] çalışmasında araştırılmıştır. Doku analiz yönteminin karşılaştırmalı çalışmaları, önerilen dalgacık tabanlı doku analiz yöntemi ve uzaysal gri seviye bağımlılığı yöntemi (SGLDM) için yapılmıştır.

Önerilen sistem dört aşamadan oluşur [9]:

- i. Ayrık dalgacık ayrıştırma
- ii. Özellik özütleme
- iii. Özellik seçimi
- iv. Çıkarılan doku özelliklerinin sınıflandırıcı tarafından analizi

Bir wavelet tabanlı istatistiksel doku özellik kümesi normal ve tümör bölgelerinden türetilir. Genetik algoritma (GA) [10], elde edilen doku özelliklerinin kümesinden en uygun doku özelliklerini seçmek için kullanılır. Destek vektör makineleri (SVM) [11] tabanlı sınıflandırıcıyı oluşturulmuş ve SVM tabanlı sınıflandırıcının sınıflandırma sonuçlarını geriye yayımlı sinir ağı sınıflandırıcısı (BPN) [12] ile karşılaştırılarak sınıflandırıcının performansı değerlendirilmiştir.

Sistem, gerçek bilgisayarlı tomografi beyin görüntüleri ile test edilmiştir. Sonuçlar dalgacık tabanlı istatistiksel doku özelliklerine sahip SVM sınıflandırıcısının, dalgacık dönüşümü uygulamadan doğrudan görüntüden çıkarılan istatistiksel doku özelliklerine kıyasla daha iyi sonuçlar verdiğini göstermektedir. Bu, dalgacık dönüşümü seçimini haklı çıkarmaktadır. Büyük veri tabanlarının kullanılması, sistem performansını iyileştirir ve sonuçta performansın tekrarlanabilirliğini garanti eder.

1.2.5 Romatoid artrit için optik tomografi ile bilgisayar destekli tanısı

Diffüz optik tomografi (DOT) için bilgisayar destekli tanı uygulaması üzerine çalışma [13, 14] yapılmıştır. DOT görüntülerinden sezgisel özellikler çıkarmak için bir yaklaşım ve romatoid artrit (RA) teşhis etmek için bu özellikleri kullanma yöntemi sunulmuştur [13, 14]. Çalışmanın ilk bölümünde [13] özellik çıkarımı üzerinde durulmuş, ikinci bölümde [14] sınıflandırma algoritmalarının yararları değerlendirilmiştir. Sistem, proksimal interfalangeal (PIP) eklemlerin 219 DOT

görüntüsü setinde doğrulanır. Genel olarak, her eklemin absorpsiyon ve saçılma görüntülerinden 594 özellik elde edilmiştir.

Yapılan çalışma neticesinde üç önemli bulgu ortaya çıkarılmıştır. İlk olarak, RA'lı hastaların DOT görüntüleri, incelenen özelliklerin %90'ından fazlası için RA bulunmayan hastaların görüntülerinden istatistiksel olarak farklıdır. İkincisi, saptanabilir efüzyon, erozyon veya sinovit (RA ve ultrason ile belirlendiği gibi) bulunmayan RA'lı hastaların DOT görüntüleri, efüzyon, erozyon veya sinovit gösteren RA hastalarının DOT görüntülerinden istatistiksel olarak ayırt edilemez. Bu nedenle, bu alt gruptaki olgular, DOT görüntülerinden RA ile teşhis edilebilirken, MR veya ultrason görüntülerinin gözden geçirilmesiyle saptanamayacaklar. Üçüncü olarak saçılma katsayısı görüntüleri daha iyi tek boyutlu sınıflandırıcılar üretir. Bu bulgular, DOT'un sağlıklı PIP eklemleri ile efüzyon, erozyon veya sinovit varlığında veya yokluğunda RA'dan etkilenen PIP eklemlerini ayırt edebileceğini göstermektedir. Bu iki kısımlı çalışmanın amacı, DOT görüntülerinden RA tanısı koymak için bir çerçeve oluşturmaktır. İlk bölümde, DOT görüntülerinden, RA'lı ve olmayan özneler arasında ayırım yapan özellikleri ayıklamak için bir yöntem sunulmuştur.

Çalışmada önerilen süreç üç aşamadan oluşmaktadır:

- i. veri ön işleme
- ii. öznelik çıkarma
- iii. bireysel özelliklerin istatistiksel ve ROC eğrisi analizi

Sistem, klinik bir araştırma (33 RA ve 20 sağlıklı kontrol denekleri) ile toplanan PIP eklemleri 219 DOT görüntüsünde test edilmiştir. Amerikan Radyoloji Koleji (ACR) kriterlerine göre RA'nın klinik tanısı altın standarttır. Klinik olarak baskın olan elin ultrasonografi (USG) ve MR taramaları yapılmıştır.

Bir romatoloji uzmanı ve radyolog görüntüleri analiz etmiş ve her özneyi RA'nın saptanabilir semptomlarına dayalı olarak sınıflandırmıştır. RA'dan kaynaklı eklem deformiteleri bulgusu olmayan kişiler, görüntüsüz temelli kanıtlara dayalı olarak sağlıklı veya RA ile etkilenen olarak sınıflandırılmıştır. Tanı grupları arasındaki istatistiksel olarak anlamlı farklılıkları ortaya çıkaran özellikler bulmak için kullanılmıştır. İkinci bölümde [14], bu çalışmada sunulan alıcı işlev karakteristiği (ROC) analizinden en büyük Youden endekslerine neden olan özellikleri kullanarak çok boyutlu sınıflandırma üzerine odaklanmaktadır. Beş farklı sınıflandırma

algoritması kullanıldığında, tek görüntü özelliklerinden ziyade çoklu görüntü özelliklerinin kullanılması, daha yüksek duyarlılık ve özelliklere yol açtığını göstermiştir.

1.2.6 Bilgisayarlı beyin tomografide inme hasarının otomatik nicemlemesi

Akut iskemik inmenin acil radyolojik tanısı, ilgili görüntüleme bulgularının doğru algılanmasını ve uygun şekilde yorumlanmasını gerektirir. Kontrastsız bilgisayarlı tomografi, iskeminin erken belirtilerinin hızlı ve düşük maliyetli olarak değerlendirilmesini sağlar ve akut inme için en yaygın kullanılan tanı modalitesidir [15]. Alberta inme programı erken BT puanlaması (ASPECTS), beyin BT taramaları üzerindeki iskemik bulguların boyutunu ölçmek için kantitatif ve klinik olarak onaylanmış bir yöntemdir [15]. Conformance European (CE) sertifikalı elektronik ASPECTS (e-ASPECTS) yazılımı ASPECTS puanı otomatikleştirir.

Anglia Ruskin Klinik Deneme Birimi, akut iskemik inme hastasının tanı yoluna entegre edilebilen ve böylece doktorun beynin uzman yorumu ile desteklenebilen otomatik puanlama sistemi olan e-ASPECTS yazılımının klinik araştırmasını bağımsız olarak yürütmüştür [15]. Tüm randomize çalışmalar taranmış ve ASPECTS performansının gösterilmesi ile alakalı olarak değerlendirilen veriler değerlendirilmiştir.

Çalışma üç alan üzerinde yoğunlaşmıştır [15]:

- i. inme hastalarının beyin BT incelemelerinin yorumlanması
- ii. iskemik inmede ASPECTS skorunun uygulanması
- iii. beyin BT analizinin otomasyonu

ASPECTS veya e-ASPECTS'in hiçbir zaman izole olarak kullanılamayacağı ancak tamamlayıcı bilgi olarak kullanılacağı aktarılmıştır.

Hiperakut ortamda ASPECTS, akut iskemik inmeli hastalarda fonksiyonel sonucun öngördürücüsü olarak doğrulanmıştır. Bu nedenle, ASPECTS skorunun bir karar destek aracı olarak bir klinik bakım yoluna entegrasyonu mantıklı olacaktır. Bununla birlikte, ASPECTS'in elle uygulanmasının gerektirdiği uzmanlık, klinik bakımdaki kullanımını sınırlayabilir. Buna ek olarak, göz içi ve gözlemciler arası değişkenlik, yalnızca klinik ortamda değil, aynı zamanda resim seçim kriterleri kullanıldığında klinik denemede kayıt yapılmasında da bir sorundur.

Yazılımın geliştirilmesi, tercüman uzmanlığına bakılmaksızın geçerliliği onaylanmış ASPECTS skorunu kullanarak beyin BT taramasının hızlı ve standartlaştırılmış değerlendirilmesini sağlar, böylece gözlemciler arası ve gözlemciler arası değişkenliği ortadan kaldırır. ASPECTS'in standartlaştırılmış kullanımının, genel sağlık durumu, işlevsel yeteneği, biliş ve yaşam kalitesi açısından hastalar için anlamlı olan uzun vadeli sonuçlarının büyük değere sahip olacağı bildirilmiştir.

1.2.7 BT görüntülerinde otomatik kanama segmentasyonu ve sınıflaması

Beyin kanaması tespiti ve sınıflandırılması, doktorların erken bir aşamada hastaları kurtarması için büyük bir yardımcıdır. Bu çalışmada, hekimlerin karar verme sürecini iyileştirmek ve hızlandırmak için otomatik algılama ve sınıflandırma yöntemi sunmaya çalışılmıştır [16].

Genellikle, beyin kanamaları; epidural kanama (EDH), subdural kanama (SDH), subaraknoid kanama (SAH), intraserebral kanama (ICH) ve intraventriküler kanama (IVH) olmak üzere 5 ana tipe ayrılır [16]. Çalışmada EDH, SDH ve ICH kanamalarını seçilmiş çünkü bu kanama tiplerinde özellikle de kanamanın beyin dokusunda olduğu ICH kanamalarında hastaların yaşamları tamamen erken teşhisi bağlıdır [16].

Başlangıçta kanama bölgelerini beynin diğer bölgelerinden algılayan ve ayıran basit ve etkili bir sınıflandırma yöntemi kullanılmıştır. Bu aşamada ilk olarak kafatası ve beyin ventriküllerinin çıkarılması işlemi yapılmıştır. Bunun için histogram analiz edilmiş ve kafatası ve ventriküllere ait bileşenler tespit edilerek çıkarılmıştır. Sonrasında gürültü azaltma için medyan filtre tercih edilmiştir. Bazı imajlarda yumuşak doku ödemleri hataya sebebiyet verebileceği için maske oluşturularak ayrıştırılmıştır. Tüm işlemler sonucu elde edilen görüntü eşikleme vasıtasıyla sadece kanama bölgesinin kalacağı şekle dönüştürülmüştür.

Daha sonra kanama bölgesinin her birinden bir dizi özellik çıkarılmıştır. Bu özellikler iki grup altında aşağıdaki gibidir:

Çalışmada kullanılan şekilsel öznitelikler şunlardır [16];

1. Alan: Kanama bölgesinde gerçek piksel sayısıdır.
2. Çevre: kanama bölgesi sınırı etrafındaki mesafedir.
3. Oryantasyon: Kanama bölgesi ile aynı ikinci momentlere sahip olan elipsin x-ekseni ve ana eksen arasındaki açıdır.

4. Ana eksen uzunluđu: Kanamalı bölge ile aynı normalize edilmiş ikinci merkezi momentleri olan elipsin uzun ekseninin piksel cinsinden uzunluđudur.
5. Minör eksen uzunluđu: Kanamalı bölge ile aynı normalize edilmiş ikinci merkez momentleri olan elipsin yan ekseninin piksel cinsinden uzunluđudur.
6. Kapsam: Sınırlama kutusunda olup aynı zamanda hemorajik bölgede olan piksellerin oranıdır.
7. Konveks alan: Konveks resimdeki piksel sayısını belirten deđerdir.
8. Katılık: Dışbükey gövdede bulunup aynı zamanda hemoraj alanında olan piksellerin oranıdır.
9. Eşdeđerlik: Kanama bölgesi ile aynı alana sahip bir dairenin çapını belirten deđerdir.
10. Doldurulmuş alan: Dolgulu resimdeki piksel sayısını belirten deđerdir.

Genişletilmiş dokusal öznitelikler ise [16];

1. Kontrast: Bir pikselin komşusu ile bütün görüntü üzerindeki yoğunluk kontrastının bir ölçüsü döndürür.
2. Enerji: Gri düzeyli eşdizilimlilik matrisindeki (GLCM) elemanların karelerinin toplamıdır.
3. Korelasyon: Bir pikselin komşusu ile bütün resme ne kadar korelasyona uğradığının bir ölçüsüdür.
4. Homojenlik: GLCM matrisindeki elemanların GLCM köşegenine dağılımının yakınlığını ölçen bir deđer döndürür.

Genetik Algoritma (GA) tabanlı bir özellik seçme algoritmasını [17] kullanarak bu özelliklerden uygun bazıları seçilmiştir. Sonunda, farklı kanamalar sınıflandırılmıştır. Algoritma bir BT tarama görüntü seti üzerinde deđerlendirilmiş ve üç büyük kanama türünden EDH için segmentasyon doğruluđu %96,22, ICH için %95,14 ve SDH için %90,04 olarak elde edilmiştir. Sınıflama aşamasında, çok katmanlı sinir ağı daha yüksek doğruluk (%93,3) nedeniyle K-en yakın komşuluk (KNN) sınıflandırıcısından [18] daha başarılı olabilir. Sonunda beyin kanamalarının tespiti ve sınıflandırılması için doğruluk oranını %90'dan fazla bulunmuştur.

1.2.8 Dokusal analiz yöntemiyle hemorajik inme algılama ve segmentasyon

Çalışmada [19] öncelikle BT tarama görüntülerinin ön işleme süreci ele alınmıştır. Görüntülerden kafa tasının çıkarılması için görüntüye bağlı iki adet maske oluşturulmuştur. Maskeler vasıtasıyla kafatası görüntülerden izole edilmiştir. Gürültü azaltma için üç defa ardışıl olarak medyan filtre uygulaması yapılmıştır. Kanama alanının çıkarılıp alınması içinse eşikleme uygulanmıştır.

Beynin görüntüsü iki eşit parçaya bölünmüştür; bu parçalardan birinde anormal bölge, diğeri normal alanı içermektedir. Daha sonra istatistiksel özellikler birinci derece histogramdan hesaplanmıştır. Hangi parçanın inmeyi taşıdığını kontrol etmek için iki parçanın histogramları arasında karşılaştırmalar yapılmıştır. İstatistiksel özellikler olarak;

1. ortalama

2. standart sapma

3. enerji

4. entropi

5. varyans

6. çarpıklık

7. basıklık

katsayıları ilgili formüllerle hesaplanmıştır [19]. Burada entropi, enerjiyle ters orantılıdır. Entropi yüksekliği homojen olmayan doku anlamına gelir, yani dokuda bir bozukluk var demektir. Çarpıklık, ortalama etrafındaki bir dokunun simetrisini temsil eder, bu nedenle anormal kısım değeri normal parçadan daha simetridir. Basıklık histogramın şeklini gösteren parametredir.

Görüntüdeki rastsallığı temsil ettiği ve enerji ile ters orantılı olduğu için anormal kısımdaki enerji değeri normalinkinden daha düşük olduğu için, bu, gri seviye değerinin normal parçadan daha yüksek olduğu anlamına gelir. Çünkü bu bölümde inme görünümü mevcuttur. Çarpıklık ve basıklık katsayıları normal kısım için daha yüksek bir değer gösterir. İnme normal beyin dokusundan daha beyaz görünür ve ortalama değer; görüntüdeki parlaklık bölümünü temsil ettiğinden dolayı anormal

kısım için daha yüksektir. Bu yöntem, istatistiksel özellikler yardımıyla beyin inmesinin algılanması ve sınıflandırılmasıyla ilgili iyi sonuç vermektedir.

1.2.9 Yapay sinir ağı kullanarak beyin kanamasının tanısı konusunda çalışma

BT taraması, beyin kanamasının doğru teşhisini sağlamaktadır. Bu projenin amacı, radyolog ve tıp fakültesi öğrencilerine BT görüntüleri vererek beyin kanaması tanısında yardımcı olmak ve beyin kanamasının türünü yapay sinir ağı ile birlikte havza algoritması kullanarak tanımlamaktır [20].

Sinir ağlarındaki teknolojilerdeki ilerlemeyle birlikte, dünyanın her yerindeki görüntü işleme vb. diğer araştırmacılar, tıbbi uzmanlığın bilgisayar destekli bir sistemle bütünleştirilmesi üzerine araştırma yapmaya başlamıştır. Bu nedenle, son otuz yılda beyin kanamalarının teşhis edilmesi için MR görüntüsünü ve BT tarama görüntülerini kullanarak beyin görüntüsünün bölünmesinde çok araştırma yapılmıştır.

Bu çalışmada, verilen BT görüntüsünden beyin kanamasının tipini saptamak ve sınıflandırmak için bir yöntem sunulmuştur. Bu yöntem birkaç aşamadan oluşmaktadır: görüntü ön işleme, görüntü parçalama, öznelik çıkarımı ve sınıflandırma. Havza algoritması [21] görüntüyü parçalamak için kullanılır. Özellikler, gri düzeyli eşdizilimlilik matrisi (GLCM) kullanılarak çıkarılır. İleri besleme geri yayımlı sinir ağı, kanama tipini sınıflandırmak için kullanılır.

Beyin görüntüleri MR, BT taraması vb. ile algılanabilir, ancak beyin kanamalarının doğru teşhisi için uygun değildirler. Beyin kanaması için çeşitli teşhis teknikleri icat edildi. Bazıları yüksek segmentasyon, gürültü giderme, doğruluk vb. gerektirmektedir. Bu projede, doğruluk, hız ve dayanıklılık bakımından gelişmiş olan sinir ağı kullanılarak bu sorunlar aşılmaktadır. Bu yazıda, biyomedikal görüntü sınıflamasında tanı bilimleri için akıllı bilgi işlem tekniklerinin uygulamaları araştırılmıştır. Hesaplama tekniklerini kullanan çeşitli özellikler avantajları ve kısıtlamaları ile tespit edilmiştir ve bu nedenle geliştirmekte olan tıbbi sistemlerin geliştirilmesi için daha iyi bir çerçeve oluşturarak sağlık bakımının maliyet etkinliği ile daha iyi yapılmasını sağlar.

1.2.10 Hemoraji içeren bölgenin bilgisayar destekli saptama sistemi

Bu çalışmada, beyin BT görüntüsünde kanamayı saptamak ve sınıflandırmak için otomatik yöntemin tanıtılması amaçlanmıştır [22]. Başlangıçta, görüntü; gürültü

ve kafatası bölgesini kaldırmak için işlenmiştir. Anormallik bölgesi segmente edilmeden önce, görüntü bölütlenir. Bu aşamada, görüntü anormal bölgelerin olabileceği bölgeyi bulmak için dört bölüme ayrılmıştır. Dolayısıyla, gereksiz bölgelerin araması ve segmentasyonuna ihtiyacı yoktur. Bu çalışma, beyin görüntüsünde anormal bölgenin tespiti için ön segmentasyon adımlarını önermiştir. Ardından, homojen bölgelerin önceden tanımlanmış kriterlere göre gruplandırılması ile anormallikler ayrılabilir.

Çalışmanın adımları aşağıda verilmiştir [22]:

1. Adım: Görüntü 4 bölüme ayrılmıştır.
2. Adım: Her bölge için piksel değerlerini hesaplanmıştır.
3. Adım: Her birini önceden tanımlanmış ölçütlerle (piksel değeri) karşılaştırılmıştır.
4. Adım: Anormal bölgeye sahip bölge bölütleme sürecine verilmiştir.

Deneysel sonuçlar incelendiğinde kanamalı bölgede ortalama ve standart sapma değerlerinin diğer normal üç bölgeye göre farklı olduğu (ortalama yüksek, standart sapma düşük) görülmüştür.

Çalışmada bulunan sonuçlar ışığında aşağıdaki yorumlar ve düşünceler belirtilmiştir [22]:

Beyin BT görüntüleri ayrı doku tiplerine bölünmekte ve anormal dokunun saptanması kolaylaşmaktadır. Bu sistem, radyolojik uzmanların beyinin kanama bölgesini algılamasına ve daha hızlı ve doğru bir karar almasına yardımcı olabilecektir. Karar vermek için ikinci görüş olarak kullanılabilir. Bölünmüş sonuçların doğruluğu radyologların bilgisi ile belirlenebilir. Sistem, tümör, apse ve lezyon gibi diğer beyin anormalliklerini saptamak için genişletilebilir. Adaptif algoritmalar akciğer, karaciğer ve kemik gibi diğer tıbbi görüntülerde kanser, tüberküloz gibi ilgili hastalıklarını tespit etmek için uygulanabilir.

1.2.11 Dokusal analiz yöntemiyle iskemik inme algılama ve segmentasyon

Yapılan çalışmada, BT görüntülerinden beyinde inmelerin saptanması, izolasyon işlemi, bölge büyütme ve mantıksal operatörler (OR ve AND) ile beyin görüntüsünü nitelenmek için görüntü iyileştirmeden başlayarak uygun işleme tekniğine ihtiyaç duyulduğu belirtilmiştir [23]. Mantıksal operatörle yapılan morfolojik teknikler (açılış

ve kapanış) iyi sonuçlar vermektedir. Eşikleme süreci olan en basit segmentasyon sürecinin yardımı ile elde edilen bu sonuçlar beyindeki BT görüntüsünden bir inme bölgesi çıkarmak için kullanılır. Medyan filtre, görüntünün gürültüsünü gidermek için uygulanır. İnme bölgesinin tespitinde istatistiksel özellikler birinci derece histogram kullanılarak hesaplanmıştır.

Hesaplanan istatistiksel özellikler ortalama, standart sapma, enerji, entropi, varyans, çarpıklık ve basıklık parametreleridir.

Ön işleme yöntemleri, bölümlenmeyi bilinen süreçten daha kolay ve hızlı yapmak için önemlidir. Beynin normal ve anormal kısımlarını karşılaştırmak için özellikler kullanılır. Birinci mertebeden histogramdan elde edilen istatistiksel özelliklerin anormal bölümünü geliştirmek için farklı ön işleme yöntemleri kullanılmıştır. Entropi yüksek değerler izlenmektedir. Bu görüntüdeki rastsallığa ve enerjiye ters orantılı olduğu içindir. Yani anormal kısım için enerji değeri normal kısmın altındaysa, bu, gri seviye değerinin normal parçadan daha yüksek olduğu anlamına gelir, dolayısıyla inme görünüşü mevcuttur. Çarpıklık ve basıklık normal kısım için daha düşük bir değer gösterir. Ortalama değer ve ortalama değere bağlı varyans anormal kısım için daha düşüktür çünkü inme normal beyin dokusundan daha koyu görünür ve ortalama görüntüdeki parlaklık bölümünü temsil eder. Bu yöntem istatistiksel özellikler yardımıyla beyin inmesinin algılanması ve bölünmesi hakkında iyi sonuç vermektedir.

1.2.12 Genetik algoritma kullanarak beyin tümörü segmentasyonu

Beyin tümörü, sağlık alanında çok yaygın bir ölüm nedenlerindedir. Görüntü parçalama, beyindeki anormal tümör bölümünü çıkarmak için kullanılır [24]. Beyin tümörü, hücrelerin büyüdüğü ve hücreleri kontrol eden mekanizmalar tarafından kontrolsüz şekilde çoğaltılmış anormal bir doku kütesidir. Beyindeki tümörün saptanması için çeşitli teknikler geliştirilmiştir. Bu çalışmadaki temel konsantrasyon, beyin tümörünü saptamak için görüntü bölümlenmesini kullanan teknikler üzerinedir [24]. Tümör sınıflandırması ve beyin bilgisayarlı tomografi görüntü verilerinden segmentasyon, tıbbi uzmanlar tarafından gerçekleştirilen önemli fakat zaman alıcı bir görevdir. Beyin tümörleri primer ve sekonder olarak iki kategoriye ayrılmaktadır.

Genel olarak genetik algoritmanın beş aşaması vardır [25, 26]: nüfusun başlatılması, fitness fonksiyonunun değerlendirilmesi, seçim, çaprazlama, mutasyon ve sonlandırma. İlk popülasyon rastgele oluşturulur, bu da genlerin tesadüfi değerlere

ayarlanmasıyla yapılabilir. Başlatma işlemi sonrasında, her kromozomun uygunluk fonksiyonu değerlendirilir. Seçim sürecinde, mevcut popülasyondaki en uygun üyeler, yeni çözümleri çaprazlama işlemiyle üretecek şekilde seçilir. İki kromozom seçilir ve bir noktaya kadar genler değiştirilir. Mutasyon sürecinde bir gen rasgele seçilir ve değeri değiştirilir. Sonunda, iterasyonun sonlandırılması belirli bir kriter karşılandığında yapılır. Genellikle sonlandırma yineleme sayısı ile yapılır.

Taranan MRG görüntülerinden beyin tümörünü saptamak ve segmentlere ayırmak için çeşitli yöntem ve teknikler incelenmektedir. Çeşitli yöntem ve teknikler gözden geçirildikten sonra beyin tümörünü gelişmiş doğruluk, hassasiyet ve özgüllük ile tespit edebilen çeşitli yöntemler açıkça gösterilmektedir. Resim bölümlenmesinin evrensel bölümlenme algoritması olarak gelecek vaat eden bir geleceği mevcuttur [24]. Tüm gözden geçirme faktörleri nedeniyle, görüntü parçalanması görüntü işleme ve bilgisayar görüntüsünde zorlu bir problem olmaya devam etmektedir ve halen bekleyen bir sorundur. Gelecekteki çalışma planları, kanama, kireçlenme ve lezyon gibi anormal bölgelerin spesifik açıklamasını içermektedir. İyi bilinen genetik algoritma [25, 26] adlı yapay zeka vasıtasıyla çıktı beyni tümörü bölgenin köşelerinden net bir şekilde çıkarılır ve simülasyonda keskin sonuçlar alınır.

1.2.13 Beyin tümörü segmentasyonu için çerçeve tespiti

Bu çalışma, MR görüntülerinden otomatik beyin tümörü segmentasyonu için bir çerçeveyi açıklamaktadır [27]. Ödem belirlenmesi, tanı, planlama ve tedavi için önemli olduğu için ödem tespiti tümör segmentasyonu ile aynı anda yapılır. Birçok diğer tümör bölümlenme yöntemi, T1 ağırlıklı görüntüde gadolinyum kontrast ajanın ürettiği yoğunluk artışına dayanmasına rağmen burada önerilen yöntem kontrastlı görüntü kanalları gerektirmez [27].

Segmentasyon prosedürü için tek gerekli girdi T2 MR görüntü kanalıdır, ancak geliştirilmiş doku segmentasyonu için herhangi bir ilave geliştirilmemiş görüntü kanalı kullanılabilir. Segmentasyon çerçevesi üç aşamadan oluşur [27]. Birincisi, kayıtlı beyin atlasını sağlıklı beyin için bir model olarak kullanarak anormal bölgeler tespit edilmektedir. Daha sonra, farklı doku türlerinin yoğunluk özelliklerini belirlemek için normal beyin dokusu yoğunluğu kümelerinin yerinin ve dağılımının sağlam tahminleri kullanılmaktadır. İkinci aşamada T2 görüntü yoğunluğundan ödemin anormal bölgelerdeki tümörle birlikte görüp görmediği belirlenmektedir. Son olarak, tespit

edilen tümör ve ödem bölgelerine geometrik ve uzaysal sabitler uygulanmaktadır. Segmentasyon prosedürü, farklı tümör şekillerini, yerleri, boyutları, görüntü yoğunluklarını ve güçlendirmeyi temsil eden üç gerçek veri setine uygulanmıştır.

Tümörün geometrik özelliklerinin ve ödemin uzaysal ilişkisinin kullanıldığı ve görüntünün tekrar sınıflandırıldığı metodun son aşaması; olasılıkların ve örneklerin eşiklenmesiyle başlamaktadır. Tümör örnekleri, seviye kümelerinin değişimine bağlı olarak budanır. Ödem örnekleri komşuluk testleriyle budanır. Olasılık yoğunluk fonksiyonu tahmin edilir. Sınıf olasılıkları hesaplanır. Sapmaların düzeltilmesiyle başa dönülür.

1.2.14 Akıllı akut beyin kanaması teşhis sistemi


Bu çalışmada, beyin kanamasının tahmininde radyologlara yardımcı olmak hedeflenmiştir [28]. Beyin içi kanamayı üç tipe yani epidural kanama (EDH), subdural kanama (SDH), hipertansif kanama (HTN) olarak ayırmak için yeni bir yaklaşım sunulmuştur [28]. Sınıflamayı kolaylaştırmak için görüntü geliştirme araçları ve medyan filtreleme kullanılmıştır. Ayrıca, özgün eşik tekniği, şüpheli hemorajik alan olan ilgi bölgesini (ROI) ayırmak için kullanılmaktadır.

Kanama tespitinden önce, çeşitli morfolojik işlemler uygulanarak uniform bir ROI elde edilir. Sinir ağına (NN) ve destek vektör makinesine (SVM) girdi olarak geometrik ve dokusal özellikler kullanılır. NN ve SVM'nin uygulanması sırasıyla 0,875 geri çağırma, 0,952 hassasiyet ve 0,958 geri çağırma, 0,98 hassaslık vermiştir [28].

1.2.15 Beyin kanamalarının otomatik algılanması ve sınıflandırılması

Bilgisayar destekli tanı sistemleri birçok araştırma çabasının odak noktası olmuştur. Bunlar, hızlı ve doğru bir teşhis için insan vücudunun farklı bölümlerinin görüntülerini işlemek ve analiz etmek fikrine dayanmaktadır. Bu çalışmada, beynin BT taramalarında bir beyin kanamasının var olup olmadığını tespit etmek için bazı yaklaşımlar izlenmektedir [29]. Ayrıca, kanama tipi tanımlanmaktadır. Uygulanan sistem görüntü önışleme, görüntü parçalama, öznitelik çıkarma ve sınıflandırma içeren birkaç aşamadan oluşur [29]. Yapılan deneylerin sonuçları çok umut vericidir.

Çalışmada üç tip kanama baz alınmıştır. Bunlar; subdural kanama, intraparakimal kanama ve epidural kanamalardır (Şekil 1.2).



Şekil 1.2 : Normal beyin ile birlikte bu çalışmada baz alınan sırasıyla subdural, intraparenkimal ve epidural kanamalar [29].

Görüntü işleme parçası için yararlı olabilecek çeşitli yaklaşımlar mevcuttur. Buradaki odaklanma, eldeki gibi problemlerde çok yararlı olduğu gösterilen bölütlemidir. Segmentasyon aşamasında, Otsu'nun gri seviyeli histogram eşikleme yöntemi [30] kanamayı görüntüden çıkarmak için kullanılır.

Bir sonraki adımda, ilgi alanının (ROI) ayırt edici özellikleri çıkarılır. Son olarak, sınıflandırma aşamasında görüntü ROI'nin hesaplanan özelliklerine dayalı olarak sınıflandırılır. Sınıflandırma ve test parçaları için Weka veri madenciliği aracı [31] kullanılmışken, MATLAB kodu görüntü işleme ve bölümlemenin yanı sıra özellik çıkarma kısımlarını gerçekleştirmek için yazılmıştır.

Yararlı ve ayırıcı özellikleri görüntülerden çıkarma, herhangi bir sistemde en önemli adımlardan biri olabilir. Aşağıda, ilgi alanı (ROI) hakkında çıkartılan özellikler verilmiştir.

- ROI'nin boyutu (piksel cinsinden).
- ROI'nin merkezi.
- ROI'nin çevresi.
- ROI ve kafatası arasındaki mesafe; epidural ve subdural hemorajiler için çok küçük olması ve parankimal içi kanama için nispeten büyük olması beklenir.
- ROI ile aynı büyüklüğe sahip bir dairenin çapı.
- ROI'deki piksellerin, ROI'nin dış bükey gövdesindeki piksellere oranı; bu, kanama tipleri arasında, genellikle subdural kanama gibi yaygın içbükey şekillere sahip kanama tipleri ve epidural ve intraparenkimal hemorajiler gibi yaygın dışbükey şekilleri ayırt etmede yararlı olmalıdır.

- ROI'yi içeren en küçük sınırlayıcı kutu. Aşağıdaki özellikler bu sınırlayıcı kutuyla ilgilidir.
 - ROI sınırlama kutusu ile aynı boyuttaki ikili bir resimdeki piksel sayısı.
 - ROI'daki piksellerin ROI'nin sınırlayıcı kutusunda piksellerine oranı.
- Aşağıdaki özellikler, ROI ile aynı ikinci-momentleri olan elips ile ilgilidir.
 - Elipsin dışmerkezliği.
 - Elipsin büyük ve küçük eksenlerinin uzunluğu.
 - Elipsin x eksenini ve ana eksenini arasındaki açı (derece olarak -90 ila 90 derece arasında değişir).

MATLAB'ın regionprops aracı, bu özelliklerin çoğunu hesaplamak için kullanılan temel araçtır [29].

Böyle bir çalışma, ikili sınıflandırma problemi olan bir beyin kanamasının var olup olmadığını tespit etme problemidir ve eğer varsa, çok sınıflı sınıflandırma problemi olan hangi tür olduğunun çözülmesidir. Bu çalışmada sunulan deneyler BT taramalarını ön işleme koyduktan sonra ikili sınıflandırma probleminin %100'e yakın doğrulukla çözüldüğünü göstermiştir [29]. Ayrıca, uygulanan sistem, sınıflandırıcı olarak sinir ağlarını kullanarak kanama türünü belirleme 3-sınıflı sınıflandırma sorunu için % 92'den fazla doğruluk sağlamıştır [29].

1.2.16 Çok katmanlı perceptron ile beyin stroke sınıflama

İnme, beyindeki kan akışı durduğunda ortaya çıkan bir kardiyovasküler hastalıktır. Beyin vuruşlarının teşhisi, hastalığın ilerlemesinin karakterize edilmesi ve tedavi terapilerinin izlenmesi için manyetik rezonans görüntüleri (MRG) şeklinde nörogörüntüleme teknikleri yaygın olarak kullanılmaktadır. İnmeli bölgelerin doğru bölünmesi ve sınıflandırılması, doğru tanı ve teşhis için gereklidir. Görüntü sınıflandırması, otomatik beyin felci sınıflamasının üst düzey işlenmesi için kritik bir adımdır. Bu çalışmada MRG görüntülerini inme ve darbeli olmayan görüntülere sınıflamak için bir yöntem önerilmektedir [32]. Özellikler, watershed bölümlenmesi ve gabor filtresi kullanılarak çıkarılır. Ayıklanan özellikler çok katmanlı perceptron (MLP) kullanılarak sınıflandırılır. Değişik sayıda özellik ile önerilen yöntemin verimliliğini değerlendirmek için denemeler yapılmıştır.

Öncelikle giriş görüntüsü bölümlendirme için watershed segmentasyonu uygulanır. Watershed, görüntü segmentasyonu için morfolojik temelli bir araçtır [21]. Bölgeye dayalı bir bölümlendirme yaklaşımıdır. Sonrasında özellik çıkarımı için gabor filtresi kullanılır [33]. Özellik azaltımı ve bilgi kazanımı sağlanır. Kaç özellekle işlem yapılacağı seçilir. Çok katmanlı perceptron vasıtasıyla MR görüntüsü sınıflandırılır.

MRG beyin görüntüsünün inme ve inme dışı olarak sınıflandırılması için yöntem gerçekleştirilmiştir. Sınıflandırma için en iyi 20, 40, 60, 80, 100, 120, 140 ve 160 özellikleri kullanılır. Çok Katmanlı Perceptron (MLP) ayıklanan özellikleri sınıflandırmak için kullanılır [34].

Sigmoid fonksiyonlu çok katmanlı perceptronu (MLP) değerlendirmek için deneyler gerçekleştirilmiştir. Çeşitli özelliklere sahip beyin görüntülerinin sınıflandırılmasında önerilen yöntemin etkinliği araştırılmıştır. Sonuçlar, en iyi sınıflandırma performansının, düşük kök kareler ortalama hata ve yüksek hassasiyet ile 80 ila 120 özellikli sigmoidal işlevle gerçekleştirildiğini göstermektedir.

Gelecekteki çalışma, sınıflandırma doğruluğunu artırmak için özellik sayısını optimize etmeyi amaçlamaktadır [32]. Kronik enfarktüs, kanama ve benzeri farklı inme tiplerini saptamak ve sınıflandırmak için daha fazla çalışma gerekmektedir.

1.2.17 Beyin kanamasının CAD sistemleri ile tanısı ve sınıflandırılması

Beyin kanaması beyinde patlayan bir arterin neden olduğu ve çevredeki dokulardaki kanamayı tetikleyen bir inme türüdür. Bu çalışmanın temel amacı ilk önce beyin kanamasını tespit etmek, CAD sistemini kullanarak sınıflandırmak ve böylece beyin kanaması yüzünden ölüm oranını azaltmaktır [35]. CAD sistemi, insan vücudunun farklı bölümlerinin görüntülerini işlemek ve analiz etmek temelinde çalışır. Uygulanan sistem, görüntü ön işleme, görüntü parçalama, öznelik çıkarımı ve sınıflamayı içeren çeşitli aşamalardan oluşmaktadır.

Taşınan deneylerde, özellikle sinir ağları, destek vektör makineleri, karar ağaçları vb. gibi bu çalışmayla ilgili önceki çalışmalarında iyi performans gösteren bazı sınıflandırıcılar test edilmiştir. Denemeleri çalıştırmak için Weka aracı kullanılmıştır [31]. Bu nedenle; tartışma, Weka aracında kullanılan uygulamalarla sınırlı kalmaktadır. Test ve değerlendirmeyle ilgili olarak, yaygın olarak kullanılan 10 kat çapraz doğrulama tekniği kullanılmıştır. Önerilen sınıflandırıcıların performansını


değerlendirmek için kullanılan ölçüler; hassasiyet, geri çağırma, F-ölçüsü ve alıcı işlev karakteristiği (ROC) eğrisi altında kalan alan olan AUC'dir.

Tıbbi görüntüleri analiz etmek ve sınıflandırmak için kullanılan otomatik sistemlerin sonuçları cesaret vericidir ve doğrudan BT tarayıcıdan alınan yüksek çözünürlüklü görüntülerle daha iyi bir veri kümesi elde ederek üç sınıflı sınıflandırma sorunu için daha yüksek bir doğruluk elde edilebilir [35]. Ayrıca, sistemin performansını arttırmak için farklı öznelik çıkarma ve özellik seçme teknikleri kullanılabilir. Son olarak, sınıflandırma için topluluk sınıflandırıcıları, daha yüksek doğruluğu başarmak için gelecekteki bir çalışma olarak değerlendirilecektir [35].

1.2.18 Sinir ağı yaklaşımı ile otomatik görüntü sınıflaması

Cerrahi görüntülerin görüntü bölümlenmesi, insan vücudunun anatomik yapısının teşhisinde ve analizinde önemli rol oynamaktadır. Manyetik rezonans görüntüleme (MRG), vücudun iç kısımlarının yapısal bir görüntüsünü elde etmede yardımcı olur. Bu çalışma, öğrenme makinesi kullanılarak evre sınıflaması için otomatik bir destek sistemi geliştirmeyi ve beyin tümörünü bulanık kümeleme yöntemleriyle tespit etmeyi, böylece tümörün erken evrelerinde saptanmasını ve anatomik yapıları analiz etmeyi amaçlamaktadır [36].

Çalışmada üç aşama şunlardır [36]: Gri seviye eşdizilimlilik matrisi (GLCM) kullanılarak özellik çıkarımı ve olasılıksal sinir ağı-radyal tabanlı fonksiyon (PNN-RBF) kullanılarak [37] tümör sınıflandırması ve uzaysal bulanık c-ortalama (SFCM) metodu kullanılarak segmentasyon. Burada hızlı ayırık eğri dönüşüm işlemi, bir bilgisayar destekli tanı (CAD) sistemi için bir temel olarak kullanılacak bir görüntünün dokusunu analiz etmek için kullanılır. Radyal taban fonksiyonlu olasılıksal sinir ağı [37] otomatik bir beyin tümörü sınıflandırması yapmak için kullanılır. Benign, malign veya normal olan beyin tümörünün aşamasını otomatik olarak sınıflandırır. Sonra, SFCM kullanarak beyin anormalliğinin segmentasyonu ve tümörün ciddiyeti, saptanmış anormal bölgedeki tümör hücrelerinin sayısı kullanılarak analiz edilir. Çalışmanın blok diyagramı Şekil 1.3'de verilmiştir.



Şekil 1.3 : Çalışmanın blok diyagramı [36].

Çalışma, sinir ağı sınıflandırıcısı ve tümörün lekelenmesi ile erken evre anormallik tespiti için otomatik beyin görüntü sınıflandırmasının görüntü parçalanması ile yapıldığını ortaya koymuştur. Önerilen, çok seviyeli dönüşümün mümkün olduğu ayırık eğri dönüşümüne dayalı yeni bir tümör sınıflandırmasıdır. Nesne tanıma, radyal temel fonksiyonlu olasılıksal sinir ağı kullanılarak gerçekleştirilmiş ve model, hızlı ayırık eğri dönüşümü ve Haralick özellikleri analizi yardımıyla karakterize edilmektedir [37]. Burada anormal bölgenin alanını ölçmek için doğru tümör saptamasında uzaysal bulanık kümeleme algoritması etkili bir şekilde kullanılmıştır.

Bir deney vasıtasıyla sistem, çeşitli test numuneleri aşamasında daha iyi sınıflandırma doğruluğu sağladığını ve işlem için daha az zaman harcadığını kanıtlamıştır. Başka bir uzantı olarak, MATLAB'da 2 boyutlu resimleri 3 boyutlu hale dönüştürmek için bir toolbox geliştirilebilir. Ameliyat sırasında onkologlar için bir 3D görüntü yararlı olacaktır. Bundan dolayı, 2D görüntüsünün büyük bir dezavantajı olan MR görüntülerinin mikroskopik kısmını bile gösterebilir [36].

1.2.19 Sinir ağı tabanlı yöntemlerle beyin tümörü sınıflandırma

Manyetik rezonans görüntüleme (MRG) beyin tümörü görüntüleri Sınıflama, tümörlerin çeşitliliği ve karmaşıklığına bağlı olarak zor bir iştir. Bu çalışmada, manyetik rezonans insan beyin görüntülerinin sınıflandırılması için iki sinir ağı tekniği sunulmaktadır [38]. Önerilen sinir ağı tekniği, özellik çıkarma, boyut azaltma ve sınıflandırma olmak üzere üç aşamadan oluşur. İlk aşamada, ayırık dalgacık dönüşümü (DWT) kullanarak MR görüntüleriyle ilgili özellikleri elde edilmiştir. İkinci aşamada, manyetik rezonans görüntülerin (MRG) özellikleri, ilke bileşeni analizi (PCA) kullanılarak daha önemli özelliklere indirgenmiştir.

Sınıflandırma aşamasında, denetlenen makine öğrenmesine dayalı iki sınıflandırıcı geliştirilmiştir. Birinci sınıflandırıcı ileri besleme yapay sinir ağı, ikinci sınıflandırıcı ise geri yayılım yapay sinir ağına dayanan ikinci sınıflandırıcı temel almaktadır. Sınıflandırıcılar, denekleri normal veya anormal MRG beyin görüntüleri olarak sınıflandırmak için kullanılmıştır. Önerilen yaklaşım bu iki sinir ağı tekniğinin bir kombinasyonunu kullanır.

Yapay sinir ağları, fonksiyon yaklaşımı, özellik çıkarma, optimizasyon ve sınıflandırma gibi geniş bir uygulama yelpazesi için geliştirilmiştir. Özellikle, görüntü iyileştirme, bölütleme, kayıt, öznelik çıkarma ve nesne tanıma ve sınıflandırma için geliştirilmiştir. Bunların arasında, beyin tümörü sınıflaması gibi üst düzey işleme için kritik bir adım olduğundan nesne tanıma ve görüntü sınıflandırması daha önemlidir.

Görüntü bölümlenme için Çok Katmanlı Perceptron (MLP), Radyal tabanlı fonksiyon (RBF), Hopfield, Cellular ve Pulse-Coupled sinir ağları kullanılmıştır [39]. Bu ağlar, ileriye besleme (ilişkisel) ve geri bildirim (otomatik ilişkilendirmeli) ağlar olarak kategorize edilebilir [38].

1.3 Hipotez

Beyindeki anormallikler tomografi ünitesinde oluşan görüntülerde; temel olarak normal beyin görüntüsüne göre farklılıkların tespiti ve bölgesel piksel değerlerinin yorumlanması suretiyle tespit edilmektedir. Görüntü işleme algoritmaları vasıtasıyla öncelikli olarak anormal piksel değerleri belirginleştirebilir. Bir başka deyişle normal bir görüntüyle olan ayrıklığı derinleştirilebilir. Hastalıklı ve sağlıklı görüntüler daha izole edilmiş sınıflar halini alır. Böylece görüntü tanıma ve makine öğrenmesi algoritmaları aracılığıyla karşılaştırma ve algılama sağlanabilir. Dolayısıyla temel beyin tanılarının otomatik tespiti belirtilen yöntemlerle mümkün hale getirilebilir.

2. MATERYAL VE YÖNTEM

2.1 Bilgisayarlı Tomografi

Bilgisayarlı Tomografi (BT) görüntüleme, yunanca tomos (dilim, kesit) ve graphia (grafik, açıklama) kelimelerinin birleşiminden oluşmaktadır [40]. Bilgisayarlı Tomografi, 1972 yılında İngiltere EMI laboratuvarlarında görev yapan İngiliz mühendis Godfrey Hounsfield [41] ve Massachusetts Tufts Üniversitesinde görevli fizikçi Allan Cormack [42] tarafından keşfedilmiştir. Hounsfield, sonrasında tıp ve bilime katkılarından dolayı Nobel Barış Ödülü almıştır. 1974 ile 1976 arasında kliniklere kurulumu yapılmıştır. Şekil 2.1’de görülen ilk tarayıcılar beyin görüntülemesi yapmaktayken 1976 yılı sonunda tüm vücudu tarayabilen BT sistemleri kliniklerde bulunmaya başlamıştır.



Şekil 2.1 : Siretom beyin tarayıcısı, 1974.

BT 1980’lerde daha da yaygınlaşmıştır. Günümüze gelindiğinde 2015 yılsonu itibariyle OECD ülkelerinde 1.000.000 kişi başına ortalama 22,5 BT düşerken Türkiye de bu değer 14,1 dir [43]. Hounsfield’in EMI laboratuvarlarında geliştirdiği ilk BT cihazıyla bir tarama ya da bir kesit için kullanılacak ham veriyi elde etmek saatler, ham veriden tek bir görüntü elde etmek ise günler alıyordu. Günümüzde kullanılan

çok kesitli BT cihazları 640 adet kesiti 275 msn içerisinde ve 512 x 512 matrislik bir görüntüyü (Şekil 2.2) 1 saniyeden daha az bir sürede oluşturabilmektedir [44].



Şekil 2.2 : 512x512'lik beyin tomografi görüntüsü.

Günümüz BT tarayıcıları ile tüm vücut (80 adet 10 mm kesit) ile 5 saniye gibi kısa bir sürede taranabilmektedir [44]. 40 yıllık gelişim süreci boyunca hasta konforunda, tarama hızında, çözünürlükte büyük gelişmeler kaydedilmiştir. BT çekim süreleri kısalırken, daha çok bölge daha kısa sürede taranabilmektedir. Hızlı çekim süresi sayesinde hastanın sebebiyet verebileceği bozulmalar engellenebilmektedir. Tüm geliştirme faaliyetlerinin amacı mümkün olan en düşük seviyede X-ışını dozu vererek doğru tanı için görüntü kalitesini yükseltmektir [45].

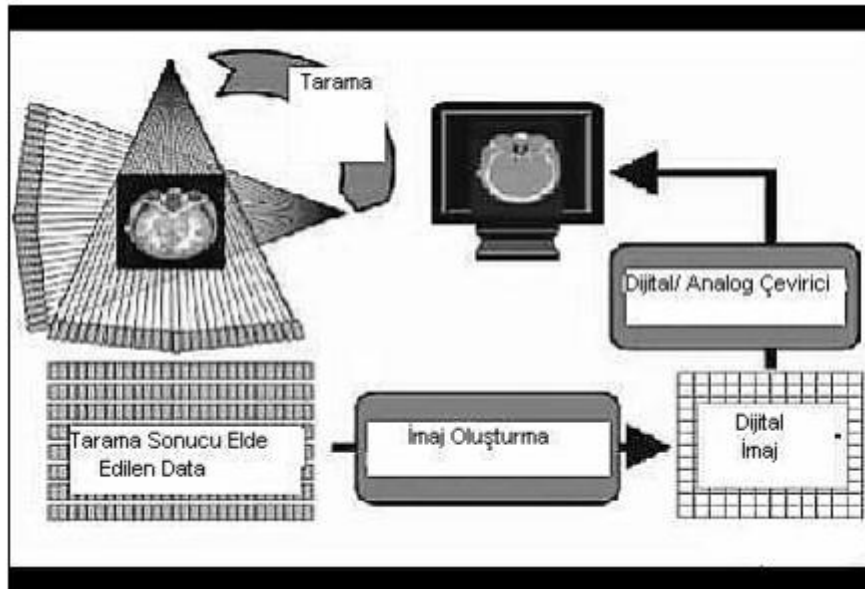
2.1.1 Bilgisayarlı tomografinin genel yapısı

Bilgisayarlı tomografi, geleneksel X-ışını görüntülemesinden pek çok yönden farklıdır. Görüntünün oluşum şekli başlıca farktır. Bilgisayarlı tomografi görüntüsünün oluşması çok aşamalı bir süreçtir. Görüntü oluşumu tarama adımı ile başlamaktadır. Bu adım sırasında, görüntülenen vücut kesitinden geçen X-ışını demetinin izdüşümü alınır. Bir dizi dedektör kesite yayılan radyasyonu ölçer. Dedektörler vücut kesitine ait görüntünün bütünü değil, sadece tek yönden bir izdüşümünü alabilmektedir [46]. İzdüşüm verileri, her bir dedektörün ölçümünden meydana gelir. Bütün bir görüntünün oluşması amacıyla yeterli bilginin elde edilmesi için X-ışını demeti farklı açılardan görüntü elde etmek üzere vücut kesitinin çevresinde


döndürülür. Genelde, birkaç yüz görüntü alınır ve her bir görüntünün izdüşüm bilgisi bilgisayar hafızasında tutulur.

Tarama sırasında yapılan izdüşüm ölçümlerinin toplam sayısı, görüntü sayısı ve her bir görüntü içindeki ışın sayısının bir sonucudur. Operatörün seçtiği tarama parametreleri ve tarama mekanizmasının dizaynına bağlı olarak bir kesitin toplam tarama süresi 1-15 saniye arasında değişebilmektedir. Temel olarak, görüntü kalitesi tarama süresinin artırılması vasıtasıyla iyileştirilebilir.

Görüntü oluşumunda ikinci adım Şekil 2.3'de olduğu gibi görüntünün geri oluşturulmasıdır [45]. Bu işlem BT sisteminin bir parçası olan bilgisayar tarafından gerçekleştirilir [47]. Şekil 2.4'da bilgisayarın BT görüntüleme sistemindeki yeri gözükmektedir. Görüntü geri oluşturma, her bir görüntüye ait tarama verisinin dijital görüntüye dönüştürüldüğü matematiksel bir süreçtir.



Şekil 2.3 : Tarama sonucu elde edilen dataların işlenmesi [45].



Şekil 2.4 : Bilgisayarın BT görüntüleme sistemindeki yeri [45].

Görüntü; resim elemanları ya da pikseller dizisi içinde yapılandırılır. Her bir piksel, sayısal değer ile temsil edilir [40]. Bu değer, ilgili hacimsel elemanın yani dokunun yoğunluğu ile alakalıdır. Geri oluşturma, görüntünün karmaşıklığına ve bilgisayarın teknik spesifikasyonlarına bağlı olarak birkaç saniye sürebilir. Sonrasında sayısal görüntü, bilgisayar hafızasında saklanır.

Son adım, sayısal görüntünün, direkt izlenmesi ya da filme kaydedilmesi için video görüntüsüne dönüştürülmesidir. Sayısal verileri analog verilere dönüştürmeye yarayan elektronik kısımlar bu adımı gerçekleştirir. Piksel sayı değerleri ile görüntüdeki parlaklık ya da gri gölge arasındaki ilişki operatörün seçtiği pencere seviyeleri ile belirlenir. Görüntülenen resmin parlaklık ve karşıtlığını, üst ve alt pencere seviyeleri seçerek ayarlamak mümkündür. Pencere ayarları tüm gri skala resme yayılan BT sayı aralığını belirler [45].

2.1.2 Bilgisayarlı tomografinin tıbbi uygulamaları

Diğer tıbbi görüntüleme tekniklerinden farklı olarak geleneksel X-ışını görüntüleme gibi BT direkt görüntülemenin yanında yumuşak doku farklılıklarını da görüntüleyebilmektedir [45]. Bunlardan bazıları bağırsak, akciğer, yağ dokusu şeklindedir. Lezyon, tümör, metastaz gibi oluşumların büyüklüklerinin ve

lokasyonlarının araştırılmasında da kullanılmaktadır. Baş ve beyindeki tümörler, kan damarlarında bulunan bozukluklar, karıncık genişlemeleri, kan pıhtılaşması, göz kaslarındaki ve bir çok vücut anormallikleri görüntülenmektedir. BT tarama zamanının hızlı olması nedeniyle hasta hareketlerinden ve solunumundan etkilenen tüm bölgelerde görüntülemeyi kolaylaştırmaktadır. Akciğerde nodüler yapıların görüntülenmesi örnek olabilir.

Bilgisayarlı tomografi, radyoterapi tedavilerinin planlanmasında yine temel olarak başvurulmuş görüntüleme yöntemidir. Ayrıca kanser tedavilerinde tümörün tedaviye nasıl cevap verdiğinin araştırılmasında da kullanılmaktadır. BT görüntüleme yumuşak doku görüntülemesinde yüksek çözünürlük sağlamaktadır. Bu özelliği sayesinde BT ortopedi alanında sık olarak kullanılmaktadır [45].

Kemiksi yapıların, vertebral disklerin (Şekil 2.5), omuz, kalça, omurga gibi kompleks birleşimlerin görüntülenmesinde kolaylık sağlamaktadır. Görüntü tamamlama özelliği mevcuttur. Bu sayede üç boyutlu görüntüleme ile cerrahlara daha da kaliteli görüntüler sağlamaktadır.



Şekil 2.5 : BT bel vertebra görüntüsü.

Yüz travmalarında üç boyutlu bilgisayarlı tomografi yoğunlukla kullanılan bir yöntemdir. BT'nin basit ve çok hızlı kullanımı acil durumlarda, hayati tehlikesi olan travmalı hastaların patolojik olarak incelenmesi ve ameliyata karar verilmesinde hekimlere kolaylık sağlamaktadır.

Sürekli ve tam olarak BT hacimlerinin elde edilebilmesi; kan damarlarının tanı ve tedavisinde anjio BT'nin kullanımını yaygınlaştırmıştır. Anjio BT ile birlikte böbrek atardamarı, karın aortik aneurysm, karotis damarları ve kalp damarları minimum karışma ile rahatlıkla görüntülenebilmektedir [45]. Şekil 2.6'da bilgisayarlı tomografi ile elde edilen anjio görüntüsü verilmiştir.




Şekil 2.6 : BT anjio görüntüsü.

BT'de toplam elde etme süresinin kısa olması karaciğerin farklı kontrastlarda görüntülenmesini mümkün kılmaktadır. Çoklu-faz olarak anılan bu çalışma sayesinde karaciğerdeki lezyonlara göre tedavi tipi belirlenebilmektedir.

2.1.3 Görüntü oluşturma

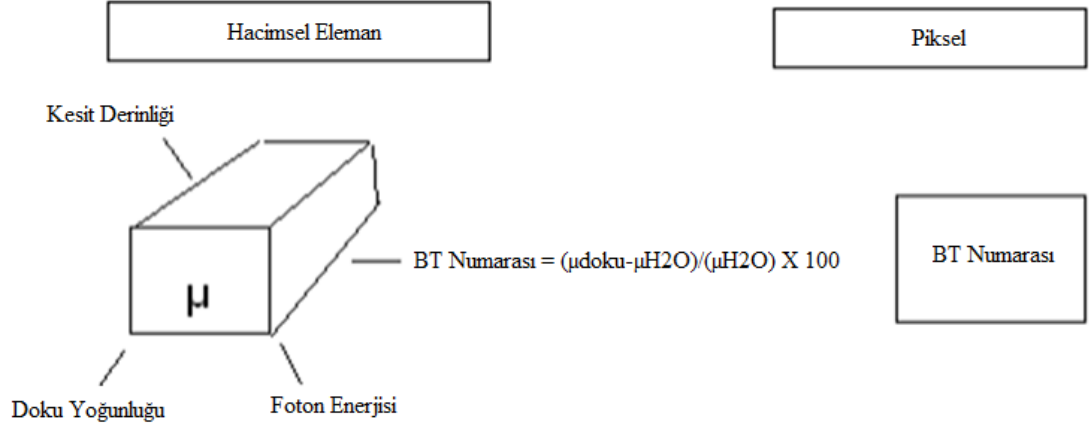
Taranan hasta vücuduna ait bölge boyunca geçerek zayıflayan X-ışınlarından elde edilen izdüşüm ölçümleri dijital ortama aktarılır. Görüntü; piksel elemanlarından oluşan dizilerle ifade edilir. Boyutlar 64x64 pikselden 512x512 piksele değişmektedir. Operatör çekim öncesi matris boyutunu seçer. Piksel boyutu ise görüntü kalitesinde önemli bir unsurdur. Her bir piksel gerçekte vücudun görüntülenen bölümündeki bir hacim elemanını yansıtmaktadır. Şekil 2.7'de de görüldüğü gibi matris boyutu, kesit kalınlığı ve görüntülenen alan hacim elemanının boyutunu etkiler. Hacimsel olan bölge matris boyutuna bölünür. Örnek olarak görüntülenen 25,4 cm'lik 256 matrislik alan 1mm'lik derinlik ve uzunluğa sahip doku hacimsel elemanı yaratmaktadır. Her bir hacim elemanının boyutu, matris boyutunda veya görüntülenen alanda olacak değişikliklerden etkilenmektedir.

Yeniden oluşturulan görüntüde, her bir piksel bir hacimsel elamanının lineer zayıflama katsayısına bağlı nümerik olarak ifade edilmektedir. Yeniden oluşturma işlemi ilk önce hacim elemanındaki zayıflama katsayılarının hesaplanması ve daha sonra bu bilgiyi görüntüdeki piksel değerine çevirme sistemine dayanmaktadır. Çoğu BT sistemi Housfield birimlerini kullanmaktadır. Su BT sayısı belirlemede en çok kullanılan maddedir. Suyun BT sayısı = 0 olarak kabul edilmektedir [45]. Zayıflama katsayıları sudan küçük olanlar ise negatif, büyük olanlar pozitif BT sayısına sahiptir. Bu ilişki Şekil 2.8’de ayrıntılarıyla gösterilmiştir.



Şekil 2.7 : Hacimsel eleman boyutunun bağlı olduğu parametreler [45].

BT cihazları dokularla Compton etkileşimi için genellikle yüksek gerilimlerde çalışmaktadır. Compton etkileşimlerini lineer zayıflama katsayıları metal yoğunluğuna göre de değişmektedir. Bu nedenle yumuşak dokularda BT sayıları doku yoğunluğu ile birlikte direkt alakalıdır.




Şekil 2.8 : Hacimsel eleman zayıflama katsayısı μ ile piksel (BT numarası) arasındaki ilişki [45].

Sistem kalibrasyon faktörleri ve kullanılan farklı X-ışını enerjisi (kV ve filtreleme) aynı dokunun farklı çekimlerinde farklı BT sayısı vermesine neden olmaktadır [45]. Aynı BT cihazından alınan belli bir dokuya ait BT sayıları zaman içerisinde görüntülenen görüntüdeki yerine göre değişebilmektedir.

2.2 Beyin Kanaması

Beyin kanaması; beyni besleyen damarların yırtılması (rüptür) ve damar dışına sızan kanın yırtığın olduğu bölgede göllenmesidir [48]. Beyin kanaması sadece bir damarda oluşabileceği gibi aynı anda birkaç damarda birden meydana gelebilir. Beyin kanaması travma sonucunda veya kendiliğinden (spontan) gelişebilir [49]. Yırtılan damarın beslediği bölge yırtılmadan sonra beslenemediği için, kanın göllendiği bölge göllenmenin neden olacağı basınçtan dolayı hasar görebilir, hatta tamamen çalışamaz duruma gelebilir.

Beyin kanamasını tespit etmek için kullanılan en iyi yöntem bilgisayarlı tomografi (BT) incelemesidir. Şekil 2.9’da beyin kanaması geçiren bir hastaya ait BT görüntüsü verilmiştir. Bazı durumlarda manyetik rezonans görüntüleme (MRG) yönteminde kullanılabilir. Beyin kanaması tıbbın en acil ve riskli durumlarından birisidir. Kısa sürede ölüm veya felce yolaçabildiğinden çok acil müdahale gerektirebilir.



Şekil 2.9 : Beyin kanamasına ait örnek BT görüntüsü.

Kanama sonrasında beyinde hasar meydana gelirse beyin hasar gören bölgesinin kontrol ettiği organlarda fonksiyon kayıpları veya felç görülebilir. Örneğin; beyinin görme merkezi hasarlıysa görme duyusunu kısmen ya da tamamen kaybedilebilir, bacağı kontrol eden bölge hasarlıysa bacakta kısmen ya da tamamen felç oluşabilir. En tehlikelisi de kanamanın beyin sapına yakın bölgelerde olmasıdır. Çünkü beyin sapındaki bazı alanlar kan basıncı, kalp hızı ve solunum gibi birçok hayati fonksiyonların düzenlenmesinden sorumludur ve beyin sapının hasar görmesi bu hayati fonksiyonların kaybına yol açabilir [48].

Beyin damarları yaş ilerledikçe yıpranırlar ve elastik özelliklerini kaybederler. Bu nedenle özellikle tansiyon yüksekliği olan yaşlı insanlarda sıklıkla yırtılarak beyin kanamaları oluştururlar. Genç yaşlarda beyin damarlarının zayıflaması sonucunda balonlaşması ve bu balonlaşan kısmın yırtılması neticesinde beyin kanaması oluşabilir. Damarlarda oluşan bu balonlara anevrizma adı verilir. Anevrizma rüptürü, yani anevrizma yırtılması her yaşta görülebilir. Önceden tespit edilmeleri mümkündür.

2.2.1 İntraserebral kanama

Beyin dokusu (serebrum, serebellum, beyin sapı) içerisindeki kanamadır. Bir intraserebral kanama kan aniden beyin dokusuna girip beyinde hasara yol açtığında oluşur [50]. İntraserebral kanama geçiren hastaların büyük çoğunluğunda orta veya ileri derecede bir arteriyel hipertansiyon vardır, ancak kanama ile hipertansiyon derecesi arasında her zaman anlamlı bir korelasyon (bağıntı) bulunmaz. Tedavi edilmemiş kronik hipertansiyon, travma, ileri yaş, sigara, yüksek miktarda alkol tüketimi ve hemofili gibi kanama bozuklukları intraserebral kanamaya yol açabilir.

2.2.2 İntraventriküler kanama

Beyin içindeki su dolu boşlukların (ventriküller) içerisine olan kanamadır. Genellikle travmalarda ve beyin içerisindeki damarlarda oluşan ani basınç artışlarında olur [48]. Yeni doğan bebeklerde, özellikle de erken doğumlarda ve annenin doğuramayarak doktor ya da ebe yardımıyla doğum yaptığı zor doğumlarda, doğum sırasında bebeğin beyinde intraventriküler kanama oluşabilir.

2.2.3 Epidural kanama

Beynin en dış zarı olan duramater ile kemik arasındaki kanamadır [48]. En sık nedeni kafa travmalarıdır. Beyin ve beyin sapı oluşan epidural kanamayla bası altında kalırsa koma tablosu gelişebilir. Epidural kanamalarda biriken kanın oluşturduğu beyin içi basınç artışı hastanın ölmesine neden olabilir. Epidural kanama hassas beyin alanlarını baskılayıp shifte (beynin orta hattının kaymasına) sebep olabilir.

2.2.4 Subdural kanama

Beynin duramater ile araknoid zarları arasındaki kanamadır [50]. En sık nedeni kafa travmalarıdır. Epidural kanama gibi klinik bulgular verir. Ama epidural kanama hızlı ilerlerken subdural kanama ise daha yavaş ilerler. Subdural kanama, travma sırasında aniden oluşabileceği gibi, travmadan çok sonra (haftalar, aylar sonra) yavaş yavaş ilerleyerek de gelişebilir. Aniden oluşana akut epidural kanama, sonradan (haftalar, aylar sonra) gelişene kronik epidural kanama denir.

2.2.5 Subaraknoid Kanama

Beyni saran zarların en iç tabakası olan araknoid zar ile beyin arasında oluşan kanamalardır [50]. En sık nedeni, beyin damarında bulunan bir anevrizmanın yırtılarak

kanamasıdır. Travma veya enfeksiyona da bağılı olarak da gelişebilir. Anevrizmalar kanamadıkları sürece, bir siniri ezmezse belirti vermez. Bu nedenle subaraknoid kanamalarda hasta çoğu zaman kanama öncesinde tamamen sağlıklıdır [48]. Bu tip hastalarda subaraknoid kanama aniden ortaya çıkan çok şiddetli başağrısı ile başlar. Kanama miktarına göre de nörolojik kayıplar oluşur. Kanama miktarı az ise başağrısı ve ensede sertlik dışında başka bir bulgu olmayabilir. Kanama miktarı fazla ise felçler, bilinç kaybı, epileptik nöbetler, yürüme ve duruş bozuklukları ve son olarak solunumun durması izlenebilir.

2.3 İnme ve Beyin Enfarktüsü

İnme beyni besleyen damarların etkilenmesi sonucunda yüz, kol ve bacakta felç ya da hissizlik, dengesizlik, konuşma ve anlama bozukluğu, baş dönmesi, çift görme, bir yarıyı görememe veya bilinç kaybı gelişmesiyle seyreden bir hastalıktır [51]. İnme dünya sağlık örgütü verilerine göre gelişmiş toplumlarda 2. gelişmekte olan toplumlarda 3. sıklıktaki ölüm nedenidir ancak özellikle oluşturduğu felç nedeniyle en sık sakatlığa yol açan hastalıktır. Daha önceden çalışan ve üretken olan bir birey inme sonrasında yatağa bağımlı ya da destekle yürüyebilen, artık çalışamaz durumda, tuvalet ve yemek yeme gibi günlük ihtiyaçlarını kendi başına gideremeyen, başkalarının bakımına muhtaç “tüketen” bir birey haline gelmektedir.

İnme iki şekilde görülebilir: Birinci ve en sık görülen inme tipi beyindeki bir damarın tıkanması sonucunda o damarın beslediği bölgedeki beyin hücrelerinin oksijensizlikten ve besinsizlikten ölmesi (gangren olması) şeklindedir. Bunlara tıp dilinde “serebral infarkt”, yani beyin enfarktüsü adı verilir [51, 52]. Şekil 2.10’da beyin enfarktüsü olan duruma ait BT görüntüsü verilmiştir. Bazen beyin enfarktüsleri gelişmeden günler-haftalar önce hastaları uyarabilir. Hastada 5 dakikadan-1 saate kadar sürüp tamamen düzelen konuşma bozukluğu, bir tarafta tutmama, uyuşma şeklinde bulgular görülebilir. Bunlara “Geçici İskemik Atak” adı verilir ve çok önemli bir uyarıdır [52]. Hemen hastaneye gitmeyi gerektirir.



Şekil 2.10 : Beyin enfarktüsüne ait örnek BT görüntüsü.

Geçici iskemik ataklar kalıcı ve hastanın hayatını kabusla çevirebilecek kalıcı bir inmenin “ben geliyorum” demesidir. Bunu çok büyük ve yıkıcı bir depresyon öncesindeki hafif öncü sarsıntılara benzetebiliriz. Ancak depresyonu önlememiz mümkün değilken bu uyarıların olduğu durumda erken teşhis ve tedavi ile serebral enfarktüsü önleyebiliriz.

İkinci tip inme ise beyin damarlarından birinde yırtılma olarak kanın beyin dokusuna sızması sonucunda gelişen beyin kanamalarıdır [51]. Bunlar çoğunlukla daha ölümcüldür.

2.4 Görüntü İyileştirme Yöntemleri


Görüntü filtreleme işlemleri genellikle görüntüdeki gürültüyü giderme, kontrastı keskinleştirme, konturları vurgulama ve kenarları algılama gibi amaçlarla kullanılmaktadır [53, 54].

Görüntü filtreleri doğrusal veya doğrusal olmayan olarak sınıflandırılabilir. Doğrusal filtreler, bir matris çarpımı kullanılarak gösterilebildiği için konvolüsyon filtreleri olarak da bilinirler. Eşik değerlendirme ve görüntü eşitlemesi, medyan filtrenin olduğu gibi doğrusal olmayan işlemlerin örnekleridir.

2.4.1 Median filtreleme


Medyan filtreleme, görüntülerden gelen gürültüyü gidermek için kullanılan doğrusal olmayan bir yöntemdir [53]. Gürültüyü giderirken kenarları korumada çok etkili olduğu için yaygın olarak kullanılır. Özellikle 'tuz ve biber' tipi gürültüyü ortadan kaldırmada etkilidir. Medyan filtre, görüntüyü piksel piksel hareket ettirerek çalışır, her değeri komşu piksellerin ortanca değeriyle değiştirir. Komşuların görüntülerine "pencere" adı verilir; bu pencere, tüm görüntü üzerinde 2 piksellik bir pikselin tüm görüntüsünde kayar. Medyan, önce tüm piksel değerlerini pencereden sayısal sıraya ve sonra da orta (medyan) piksel değeriyle değiştirilen pikselin değiştirilmesiyle hesaplanır.

Şekil 2.11'de tek boyutlu bir sinyal için median filtreleme örnek hesaplaması ve filtreleme sonrası çıkış sinyali verilmiştir.



Şekil 2.11 : Median filtreleme örnek hesaplama [53].

Şekil 2.12'de kanama durumu olan bir tomografi görüntüsünün median filtre uygulanmış ve uygulanmamış halleri mevcuttur.



Şekil 2.12 : Sırasıyla filtresiz ve median filtreli BT görüntüsü.

2.4.2 Ortalama filtreleme

Ortalama filtreleme, komşu pikseller arasındaki yoğunluk değişim miktarını azaltarak görüntülerin 'yumuşatılması' yöntemidir [53]. Ortalama filtre, görüntü boyunca piksel piksel hareket ettirerek çalışır; her değeri kendisi de dahil olmak üzere komşu piksellerin ortalama değeri ile değiştirir.

Olası bazı sorunlar mevcuttur. Çok temsil etmeyen bir değere sahip tek bir piksel, mahalledeki tüm piksellerin ortalama değerini önemli ölçüde etkileyebilir. Filtre komşusu bir kenar boyunca uzandığında, filtre kenardaki pikseller için yeni değerler enterpole edecek ve bu kenarı bulanıklaştıracaktır. Çıkışta keskin kenarlar gerekiyorsa bu bir sorun olabilir.

Şekil 2.13'de tek boyutlu bir sinyal için ortalama filtreleme örnek hesaplaması ve filtreleme sonrası çıkış sinyali verilmiştir.

$$x = \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 3 & 3 & 9 & 4 & 52 & 3 & 8 & 6 & 2 & 2 & 9 & 9 \\ \hline \end{array}$$

$$y[1] = \text{round}((3+3+9)/3) = 5$$

$$y[2] = \text{round}((3+9+4)/3) = 5$$

$$y[3] = \text{round}((9+4+52)/3) = 22$$

$$y[4] = \text{round}((4+52+3)/3) = 20$$

$$y[5] = \text{round}((52+3+8)/3) = 21$$

$$y[6] = \text{round}((3+8+6)/3) = 6$$

$$y[7] = \text{round}((8+6+2)/3) = 5$$

$$y[8] = \text{round}((6+2+2)/3) = 3$$


$$y[9] = \text{round}((2+2+9)/3) = 4$$

$$y[10] = \text{round}((2+9+9)/3) = 7$$

$$y = \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 5 & 5 & 22 & 20 & 21 & 6 & 5 & 3 & 4 & 7 \\ \hline \end{array}$$


Şekil 2.13 : Ortalama filtreleme örnek hesaplama [53].

Şekil 2.14’de tek boyulu bir sinyal için median ve ortalama filtrelerin davranışları gösterilmiştir.



Şekil 2.14 : Tek boyutlu sinyalin median ve ortalama filtreleme sonuçları [53].

Şekil 2.15’de kanama durumu olan bir tomografi görüntüsünün ortalama filtre uygulanmış ve uygulanmamış halleri mevcuttur.



Şekil 2.15 : Sırasıyla filtresiz ve ortalama filtreli BT görüntüsü.

2.4.3 Dönüşümler

En basit uzaysal alan işlemleri, komşuluğun sadece pikselin kendisinden ibaret olduğu durumlarda gerçekleşir [54]. Bu işlemler için T ifadesi kullanılır ve bu ifade gri seviye dönüşümüne ya da bir nokta işleme operasyonuna karşılık gelir. Nokta işleme operasyonları Denklem 2.1’deki formdadır.

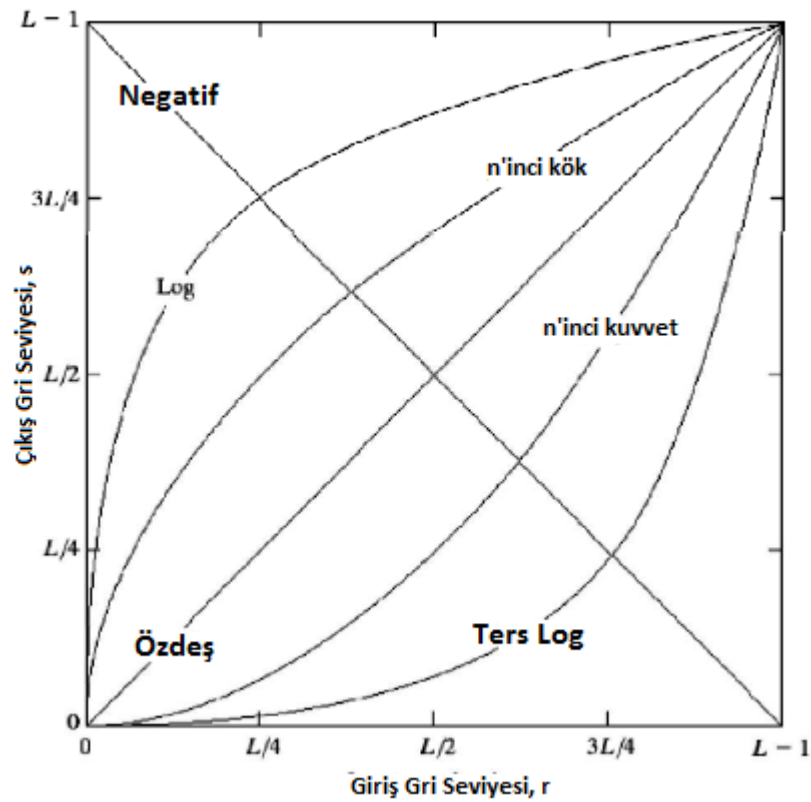
$$s = T(r) \quad (2.1)$$

Burada s işlenmiş görüntü piksel değerlerini, r orijinal görüntü piksel değerlerini ve T ise dönüşüm fonksiyonunu ifade etmektedir. Nokta işleme operasyonları arasında görüntünün negatifini alma, eşikleme dönüşümü ve yoğunluk dönüşümü bulunmaktadır [54].

Çok çeşitli gri seviye dönüşümleri bulunmaktadır. Ancak en çok kullanılan üç gri seviye dönüşüm aşağıdaki gibi sıralanabilir:

- 1-Linear (Negatif ya da özdeş)
- 2-Logaritmik (Log ya da ters log)
- 3-Power law (n'inci kuvvet ya da n'inci kök)

Şekil 2.16'da bu üç tip dönüşüm kombinasyonlarıyla beraber bir arada; giriş çıkış karakteristikleri belirtilerek gösterilmiştir.



Şekil 2.16 : Gri seviye dönüşümleri [54].

2.4.3.1 Logaritmik dönüşüm

Logaritmik dönüşüm, düşük giriş gri seviye değerlerinin dar bir aralığını daha geniş çıktı değerleri aralığına eşler [54]. Ters logaritmik dönüşümü ters dönüşümü gerçekleştirir. Log fonksiyonları, giriş gri seviyesi değerleri son derece geniş bir aralıkta olduğunda özellikle yararlıdır. Logaritmik dönüşümün genel formu Denklem 2.2 gibidir.

$$s = c * \log(1 + r) \quad (2.2)$$

Burada s işlenmiş görüntü piksel değerlerini, c sabit katsayı ve r orijinal görüntü piksel değerlerini ifade etmektedir.


2.4.3.2 Power law dönüşüm

Dönüşüm Denklem 2.3'teki şekilde formülize edilebilir [54].

$$s = c * r^\gamma \quad (2.3)$$


Burada s işlenmiş görüntü piksel değerlerini, γ kuvvet değeri ve r orijinal görüntü piksel değerlerini ifade etmektedir.

Çeşitli γ değerleri için çeşitli iyileştirme seviyeleri elde edilebilir. Şekil 2.17'de farklı γ değerleri için giriş ile çıkış arasındaki dönüşüm gösterilmiştir. Bu dönüşüm, dar bir karanlık giriş değer aralıklarını daha geniş bir çıkış değerleri aralığına eşler [54]. Bunun tam tersi de geçerlidir. Farklı ekran monitörleri görüntüleri farklı yoğunluk ve netlikte gösterir. Yani, her monitörde belirli gamma aralıklarıyla dahili bir gama düzeltilmesi bulunur ve bu nedenle iyi bir monitör, üzerinde en iyi kontrastı elde etmek için kullanıcıya en iyi deneyimi vermek için üzerinde görüntülenen tüm görüntüleri otomatik olarak düzeltir [55].



Şekil 2.17 : Farklı γ değerleri için power law dönüştürmeleri [54].

Şekil 2.18’de kanama durumu olan bir tomografi görüntüsünün power law dönüştürümü uygulanmış ve uygulanmamış halleri mevcuttur.




Şekil 2.18 : Sırasıyla dönüşümsüz ve $\gamma = 0,5$ power law dönüşümlü BT görüntüsü.

2.4.4 Histogram eşitleme

Bir resmin histogramı, görüntüdeki gri tonların dağılımını gösterir. Histogramlar bir çok uzaysal alanda işleme tekniğinin temelidir. Görüntü işleme, özellikle resim bölümlenmede çok yararlıdır [54]. Görüntü geliştirme için etkin bir şekilde kullanılabilir. Görüntü sıkıştırımda da faydalıdır.

Histogram eşitlemesi [56], görüntülerin görünümünü arttırmak için yaygın bir tekniktir. Diyelim ki ağırlıklı olarak karanlık bir görüntü var. Ardından, histogram gri tonlamanın alt ucuna doğru eğilir ve tüm görüntü ayrıntıları histogramın karanlık ucuna sıkıştırılır. Eğer daha homojen bir şekilde dağıtılan histogram üretmek için karanlık uçtaki gri seviyeleri uzatabilsek, görüntü daha net hale gelecektir. Bir görüntü için piksel değerleri 0 ve $L-1$ aralığında değişkendir. Giriş görüntüsünün olasılık yoğunluk fonksiyonu Şekil 2.19'da verildiği gibi $p_r(r)$ şeklinde olacaktır. Histogram eşitleme sonucunda oluşacak işlenmiş görüntünün yine Şekil 2.19'da görülen $p_s(s)$ şeklinde bir olasılık yoğunluk fonksiyonuna sahip olması hedeflenecektir [54]. Bu iki olasılık yoğunluk fonksiyonları arasında Denklem 2.4'deki gibi bir ilişki mevcuttur.




Şekil 2.19 : Histogram eşitleme öncesi ve sonrası olasılık yoğunluk fonksiyonları.

$$p_s(s)ds = p_r(r)dr \quad (2.4)$$

Burada $p_s(s)$ çıkış piksel değerlerinin olasılık yoğunluk fonksiyonu, $p_r(r)$ ise giriş piksel değerlerinin olasılık yoğunluk fonksiyonudur.

Şekil 2.20’de kanama durumu olan bir tomografi görüntüsünün histogram eşitleme uygulanmış ve uygulanmamış halleri mevcuttur.



Şekil 2.20 : Histogram eşitleme öncesi ve sonrası BT görüntüsü.

2.4.5 Kontrast iyileştirme

Kontrast iyileştirme işlemi biraz daha karmaşık bir süreçtir [57]. Kontrast iyileştirme işleminde ilk adım, Denklem 2.5’deki formülle kontrast düzeltme faktörünü hesaplamaktır.

$$F = \frac{259 * (C + 255)}{255 * (259 - C)} \quad (2.5)$$


Burada F kontrast düzeltme faktörünü, C değeri ise istenilen kontrast seviyesini belirtir. Algoritmanın doğru çalışması için kontrast düzeltme faktörü (F) değeri bir tamsayı olarak değil değişen nokta sayısı olarak saklanmalıdır.

Bir sonraki adım, gerçek kontrast ayarı yapmaktır. Denklem 2.6'daki formül bir görüntüye kontrast iyileştirme yapıldığını göstermektedir. Görüntünün giriş seviyeleri r, çıkış seviyeleri ise s ile ifade edilmektedir.

$$s = F(r - 128) + 128 \quad (2.6)$$

Burada s işlenmiş görüntü piksel değerlerini, F kontrast düzeltme faktörü ve r orijinal görüntü piksel değerlerini ifade etmektedir.

Şekil 2.21'de kanama durumu olan bir tomografi görüntüsünün kontrast iyileştirme uygulanmış ve uygulanmamış halleri mevcuttur.



Şekil 2.21 : Kontrast iyileştirme öncesi ve sonrası BT görüntüsü.

2.4.6 Gamma düzeltme

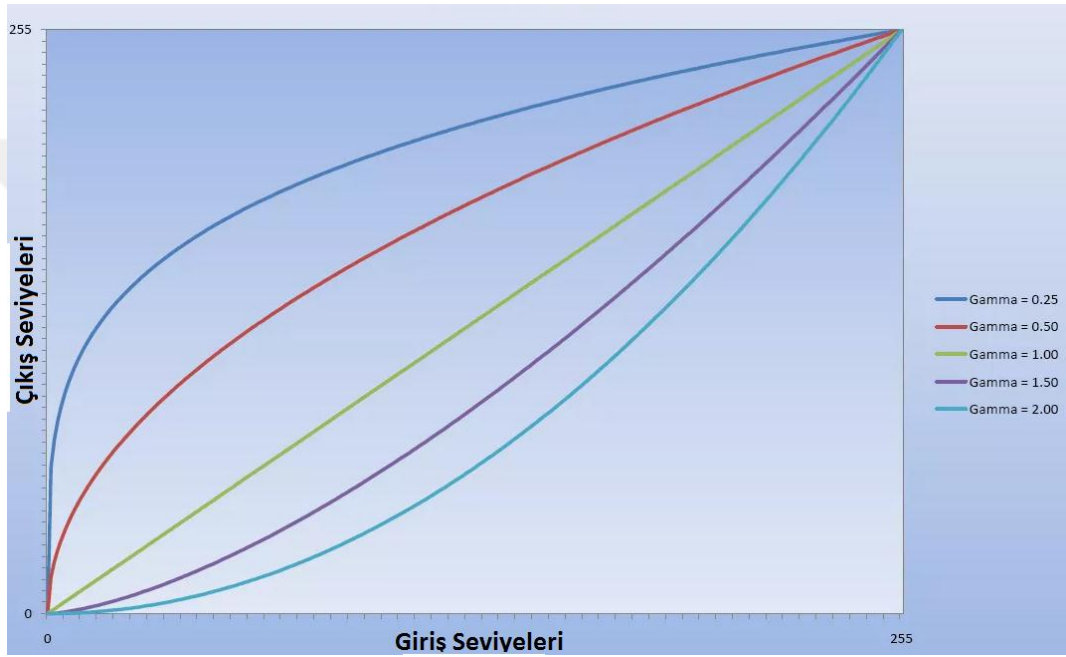
Yunan harfi ile temsil edilen gamma, bir giriş ile ortaya çıkan çıktı arasındaki ilişki olarak tanımlanabilir. Bu işlemde çıktı gama gücüne yükseltilecek girişle orantılıdır [58].

Elde edilen çıktıyı hesaplamak için formül Denklem 2.7'deki gibidir. Burada görüntünün giriş seviyeleri r, çıkış seviyeleri ise s ile ifade edilmektedir.

$$s = 255 * \left(\frac{r}{255}\right)^\gamma \quad (2.7)$$


Burada s işlenmiş görüntü piksel değerlerini, γ düzeltme katsayısı ve r orijinal görüntü piksel değerlerini ifade etmektedir.

Şekil 2.22'de farklı γ değerleri için giriş ile çıkış arasındaki dönüşüm gösterilmiştir.



Şekil 2.22 : Farklı γ değerleri için gamma düzeltmeleri [58].

Şekil 2.23'de kanama durumu olan bir tomografi görüntüsünün gamma düzeltme uygulanmış ve uygulanmamış halleri mevcuttur.




Şekil 2.23 : Gamma düzeltme ($\gamma = 0,3$) öncesi ve sonrası BT görüntüsü.

2.5 Yerel İkili Örüntü

Yerel ikili örüntü (LBP) operatörü, bir görüntüyü, görüntünün küçük ölçekli görünümünü tanımlayan; bir tamsayı etiket dizisi veya görüntüsüne dönüştüren bir görüntü operatörüdür [59]. Daha sonra, bu etiketler veya istatistikler, en yaygın olarak histogram, daha ileri görüntü analizi için kullanılır. Operatöre en çok kullanılan versiyonlar tek renkli hareketsiz görüntüler için tasarlanmıştır ancak renkli (çok kanallı) görüntüler ve videolar ile hacimsel veriler için de genişletilmiştir.

2.5.1 Temel yerel ikili örüntü

Ojala ve diğ. tarafından tanımlanan temel yerel ikili örüntü operatörü (LBP) [60], dokunun yerel olarak birbirini tamamlayıcı iki yönü, bir model ve gücü olduğu varsayımına dayanmaktadır. Bu çalışmada LBP, doku biriminin [61] yerel bir doku örüntüsünü tanımlamak için iki seviyeli bir versiyon olarak önerildi. Yerel ikili örüntü operatörünün orijinal hali, bir görüntünün 3×3 piksel bloğunda çalışır. Bu bloktaki pikseller, merkez piksel değeri ile eşiklenir, karesi alınır ve daha sonra, merkez piksel için bir etiket elde etmek üzere toplanır. Komşular 8 pikselden oluştuğundan, merkezin ve komşu piksellerin göreceli gri değerlerine bağlı olarak toplam $2^8 = 256$ farklı etiket elde edilebilir. Şekil 2.24’de örnek bir girişe ait LBP görüntüsü ve histogramı verilmiştir.



Şekil 2.24 : Örnek bir giriş görüntünün LBP görüntüsü ve histogramı [59].

2.5.2 Genel LBP operatörünün türetilmesi

Özgün yayından birkaç yıl sonra, yerel ikili örüntü operatörü, Ojala ve diğ. tarafından daha genel bir revize edilmiş biçimde sunulmuştur [62]. 3×3 piksel blokta 8 piksel kullanan temel LBP'nin aksine, operatörün bu genel formülasyonu, komşuluk boyutunu veya numune alma noktası sayısını sınırlamamaktadır. Genel LBP formülasyonu Denklem 2.8'de verilmiştir [62, 63].

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2.8)$$

Burada, g_p , P örnekleme noktalarının eşit aralıklarla çevrilmiş bir çevredeki bir örnekleme noktasının gri değerini, g_c işleme tutulan x_c, y_c noktasının gri değeri ve R , nokta (x, y) etrafındaki yarıçap değerini belirtmektedir. Temel LBP'de olduğu gibi, eşik değerli farkları ikinin kuvvetleriyle ağırlıklandırılarak toplanır. $LBP_{P,R}$ operatörü olarak tanımlanır [59].


Birçok doku analiz uygulamasında, giriş görüntüsünün rotasyonu ile değişmeyen veya sağlam olan özelliklerin olması arzu edilir. $LBP_{P,R}$ örüntüleri merkez piksel etrafında dairesel örnekleme yapılarak elde edildiğinden, giriş görüntüsünün rotasyonu iki etkiye sahiptir: her yerel komşuluk diğer piksel konumuna döndürülür ve her komşuluk içinde merkez noktasını çevreleyen daire üzerindeki örnekleme noktaları farklı bir yöne döndürülür.

2.5.3 LBP etiketlerinin eşlemeleri: uniform örüntüler

Orijinal operatöre yapılan bir başka uzantı, uniform örüntülerini kullanır [62]. Bunun için, bir örüntünün bir tekdüzelik önlemi kullanılır: U ("örüntü"), bit örüntü dairesel olarak kabul edildiğinde, 0'dan 1'e veya bitisli olarak bitwise geçişlerin sayısıdır. Yerel bir ikili örüntü, uniformite ölçüsü en fazla 2 ise uniform olarak adlandırılır. Örneğin, 00000000 (0 geçiş), 01110000 (2 geçiş) ve 11001111 (2 geçiş) örüntüleri uniform olurken 11001001 örüntüleri (4 geçiş) ve 01010011 (6 geçiş) değil. Uniform LBP haritalamada, her bir uniform örüntü için ayrı bir çıktı etiketi bulunur ve tüm düzensiz örüntüler tek bir etikete atanır. Böylece, P bit örüntüleri için haritalama için farklı çıktı etiketlerinin sayısı $P(P - 1) + 3$ 'tür. Örneğin, tekbiçimli haritalama, 8 örnekleme noktası komşuluğu için 59 çıktı etiketi (Şekil 2.25) ve 16 örnekleme komşuluğu için 243 etiket üretir.


Uniform olmayan örüntülerin atılmasının nedenleri iki katlıdır. Birincisi, doğal görüntülerdeki yerel ikili örüntülerin çoğu uniformdur. Doku görüntüleri ile yaptıkları deneylerde, (8, 1) komşuluğu kullanırken ve (16, 2) komşuluk içinde yaklaşık %70 için uniform kalıpların tüm kalıpların %90'ından azını oluşturduğunu fark etmiştir. Yüz imgelerine sahip deneylerde [64], (8, 1) komşuluktaki örneklerin %90.6 'sının, (8, 2) komşuluktaki örneklerin %85.2' sinin uniform olduğu bulunmuştur.

Uniform kalıpları düşünmenin ikinci nedeni istatistiksel sağlamlıktır. Olası tüm örüntüler yerine uniform kalıpların kullanılması birçok uygulamada daha iyi tanıma sonuçları üretmiştir [59]. Uniform kalıpların daha kararlı olduğu, mesela gürültüye daha az maruz kalması ve sadece uniform kalıplar olası LBP etiketleri sayısını önemli ölçüde daha düşük ve güvenilir dağılım tahminleri sağlamaktadır.



Şekil 2.25 : (8,R) komşuluk için 58 farklı uniform örüntü [59].

Uniform kalıplar, LBP yönteminin, geleneksel olarak farklı istatistiksel ve yapısal doku analiz örüntülerine birleştirici bir yaklaşım olarak görülmesini sağlar [63]. Her piksel, yerel komşuluk ile en iyi eşleşen doku kökünün kodu ile etiketlenmiştir. Böylece her LBP kodu bir mikro metin olarak kabul edilebilir. LBP tarafından tespit edilen yerel kökler; lekeler, düz alanlar, kenarlar, kenar uçları, eğriler ve benzeri yerleri içerir. Bazı örnekler Şekil 2.26'da gösterilmektedir. Şekilde, bir olanlar siyah, sıfırlar ise beyazdır.



Şekil 2.26 : LBP tarafından tespit edilen farklı doku kökleri [59].

Yapısal ve istatistiksel yaklaşımların kombinasyonu, mikro metinlerin dağılımının istatistiksel yerleştirme kuralları olarak görülebmesinden kaynaklanmaktadır. Dolayısıyla, LBP dağılımı, yapısal analiz yönteminin her ikisine de sahiptir. Bunlar doku kökleri ve yerleşim kurallarıdır. Öte yandan, dağılım yalnızca doğrusal olmayan bir şekilde filtrelenmiş bir görüntünün istatistiğidir ve yöntemi istatistiksel olarak açıkça ortaya koymaktadır. Bu nedenlerden dolayı, LBP dağılımı, istatistiksel ve yapısal yöntemlerin normal olarak ayrı ayrı uygulandığı çok çeşitli farklı dokuları tanımda başarılı bir şekilde kullanılabilir.


Kontrast, dokunun genellikle insan görüşü için çok önemli bir ipucu niteliğindeki özelliğidir. Ancak LBP operatörü tek başına, gri seviye farklarının büyüklüğünü tamamen göz ardı etmektedir. Birçok uygulamada, örneğin endüstriyel görsel kontrollerde, aydınlatma doğru bir şekilde kontrol edilebilir. Bu gibi durumlarda, yalnızca gri tonlamalı değişken bir doku operatörü yararlı bilgileri boşa çıkarabilir ve gri ölçekli bağımlı bilgi ekleme yöntemi doğruluğunu artırabilir. Ayrıca, görüntü parçalama gibi uygulamalarda, kademeli olarak aydınlatma değişiklikleri, gri ölçekli değişmez bir yöntem kullanılmasını gerektirebilir [59, 65].

Daha genel bir bakış açısıyla, doku sadece doku düzenleri ile değil, örüntülerinin gücü ile ayırt edilir. Doku; mekânsal yapı (örüntü) ve kontrast (örüntülerin kuvveti) olmak üzere iki ortogonal özellik vasıtasıyla iki boyutlu bir fenomen olarak kabul edilebilir. Örüntü bilgileri gri skaladan bağımsızdır, aksine kontrast öyle değildir. Öte yandan, kontrast dönme tarafından etkilenmez, ancak örüntüler etkilenir. Bu iki özellik birbirlerini çok faydalı bir şekilde takviye eder. LBP operatörü başlangıçta sadece doku "miktarının" gri ölçekli bir ölçüsünü tamamlamak amacı için tasarlanmıştır. [60]'da LBP kodlarının ortak dağılımı ve yerel bir kontrast ölçüsü bir doku tanımlayıcısı olarak kullanılmaktadır.

2.5.4 Çok ölçekli LBP

Orijinal LBP operatörünün önemli bir kısıtlılığı, küçük mekansal destek alanının olmasıdır. Yerel bir 3×3 komşulukta hesaplanan özellikler, bazı dokuların baskın özellikleri olabilecek büyük ölçekli yapıları yakalayamaz [59]. Bununla birlikte, komşu LBP kodları tamamen birbirinden bağımsız değildir.

Şekil 2.27, üç bitişik dört-bit LBP kodunu görüntülemektedir. En soldaki koddaki ilk bitin sıfır olduğunu varsayarsak, sağdaki kodun üçüncü biti bir olmalı. Benzer şekilde, kodun merkezindeki ilk biti ve en sağdaki grubun üçüncü biti, ya farklı olmalı ya da ikisine de eşit olmalıdır. Şeklin sağ yarısı, kodların imkansız bir kombinasyonunu göstermektedir. Siyah bir disk, bir numunenin gri seviyesinin merkezinkinden daha düşük olduğu anlamına gelir. Her bir LBP kodu, bitişik olası kod kümesini sınırlar ve tek bir kodun "etkin alanı"nın aslında 3×3 pikselden biraz daha fazla olmasını sağlar. Bununla birlikte, operatör, örneğin bakış açılarını veya aydınlatma yönlerini değiştirerek, dokudaki yerel değişikliklere karşı çok güçlü değildir. Bu nedenle daha geniş bir alansal destek alanına sahip bir operatöre sık sık ihtiyaç duyulmaktadır.




Şekil 2.27 : Üç bitişik LBP_{4,R} komşuluk ve imkansız bir kod kombinasyonu [65].

Alansal destek alanını genişletmenin basit bir yolu, N LBP operatörleri tarafından sağlanan bilgileri, değişen P ve R değerleriyle birleştirmektir. Bu şekilde, bir resimdeki her piksel N farklı LBP kodu alır. En doğru bilgi bu kodların ortak dağılımı kullanılarak elde edilebilir.

2.5.5 Merkezi simetrik LBP

İlgi alanı tanımlaması için merkezi-simetrik yerel ikili örüntüler (CS-LBP) [66] geliştirildi. CS-LBP, bölge tanımlayıcılarında kullanılması daha iyi kısa histogramlar üretmek için daha az sayıda LBP etiketini amaçlamaktadır. Ayrıca, CS-LBP, düz görüntü bölgelerinde daha yüksek kararlılığa sahip olacak şekilde tasarlanmıştır.

CS-LBP'de piksel değerleri merkez piksele değil, karşı piksele merkez piksele göre simetrik olarak karşılaştırılır. Şekil 2.28'de sekiz komşusu olan bir örnekleme verilmiştir.



Şekil 2.28 : 8 piksel komşuluk için LBP ve CS-LBP özellikleri [66].

CS-LBP operatörüne dayanan Heikkilä ve diğ. ilgi bölgeleri için eksiksiz bir CS-LBP tanımlayıcı önermiştir. Tanımlayıcı yapımındaki adımlar aşağıda özetlenmiştir. [66]

1. Bilinen büyüklük ve oryantasyona sahip ilgi bölgesinin tespit edildiği varsayılarak bölge belirli bir boyut ve oryantasyona göre normalize edilmiştir. [66] 'de, normalize edilmiş bölgenin boyutu olarak 41×41 piksel önerilmiştir.
2. Normalleştirilmiş bölgeye CS-LBP operatörü uygulanır.
3. Bölge hücrelere bölünmüştür. 3×3 veya 4×4 Kartezyen ızgaraları önerilmektedir.
4. CS-LBP etiketlerinin histogramı, her hücre içinde oluşturulmuştur. Sınır etkilerinden kaçınmak için, bilinear enterpolasyon, her bir etiketin ağırlığını en yakın dört hücre arasında paylaşmak için kullanılır.
5. Tanımlayıcı elde etmek için histogramlar birleştirilir. Tanımlayıcı daha sonra birim uzunluğuna normalize edilir, önceden belirlenmiş bir eşliğin üzerindeki değerler kırılır ve nihayet tanımlayıcı birim uzunluğuna yeniden normalize edilir.

Çeşitli bilgisayar görme problemleri ve uygulamalarında LBP yöntemlerinin başarısı farklı versiyonlar üzerine çok yeni araştırmalara ilham kaynağı olmuştur [59]. Esnekliği nedeniyle, LBP yöntemi farklı problem türlerinin gereksinimlerine uygun hale getirilmesi için kolayca değiştirilebilir. Temel LBP'nin de ele alınması gereken bazı sorunları vardır. Bu nedenle sağlamlık ve ayırmacı gücünü artırmak amacıyla LBP'nin birkaç uzantısı ve modifikasyonu önerilmiştir. Verilen bir uygulama için uygun bir yöntem seçimi, ayırt edici güç, hesaplama verimliliği, aydınlatma ve diğer

varyasyonlara dayanıklılık ve kullanılan görüntüleme sistemi gibi birçok faktöre bağlıdır.

2.6 Destek Vektör Makineleri

Destek vektör makineleri (SVM'ler), ikili sınıflandırma için kullanılan bir öğrenme yöntemidir [67]. Temel fikir, d-boyutlu veriyi iki sınıfına mükemmel biçimde ayıran bir hiper düzlem bulmaktır. Bununla birlikte, örnek veriler çoğunlukla lineer olarak ayrılabilir olmadığından, SVM, verilerin ayrılabilir yüksek boyutlu bir alana verdiği bir "çekirdek (kernel) kaynaklı özellik alanı" kavramını ortaya koymaktadır. Tipik olarak, böyle bir alanda hareket etmek, hesaplamayla ilgili ve aşırı oturma gibi sorunlara neden olur. SVM'lerde kullanılan kilit anlayış, yüksek boyutlu alanın doğrudan ele alınması gerekmemesidir (yalnızca bu alan içindeki nokta ürünü için formül gerekli) ve bu da yukarıdaki endişeleri ortadan kaldırır. Ayrıca, hiçbir ölçüt olmayan sinir ağı gibi diğer öğrenme yöntemlerinin aksine, SVM'lere ait VC-boyutu (görünmeyen veriler üzerinde sistemin iyi performans göstermesinin bir ölçüsü) açıkça hesaplanabilir. Genel olarak, SVM'ler sezgisel, teorik açıdan sağlam ve pratik olarak başarılı olduklarını göstermektedir [68]. SVM'ler regresyon görevlerini çözmek için de genişletilmiştir (sistem, "evet / hayır" sınıflaması yerine sayısal bir değer üretmek için eğitilerek).

SVM'lerin detaylı tanımlamaları [69] çalışmasında yer almaktadır. Konunun yetmişli yılların sonunda başladığı söylenebilir olsa da [70], yakın dönemde artan bir ilgiyle karşılanmaktadır.

Elimizde L adet eğitim örnekleri olduğunu varsayalım; $\{x_i, y_i\}; i = 1, \dots, L$. Burada her örnekte d adet giriş ($x_i \in \mathbb{R}^d$) ve iki değerden biri olan sınıf etiketi ($y_i \in \{-1, 1\}$) bulunur. Şimdi, \mathbb{R}^d 'deki tüm hiper düzlemler Denklem 2.9'daki gibi ifade

$$w \cdot x + b = 0 \quad (2.9)$$

Burada w bir vektör, b ise bir sabittir.

Buradaki w aslında hiper düzlemle ortogonal vektörlerdir. Veriyi ayıran böyle bir hiper düzlem (w, b) verildiğinde, veriyi doğru bir şekilde sınıflandıran Denklem 2.10'daki fonksiyonu verir.

$$f(x) = \text{sign}(w \cdot x + b) \quad (2.10)$$

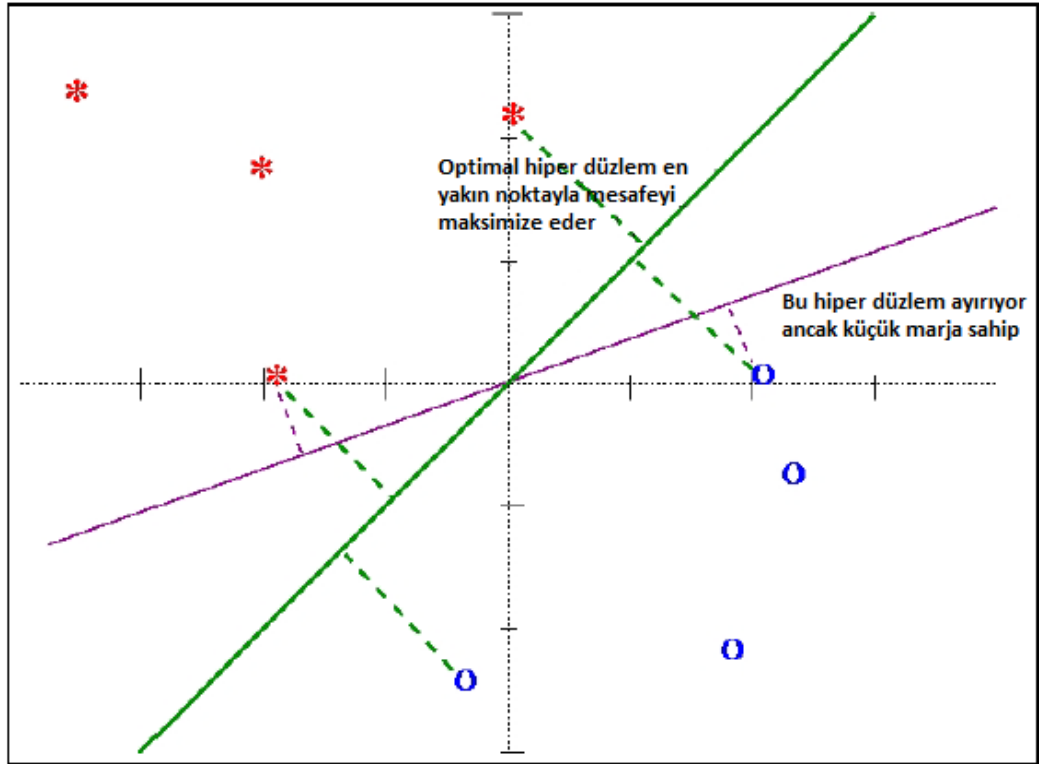
Kanonik hiper düzlemi, veriyi hiper düzlemden "en az 1" uzaklıkla ayıran bir hiper düzlem olarak Denklem 2.11'deki gibi tanımlıyoruz.

$$y_i(x_i \cdot w + b) \geq 1, \forall i \quad (2.11)$$

Denklem 2.10'daki fonksiyon çıkışı y_i olarak ifade edilmiştir. Hiper düzlemden bir veri noktasına geometrik mesafeyi elde etmek için w büyüklüğü ile normalleştirme işlemi yapılmalıdır. Bu mesafe basitçe Denklem 2.12'deki gibi ifade edilebilir.

$$d((w, b), x_i) = \frac{y_i(x_i \cdot w + b)}{\|w\|} \geq \frac{1}{\|w\|} \quad (2.12)$$

Sezgisel olarak, en yakın veri noktalarına olan geometrik mesafeyi maksimize eden hiper düzlemi isteriz. Bu durum Şekil 2.29'da gösterilmiştir.



Şekil 2.29 : Marjı maksimize eden hiper düzlemin seçilmesi [67].

Denklemden gördüğümüz gibi, w 'yi en aza indirgeyerek (mesafe kısıtlamalarına tabi olarak) başarılıdır. Bunu yapmanın ana yöntemi, Lagrange çarpanlarıdır. Türetme

ayrıntıları [69, 71] kitaplarında verilmiştir. Bu minimizasyon problemi, ikinci dereceden programlama (QP) sorunu olarak bilinir. Bunları çözmek için birçok teknik geliştirilmiştir [67].

2.6.1 Mükemmel eğitim görmüş SVM'lerin genelleştirilmesi yeteneği

Veriyi ayıran en iyi hiper düzlemin bulunduğu varsayalım. Ve l eğitim örneği ve N_s destek vektörleri olarak alınır. Daha sonra, beklenen örnek dışı hatanın (yanlışlıkla sınıflandırılacak olan görünmeyen bölümün), Denklem 2.13'deki gibi sınırlanmaktadır.

$$\Pi \leq N_s / (l - 1) \quad (2.13)$$

Burada Π beklenen örnek dışı hata, l eğitim örnekleri ve N_s destek vektörleri sayısıdır. Bu çok yararlı bir sonuçtur. Daha basit sistemlerin daha iyi olduğu görüşlerini sağlar ve SVM'ler için daha az destek vektörü aslında hiper düzlemin daha "kompakt" ve "daha basit" bir temsilidir ve dolayısıyla daha iyi performans göstermelidir [67]. Ancak veriler birbirinden ayrılamazsa, bu noktadaki SVM'ler için potansiyel bir gerileme gibi görünen hiçbir teori uygulanmaz.

2.6.2 Girişleri diğer boyutlara eşleme - çekirdeklerin kullanımı

Bir veri kümesinin doğrusal olarak ayrılabilir olmaması, veriyi ayırmanın başka basit yolları olmadığı anlamına gelmez. Örneğin, veriyi polinom eğrilerini veya daireleri kullanarak ayırmak daha kolay olabilir. Bununla birlikte, verilere uyacak en uygun eğri bulunması zordur ve en uygun hiper düzlemi bulma yöntemini kullanmak en uygunu olacaktır [67]. Gerçekten de, verinin "basit bir hiper düzlem" bulma yöntemine dönüştürüleceği şekilde "ön işleme" tabii tutmanın bir yolu vardır. Bunu yapmak için, d boyutlu giriş vektörü x 'i d' boyutlu (genellikle daha yüksek) z vektörüne dönüştüren bir haritalama $z = Q(x)$ tanımlanır. Yeni eğitim verisi $\{Q(x_i), y_i\}$ 'yi bir hiper düzlem ile ayrılabilir şekilde bir $Q(\cdot)$ seçmeyi umuyoruz. Şekil 2.30'da durum gösterilmiştir.



Şekil 2.30 : Veriyi özellik uzayında ayırma [67].

Gözlemlenebilecek önemli nokta, bir $Q(x_a)$ görüldüğü her zaman, bir başka $Q(x_b)$ ile daima bir nokta çarpımındadır. Yani, daha yüksek boyutlu özellik uzayında nokta çarpımı (çekirdek ya da kernel) için formül bilinseydi, hiçbir zaman haritalama $z=Q(x)$ ile doğrudan uğraşılmazdı.

Neyse ki, yararlı çekirdekler orijinal adıyla kerneller keşfedilmiştir. Polinom çekirdeği Denklem 2.14’de verilmiştir.

$$K(x_a, x_b) = (x_a \cdot x_b + 1)^p \quad (2.14)$$

Verilen formülde p ayarlanabilir bir parametredir ve pratikte 1 ile 10 arasında değişmektedir.

K 'yi değerlendirirken orijinal nokta ürünün hesaplanmasından daha fazla olarak ekstra bir ekleme ve üsleme içerdiğine dikkat edilmelidir. K içindeki nokta ürün genişletilmek istenirse Denklem 2.15 verilebilir.

$$K(x_a, x_b) = (x_{a1} \cdot x_{b1} + x_{a2} \cdot x_{b2} + \dots + x_{an} \cdot x_{bn} + 1)^p \quad (2.15)$$

Bir diğer popüler olan Gaussyan Radyal Tabanlı Fonksiyon (RBF) Kerneldir. Denklem 2.16’da detayları verilmiştir.

$$K(x_a, x_b) = \exp\left(-\frac{\|x_a - x_b\|^2}{2\sigma^2}\right) \quad (2.16)$$

Burada σ ayarlanabilir bir parametredir.

2.6.3 SVM'lerin uygulanması

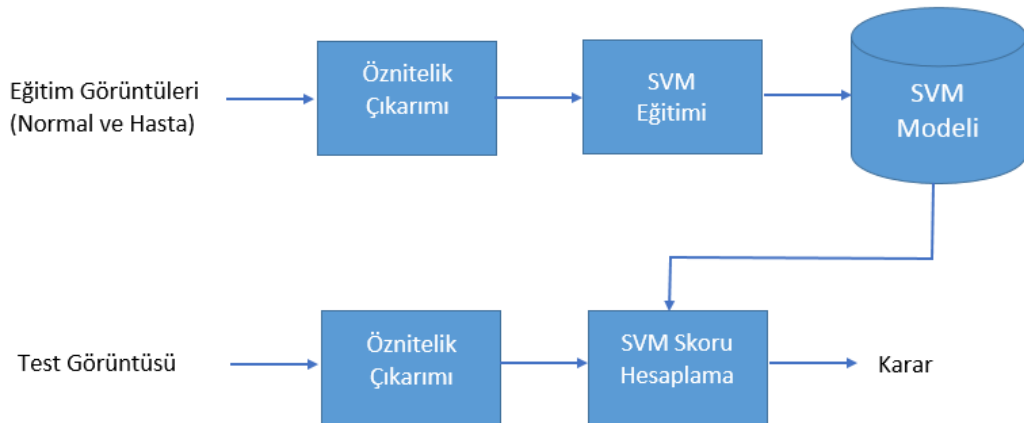
Bir SVM'yi eğitmenin en basit yolu (optimal hiper düzlemi (w, b) belirlemektir), kuadratik bir programlama çözücüsüne beslemektir [67]. Matlab'ta, bu `quadprog()` işlevidir. 1000'den az örneği bulunan eğitim setleri için bunlar gibi çözücüler iyi olabilir. Bununla birlikte, örnek sayısı arttıkça, iki kaygı vardır. Birincisi, `quadprog` (ve diğer QP paketleri) açıkça H matrisini gerektirdiğinden, bellek tüketimi $O(I^2)$ 'dir. 8 bayt hassasiyet ve 500MB RAM ile, 8.000 eğitim örneği sınırı getiriyor. İkinci endişe, sayısal istikrarsızlığın (optimal çözümler veya bazen hiç çözüm bulunmaması) potansiyel bir tehlike oluşturmasıdır. Genel olarak kuadratik programlama ilerledikçe sayısal istikrarsızlık kurtulmak için zor bir sorundur. Bununla birlikte, `quadprog` gibi "kapalı raf" yöntemleri, $I = 100.000$ örnek veya daha fazlasıyla ilgili sorunlu örnekler için uygun değildir.

3. BULGULAR VE TARTIŞMA

Test çalışmaları için çeşitli yaşlarda bayan ve erkek gerçek hasta görüntüleri kullanılmıştır. Kullanılan görüntüler radyoloji uzmanları tarafından tanılanmış ve onaylanmış görüntülerdir. Bu tanılardan yola çıkarak görüntüler üç sınıfa ayrılmıştır. Tamamen sağlıklı yani normal beyin görüntüleri sınıfı için 16 farklı hastaya ait 73 görüntü kullanılmıştır. Kanama tanısına sahip 15 farklı hastaya ait 75 görüntü kanama sınıfında, enfarkt tanısına sahip 21 farklı hastaya ait 103 görüntü enfarkt sınıfında kullanılmıştır.

Görüntülerin iyileştirilmesi için 6 adet yöntem kullanılmak için seçilmiştir. Bunlar; kontrast iyileştirme (Kİ), histogram eşitleme (HE), medyan filtreleme (MF), ortalama filtreleme (OF), gamma düzeltme (GD) ve power-law dönüşümü (PD) yöntemleridir. Parametre seçimi gerekli olan yöntemler için ayrıca optimal parametre seçimi çalışması yapılmıştır.

Görüntülerin öznitelik çıkarımı için güncel LBP yöntemi tercih edilmiştir. LBP yöntemi için komşuluk alma yöntemi ve miktarı değiştirilerek optimizasyon çalışması da yapılmıştır. LBP vasıtasıyla elde edilen öznitelikler ile sınıflandırma işlemi uygulanarak bilgisayarın otomatik olarak karar vermesi sağlanmıştır. Bunun için literatürde en sık kullanılan sınıflandırıcı algoritma olan destek vektör makineleri (SVM) sınıflandırıcısı kullanılmıştır. Tüm test ve işlemler, MATLAB programı kullanarak yapılmıştır. Çalışmanın akış diyagramı Şekil 3.1’de verilmiştir.



Şekil 3.1 : Otomatik tanı sisteminin genel yapısı.

Testler döngüler halinde gerçekleştirilmiştir. Her bir döngüde ilgili sınıftan 25 örnek eğitim için rastgele seçilmiştir. Kalan görüntüler test için kullanılmıştır. Bu görüntülerle eğitim sonrası yapılan testler neticesinde; görüntünün doğru sınıfta algılanıp algılanmadığına bağlı olarak döngüye ait doğruluk oranı 100 üzerinden hesaplanır. Her döngüde seçilen eğitim örnekleri rastgele değişmektedir. Çalışmada değerlendirilen sonuçlar 2000 döngünün işletilmesi neticesinde, döngülerin doğruluk oranlarının ortalaması ve standart sapmalarının hesaplanmasıyla elde edilmiştir. Testler kanama ve enfarkt sınıfları için ayrı ayrı gerçekleştirilmiştir. Döngü sayısı 2000 olarak seçildiğinde aynı koşullar altında yapılan test işlemlerine ait çıkan sonuçların değişkenlik arz etmediği görülmüştür.

3.1 LBP Parametre Optimizasyonu

LBP öznitelik çıkarımı sırasında komşuluk alma yöntemine ve sayısına göre sınıflandırıcı sonuçları değerlendirilmiştir. Bu sonuçlara göre elde edilen en iyi parametreler tespit edilmiş ve devam eden test çalışmalarında bu parametreler kullanılmıştır.

Komşuluk sayısı seçerek komşuluk alma yöntemine göre 4 ile 24 arasındaki değerlerde komşuluk alınması durumlarında görülen sonuçlar Çizelge 3.1’de verilmiştir.

Çizelge 3.1 : LBP komşuluk sayısı seçimine göre test sonuçları.

| Komşuluk Sayısı | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|-----------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| 4 | 52,97 | 6,12 | 69,6 | 4,31 |
| 8 | 57,1 | 6,05 | 74,49 | 3,48 |
| 12 | 57,36 | 6,01 | 74,28 | 3,34 |
| 16 | 57,61 | 5,58 | 73,84 | 2,78 |
| 20 | 57,63 | 5,59 | 73,76 | 2,81 |
| 24 | 57,68 | 5,76 | 73,73 | 2,68 |

Kanama tespitinde, alınan komşuluk sayısı arttıkça doğruluk performansının arttığı gözlemlenmektedir. En iyi sonucun 24 komşuluk sayısında 57,68 ile alındığı görülmüştür.

Enfarkt tespitinde, 4 komşuluk sayısında en düşük doğruluk performansı görülmüştür. 8 komşuluk sayısında ise en yüksek başarı ortalaması olan 74,49 sonucu alınmıştır.

8'den 24'e doğru komşuluk sayısı arttıkça başarı ortalamasında minimal azalışlar mevcuttur. Bununla birlikte sapmada ise olumlu değişiklikler söz konusudur. Dolayısıyla bu aralıkta performansın enfarkt tespiti için sabit olduğu söylenebilir.

Yarıçap belirleyerek komşuluk alma yöntemine göre 1 ile 5 arasındaki yarıçaplarda komşuluk alınması durumlarında görülen sonuçlar Çizelge 3.2'de verilmiştir.

Çizelge 3.2 : LBP yarıçap seçimine göre test sonuçları.

| Yarıçap Değeri | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|----------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| 1 | 57,07 | 6,03 | 74,51 | 3,6 |
| 2 | 58,89 | 6,02 | 79,22 | 5,31 |
| 3 | 57,31 | 5,16 | 76,36 | 6,88 |
| 4 | 57,49 | 5,44 | 76,27 | 8,95 |
| 5 | 57,56 | 5,17 | 73,5 | 7,93 |

Kanama tespitinde, yarıçap 2 olduğunda en iyi başarı ortalaması olan 58,89 elde edilmiştir. Diğer yarıçap değerlerinde ise bu seviyenin altında ancak birbirine yakın değerler gözlemlenmektedir.

Enfarkt tespitinde, kanama ile aynı şekilde yarıçap 2 olduğunda en iyi başarı ortalaması elde edilmiştir. Bu değer 79,22'dir. Yarıçapın 2'den daha yukarı çıkarılması durumunda performans düşmektedir. Yarıçap 1 olduğunda başarı ortalaması düşük seviyede olup sapma performansı iyidir.

Komşuluk sayısı seçme durumunda kanama ve enfarkt için en iyi değerler sırasıyla 57,68 ve 74,49 idi. Yarıçap belirlemede ise bu değerler sırasıyla 58,89 ve 79,22'dir. Bu durum her iki tespit çalışması için de en iyi seçeneğin yarıçapın 2 olarak belirlenerek öznitelik çıkarılması olduğunu ortaya koymaktadır. Bu nedenle, devam eden tüm test çalışmalarında LBP parametreleri bu şekilde uygulanmıştır.

3.2 Görüntü İyileştirme Yöntemleri Parametre Optimizasyonu

Gamma düzeltme ve power-law dönüşümleri için farklı parametreler seçilebilmektedir. Bu parametrelere göre dönüşümün karakteristiği değişmekte ve görüntüde meydana gelen etkiler farklılaşmaktadır. Bu nedenle, bu iki dönüşüm için farklı parametre değerlerine göre sınıflandırıcı sonuçları değerlendirilmiştir. Bu

sonuçlara göre elde edilen en iyi parametreler tespit edilmiş ve devam eden test çalışmalarında bu parametreler kullanılmıştır.


3.2.1 Gamma düzeltme yöntemi için gamma seçimi

Gamma düzeltme yönteminde gamma değişkenine göre işlemin etkileri değişmektedir. Farklı gamma değerleriyle gamma düzeltmesinin uygulandığı durumlarda görülen sonuçlar Çizelge 3.3’de verilmiştir.

Çizelge 3.3 : Seçilen gamma değerleriyle yapılan gamma düzeltme işlemi sonucu elde edilen test sonuçları.

| Gamma Değeri | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|--------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| 0,3 | 65,78 | 1,94 | 73,72 | 2,13 |
| 0,5 | 65,6 | 1,96 | 73,38 | 1,7 |
| 0,7 | 58,39 | 5,33 | 72,39 | 2,83 |
| 0,9 | 59,66 | 6,82 | 76,12 | 2,84 |
| 1,3 | 58,03 | 5,2 | 75,74 | 2,95 |
| 1,5 | 54,75 | 5,01 | 52,95 | 9,89 |
| 1,7 | 58,81 | 5,37 | 62,5 | 8,85 |
| 1,9 | 57,59 | 2,17 | 51,25 | 4,62 |

Şekil 3.2’de kanama ve enfarkt tespitindeki başarı oranının gamma düzeltmesinde farklı gamma değerlerine göre değişiminin grafiği verilmiştir.



Şekil 3.2 : Kanama ve enfarkt tespit başarı oranlarının gamma değerine bağlı değişimi.

Kanama tespiti için gamma değerinin 0,5 ve altında olduğu durumlarda performansın çok iyi olduğu görülmektedir. Diğer seviyelerde dalgalı ve daha düşük bir başarı ortalaması söz konusudur. En iyi başarı 65,78 ve 1,94 gibi düşük sapma değeriyle gamma parametresinin 0.3 olduğu duruma aittir.

Enfarkt tespitinde, gamma değeri 0,9 olduğunda 76,12 değeriyle en iyi performans sağlanmıştır. Gamma değeri 0,9'un üzerine çıktıkça başarının çok düştüğü, 0,9 altına indiğinde ise başarının minimal azalışlara uğradığı gözlemlenmektedir.

Elde edilen sonuçlar ışığında, bundan sonraki tüm test çalışmalarında görüntülere gamma düzeltme uygulandığı hallerde; gamma değeri kanama için 0,3 olarak enfarkt içinse 0,9 olarak uygulanmıştır.

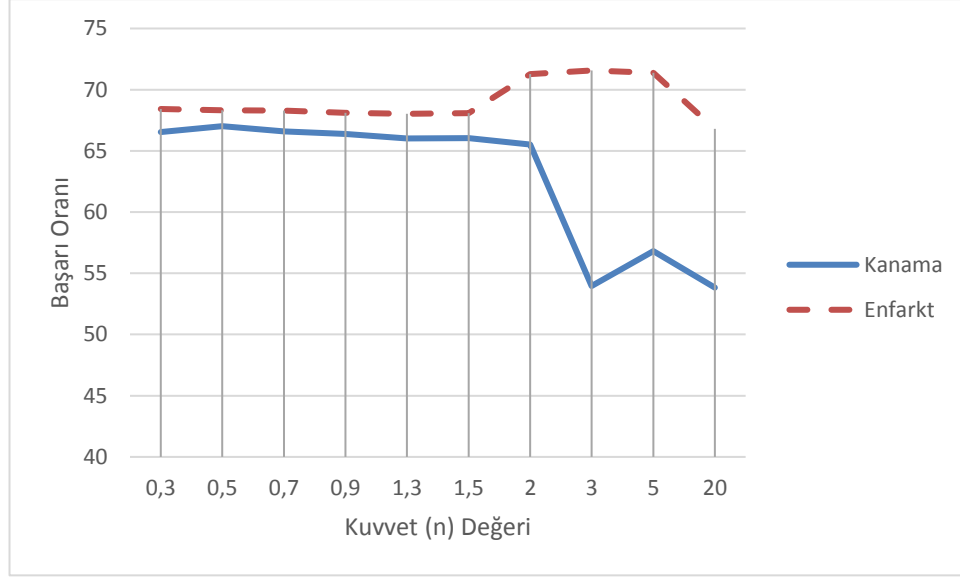
3.2.2 Power-law dönüşüm yöntemi için kuvvet seçimi

Power-law dönüşümünde seçilen kuvvete (n) yani üs alınacak değere göre işlemin etkileri değişmektedir. Farklı kuvvet değerleriyle power-law dönüşümünün uygulandığı durumlarda görülen sonuçlar Çizelge 3.4'de verilmiştir.

Çizelge 3.4 : Seçilen kuvvet (n) değerleriyle yapılan power-law dönüşüm işlemi sonucu elde edilen test sonuçları.

| Kuvvet (n) Değeri | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|----------------------|--|----------------------------------|---|-----------------------------------|
| 0,3 | 66,55 | 2,98 | 68,41 | 5,3 |
| 0,5 | 67,02 | 3,03 | 68,32 | 5,32 |
| 0,7 | 66,58 | 3,01 | 68,3 | 5,22 |
| 0,9 | 66,39 | 2,83 | 68,1 | 5,53 |
| 1,3 | 66,02 | 2,54 | 68,04 | 5,22 |
| 1,5 | 66,04 | 2,12 | 68,09 | 5,63 |
| 2 | 65,51 | 2,11 | 71,27 | 5,52 |
| 3 | 53,97 | 7,16 | 71,57 | 2 |
| 5 | 56,8 | 4,47 | 71,37 | 3,36 |
| 20 | 53,83 | 6,72 | 66,79 | 2,5 |

Şekil 3.3'de kanama ve enfarkt tespitindeki başarı oranının power-law dönüşümünde farklı kuvvet (n) değerlerine göre değişiminin grafiği verilmiştir.



Şekil 3.3 : Kanama ve enfarkt tespit başarı oranlarının kuvvet (n) değerine bağlı değişimi.

Kanama tespitinde kuvvet değeri 0,3 değerinden 2'ye kadar başarı ortalaması birbirine çok yakındır. Kuvvetin 2'nin üzerine çıkmasıyla performans oldukça olumsuz etkilenmektedir. En iyi başarı ortalaması 67,02 olup 0,5 kuvvetinde sağlanmıştır.

Enfarkt tespitinde, kanama tespitine benzer şekilde kuvvet değeri 0,3 değerinden 2'ye kadar başarı ortalaması birbirine çok yakındır. Farklı olarak bu aralıktaki performans 2'den büyük kuvvetlerde elde edilen performanstan daha düşüktür. En iyi başarı 71,57'dir. Bu ortalamaya 3 kuvvetinde ulaşılmıştır. 3'ten sonraki kuvvetlerde performansın tekrar düştüğü izlenmektedir.

Elde edilen sonuçlar ışığında, bundan sonraki tüm test çalışmalarında görüntülere power-law dönüşümü uygulandığı hallerde; kuvvet (n) değeri kanama için 0,5 olarak enfarkt içinse 3 olarak uygulanmıştır.

3.3 Görüntü İyileştirme Yöntemleri Uygulama Sonuçları

Çalışma kapsamında tercih edilen 6 adet görüntü iyileştirme yöntemleri görüntülere çeşitli kombinasyonlar dahilinde öznelik çıkarımı öncesi uygulanmıştır. Uygulamalar sonrası yapılan sınıflandırma testlerinde görüntü iyileştirme yöntemlerinin etkileri görülmüştür. Yöntemler ilk aşamada tekil olarak uygulanmış, her bir yöntem için test sonuçları ayrı ayrı alınarak Çizelge 3.5'de verilmiştir.

Çizelge 3.5 : Sadece bir görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları.

| Uygulanan Yöntem | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|------------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| Kİ | 65,84 | 1,91 | 73,37 | 2,27 |
| HE | 58,09 | 5,25 | 75,42 | 5,48 |
| MF | 59,58 | 6,19 | 81,03 | 5,66 |
| OF | 59,74 | 6,19 | 78,3 | 5,34 |
| GD | 65,78 | 1,94 | 76,12 | 2,84 |
| PD | 67,02 | 3,03 | 71,57 | 2 |

LBP parametre optimizasyonu sırasında görüntü iyileştirme yöntemleri uygulanmaksızın elde edilen en iyi sonuçlar kanama için 58,89 ve enfarkt için 79,22 idi. Yöntemlerin tek başına katkıları bu iki sonuç üzerinden izlenebilir.

Kanama tespiti için histogram eşitleme yönteminin başarıyı düşürdüğü görülmüştür. Medyan ve ortalama filtreler ayrı ayrı başarıyı çok az arttırmaktadır. Gamma düzeltme ve kontrast iyileştirmenin tek başlarına yarattığı etki olumlu ve birbirine çok yakındır. En iyi başarı power-law dönüşümüyle elde edilmiş olup 67,02 ortalamasıyla ilk duruma göre yaklaşık %14'lik doğruluk artışı sağlamıştır.

Enfarkt tespiti için medyan filtreleme dışındaki diğer 5 yöntem doğruluk performansını düşürmüştür. En dramatik düşüş, kanamada en başarılı olan power-law dönüşümüne aittir. Ortalama filtrenin başarıyı minimal ölçütlerde düşürdüğü görülmektedir. Medyan filtre ise başarıyı 81,03 değerine çıkararak ilk duruma göre yaklaşık %2'lik bir doğruluk artışı sağlamıştır.

Görüntü iyileştirme yöntemleri ikinci aşama olarak ikililer halinde ayrı ayrı uygulanmıştır. 6 adet yöntemin birbirleriyle tüm ikili kombinasyonları denenmiştir. Dolayısıyla bu aşamada toplam olarak 15 farklı deney gerçekleştirilmiştir. Bu deneylere ait tüm sonuçlar Çizelge 3.6'da verilmiştir. Kombinasyonlarda yöntem uygulama sırasının değiştirilmesi test sonuçlarını değiştirmemiştir. Bu durum, kullanılan yöntemlerin çoğunluğunun lineer olmasından kaynaklanmaktadır.

Çizelge 3.6 : Aynı anda iki farklı görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları.

| Uygulanan İki Yöntem | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|----------------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| Kİ+HE | 65,08 | 1,88 | 73,2 | 1,99 |
| Kİ+MF | 62,14 | 3,11 | 74,21 | 5,81 |
| Kİ+OF | 60,89 | 4,06 | 71,26 | 3,83 |
| Kİ+GD | 65,47 | 2,02 | 73,42 | 1,78 |
| Kİ+PD | 62,84 | 3,44 | 53,79 | 3,34 |
| HE+MF | 58,27 | 5,55 | 75,36 | 5,32 |
| HE+OF | 58,46 | 5,58 | 75,04 | 5,21 |
| HE+GD | 58,07 | 5,28 | 75,34 | 5,43 |
| HE+PD | 51,02 | 0 | 61,9 | 0 |
| MF+OF | 59,89 | 6,47 | 78,16 | 5,34 |
| MF+GD | 65,77 | 2,21 | 76,65 | 3,92 |
| MF+PD | 63,55 | 5,02 | 72,37 | 2,23 |
| OF+GD | 65,76 | 2,34 | 76,8 | 4,01 |
| OF+PD | 63,77 | 5,86 | 73,21 | 2,29 |
| GD+PD | 49,16 | 4,65 | 68,67 | 6,68 |

Görüntü iyileştirme uygulanmadığında en iyi değerler kanama için 58,89 ve enfarkt için 79,22 idi. İlk aşamada uygulanan tek iyileştirmeler neticesinde en iyi değerler kanama için 67,02 ve enfarkt için 81,03 olmuştur.

Kanama tespiti için tüm ikili kombinasyonların sonucunda elde edilen veriler, ulaşılan en iyi durumun yani 67,02 başarı ortalamasının altındadır. İki iyileştirme yönteminin birlikte uygulanmasının başarı ortalamasının iyileşmesine katkısının olmadığı görülmektedir. En iyi sonuçların gamma düzeltmenin üç farklı birlikteliğinde olduğu izlenmektedir. Gamma düzeltme, medyan filtreyle birlikte uygulandığında en yüksek, ortalama filtreyle en yükseğe çok yakın ve kontrast iyileştirmeyle üçüncü en iyi başarıyı sağlamıştır.

Enfarkt tespiti için de kanama tespitiyle aynı durum söz konusudur. Tüm ikili kombinasyon sonuçları 81,03 değerinin altındadır. En iyi sonuçların medyan filtrenin ayrı ayrı ortalama filtre ve gamma düzeltmeyle birlikte uygulanması durumlarında olduğu gözlemlenmektedir. Histogram eşitleme ile power-law dönüşümünün bir arada uygulanması her iki tespit çalışmasını da ciddi miktarda olumsuz etkilemiştir.

Görüntü iyileştirme yöntemlerinde son aşama olarak üçlüler halinde ayrı ayrı uygulanmıştır. İkili uygulamalarda faydalı sonuçlar alınmadığı için üçlü kombinasyon olarak ikilide öne çıkan grupların üçlendiği bazı kombinasyonlar incelenmiştir. Bu aşamada toplam 6 farklı deney gerçekleştirilmiştir. Bu deneylere ait tüm sonuçlar Çizelge 3.7’de verilmiştir.

Çizelge 3.7 : Aynı anda üç farklı görüntü iyileştirme yöntemi uygulanarak elde edilen test sonuçları.

| Uygulanan Üç Yöntem | Kanama Tespiti Başarı Ortalaması | Kanama Tespiti Başarı Sapması | Enfarkt Tespiti Başarı Ortalaması | Enfarkt Tespiti Başarı Sapması |
|---------------------|----------------------------------|-------------------------------|-----------------------------------|--------------------------------|
| Kİ+HE+MF | 62,14 | 2,5 | 72,14 | 5,66 |
| Kİ+HE+OF | 60,88 | 3,9 | 70,72 | 3,98 |
| Kİ+HE+GD | 66,72 | 1,85 | 73,22 | 2,08 |
| Kİ+MF+GD | 64,97 | 2,94 | 73,68 | 5,67 |
| Kİ+MF+PD | 56,06 | 6,39 | 50,8 | 3,22 |
| Kİ+OF+GD | 62,73 | 5,48 | 72,62 | 6,32 |

İkili uygulamalarda tekil uygulamalara göre daha iyi herhangi bir sonuç alınmadığından en iyi değerler kanama için 67,02 ve enfarkt için 81,03 olarak devam etmektedir.

Kanama tespiti için denenen üçlü kombinasyonların sonucunda elde edilen veriler, ulaşılan en iyi durumun yani 67,02 başarı ortalamasının yine altındadır. En iyi sonuç kontrast iyileştirme, gamma düzeltme ve histogram eşitleme üçlüsüne aittir. İkili denemelerde iyi sonuçlardan birini oluşturan gamma düzeltme ve kontrast iyileştirme ikilisinin başarı performansını, histogram eşitleme yöntemi ikiliye katılarak arttırmıştır. Bu üçluden elde edilen 66,72 değeri, testlerde alınan en yüksek değer olan 67,02 değerine çok yakındır.

Enfarkt tespiti için denenen üçlü kombinasyonların sonucunda da elde edilen veriler, ulaşılan en iyi durumun yani 81,03 başarı ortalamasının altındadır. En iyi sonuç medyan filtre, gamma düzeltme ve kontrast iyileştirme üçlüsüne aittir. İkili denemelerde iyi sonuçlardan birini oluşturan gamma düzeltme ve medyan filtre ikilisinin başarı performansını, kontrast iyileştirme ilave gelerek düşürmüştür. Kanama tespitinde bir durumda oluşan iyimser sonuç burada hiçbir durumda söz konusu değildir. Enfarkt tespitinde üçlü uygulama sonuçları tamamen olumsuzdur.

4. SONUÇLAR

Bilgisayarlı tomografi görüntülerinin otomatik olarak kanama, enfarkt ve normal tanılardan hangisine sahip olduğunun tespiti için yapılan çalışmalar neticesinde önemli sonuçlara ulaşılmıştır. Kanama ve enfarkt durumları farklı görüntüsel karakteristiklere sahiptir. Dolayısıyla iki durum farklı yöntemlere farklı cevaplar vermektedir.

Kanama tespitinde görüntü iyileştirme olmaksızın elde edilen başarı ortalamasının %58 seviyesinde ve daha düşük olduğu görülmüştür. Power-law dönüşümü tespit edilen optimal kuvvet değeri 0,5 ile uygulandığında başarı ortalamasını %67 seviyesine taşımıştır. Çalışmada kanama için görülen en yüksek sonuç budur. Görüntü iyileştirme yönteminin kanama tespiti için anlamlı bir katkısı olmuştur. Kanama durumlarında kontrast iyileştirme yöntemlerinin ön plana çıktığı söylenebilir. Bu yönde yapılan işlemler görüntülerdeki farklılıkları belirginleştirmektedir.

Enfarkt tespitinde ise görüntü iyileştirme olmaksızın elde edilen başarı ortalamasının %79 seviyesinde ve daha düşük olduğu görülmüştür. Medyan filtreleme yapıldığında başarı ortalaması %81 seviyesine çıkmıştır. Çalışmada enfarkt için görülen en yüksek sonuç budur. Enfarkt için görüntü iyileştirme yöntemi uygulanmadan da iyi sonuç alındığı söylenebilir. Enfarkt durumlarında görüntünün kendiliğinden ayırıcı özelliklere sahip olduğu söylenebilir. Medyan filtreleme ile görüntülerdeki gürültü azaltımının nispeten ayırımı artırdığı yorumu yapılabilir.

Görüntü iyileştirme yöntemlerinin farklı kombinasyonlarının birlikte uygulanmasının performansa katkısı olmamıştır. Hatta başarıda düşüslere neden olmuştur.

Literatür araştırmasında da görüleceği üzere böyle bir problemin çözümünde LBP yöntemi ilk defa kullanılmıştır. Yarıçap 2 değeri seçilerek LBP özniteliklerinin çıkarılmasının en iyi performansı verdiği tespit edilmiştir.

Özellikle enfarkt tespitinde elde edilen sonuçlar umut vericidir. Böylesi bir tespit mekanizması radyoloji uzmanı bağımlı bir şekilde kurulduğunda, uzmanın önüne gelen her 10 enfarkt görüntüsünün 8'ini yakalayacaktır. Böylece uzman sadece 2

görüntünün detaylı kontrolüyle uğraşacaktır. Kalan 8 görüntüyü ayrıntılı incelemesine gerek kalmaksızın onay vererek geçecektir.

Söz konusu durum kanama için 10 kanama görüntüsünde neredeyse 7 tespite denk gelecektir. Tüm bunlar en azından uzmanın tanı koyma sürecini hızlandıracaktır. Ayrıca uzmanın atlayabileceği vakaları da yakalayabileceği için sistem yardımcı bir rol de üstlenmiş olacaktır.

Çalışmanın geliştirilmesi için kanama ve enfarkt durumlarının kendi karakteristikleri dikkate alınarak farklı görüntü işleme metodları uygulamaya alınabilir. Beyinde olabilecek farklı hastalıklar kapsam dahiline alınarak beyne ait olabilecek tüm tanı sorgularının yapılması sağlanabilir. Bu kapsamda örnek sayısı artırılır ve detaylandırılır. Tüm tanıları birleşik bir sınıflandırma sonucuyla tek işlemde otomatik sağlanabilir. Patolojik alanların lokalizasyon tespitine ve yapısal analizlerine çalışılabilir. MR gibi farklı modaliteler için de benzer çalışmalar gerçekleştirilebilir.

KAYNAKLAR

- [1] **Radyolojik İnceleme Yöntemleri.** (t.y.). Erişim: 16.05.2017, <http://radyoloji.uludag.edu.tr/radyolojik-inceleme-yontemleri.htm>
- [2] **Çukurova Üniversitesi, Sağlık Hizmetleri Meslek Yüksek Okulu.** (2011). *Röntgen Cihazları ve Fizik Prensipleri* [Powerpoint slides]. Retrieved from <https://www.slideshare.net/muyuta/mammografi>
- [3] **Düzen Laboratuvarları.** (2013). *Kemik ve Mineral Yoğunluğu Ölçümü* [Powerpoint slides]. Retrieved from http://www.duzen.com.tr/workshop/2013/Kemik_ve_Mineral_Metabolizmasi_Filiz_Yenicesu.pdf
- [4] **Çukurova Üniversitesi, Tıp Fakültesi.** (2011). *Dijital Radyografi ve Kesitsel Görüntüleme Yöntemleri* [Powerpoint slides]. Retrieved from <https://www.slideshare.net/muyuta/djital-grntleme-yntemler1gr>
- [5] **Görüntüleme Yöntemleri ve Ana Prensipler.** (t.y.). Erişim 16.05.2017, https://tr.wikipedia.org/wiki/Görüntüleme_Yöntemleri_ve_Ana_Prensipler
- [6] **Marwaha, S., Monga, H., & Shelza** (2012). Automatic Diagnosis Systems Using Image Processing-A systematic Study. *International Journal of Computer Science and Information Technology & Security*, 2(2), 388-391.
- [7] **Mesanovic, N., Grgic, M., Huseinagic, H., Males, M., Skejic, E., & Smajlovic, M.** (2011). Automatic CT Image Segmentation of the Lungs with Region Growing Algorithm. *18th International Conference on Systems, Signals and Image Processing-IWSSIP*, 395-400.
- [8] **Peixoto, H., & Alves, V.** (2009). Computer-Aided Diagnosis in Brain Computed Tomography Screening. *Industrial Conference on Data Mining*, 62-73.
- [9] **Padma, A., & Sukanesh, R.** (2011). Automatic Diagnosis of Abnormal Tumor Region from Brain Computed Tomography Images Using Wavelet Based Statistical Texture Features. *Arxiv Preprint Arxiv*, 1109, 1067-1082.
- [10] **Van de Wouwer, G., Scheunders, P., & Van Dyck, D.** (1999). Statistical texture characterization from discrete wavelet representations. *IEEE transactions on image processing*, 8(4), 592-598. doi: 10.1109/83.753747
- [11] **Chang, R. F., Wu, W. J., Moon, W. K., Chou, Y. H., & Chen, D. R.** (2003). Support vector machines for diagnosis of breast tumors on US images. *Academic radiology*, 10(2), 189-197. doi: 10.1016/S1076-6332(03)80044-2

- [12] **Fausett, L.** (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. Englewood cliffs, NJ: Prentice Hall International.
- [13] **Montejo, L. D., Jia, J., Kim, H. K., Netz, U. J., Blaschke, S., Müller, G. A., & Hielscher, A. H.** (2013). Computer-aided diagnosis of rheumatoid arthritis with optical tomography, Part 1: feature extraction. *Journal of biomedical optics*, 18(7), 076001-076001. doi: 10.1117/1.JBO.18.7.076001
- [14] **Montejo, L. D., Jia, J., Kim, H. K., Netz, U. J., Blaschke, S., Müller, G. A., & Hielscher, A. H.** (2013). Computer-aided diagnosis of rheumatoid arthritis with optical tomography, Part 2: image classification. *Journal of biomedical optics*, 18(7), 076002-076002. doi: 10.1117/1.JBO.18.7.076002
- [15] **Hampton-Till, J., Harrison, M., Kühn, A. L., Anderson, O., Sinha, D., Tysoe, S., & Grunwald, I. Q.** (2015). Automated quantification of stroke damage on brain computed tomography scans: e-ASPECTS. *Eur Med J*, 3, 69-74.
- [16] **Shahangian, B., & Pourghassem, H.** (2013). Automatic brain hemorrhage segmentation and classification in CT scan images. *Machine Vision and Image Processing (MVIP), 2013 8th Iranian Conference*, 467-471. doi: 10.1109/IranianMVIP.2013.6780031
- [17] **Kharrat, A., Gasmi, K., Messaoud, M. B., Benamrane, N., & Abid, M.** (2010). A hybrid approach for automatic classification of brain MRI using genetic algorithm and support vector machine. *Leonardo journal of sciences*, 17(1), 71-82.
- [18] **Ramteke, R. J., & Monali, Y. K.** (2012). Automatic medical image classification and abnormality detection using k-nearest neighbour. *International Journal of Advanced Computer Research*, 2(4), 190-196.
- [19] **Ali, A. H., Abdulsalam, S. I., & Nema, I. S.** (2015). Detection and Segmentation of Hemorrhage Stroke using Textural Analysis on Brain CT Images. *International Journal of Soft Computing and Engineering (IJSCE)*, 2231-2307.
- [20] **Mahajan, R., & Mahajan, P. M.** (2016). Survey On Diagnosis Of Brain Hemorrhage By Using Artificial Neural Network, *International Journal of Scientific Research Engineering & Technology (IJSRET)*, 5(6), 378-381.
- [21] **Bala, A.** (2012). An Improved watershed image segmentation technique using MATLAB. *International Journal of Scientific & Engineering Research*, 3(6), 1-4.
- [22] **Kyaw, M. M.** (2013). Computer-Aided Detection system for Hemorrhage contained region. *International Journal of Computational Science and Information Technology*, 1(1), 11-16.
- [23] **Ali, A. H., Abdulsalam, S. I., & Nema, I. S.** (2015). Detection and Segmentation of Ischemic Stroke Using Textural Analysis on Brain CT Images. *International Journal of Scientific & Engineering Research*, 6(2), 396-400.

- [24] **Kaushik, D., Singh, U., Singhal, P., & Singh, V.** (2014). Brain tumor segmentation using genetic algorithm. *Proceedings on International Conference on Advances in Computer Engineering and Applications*, 13-15.
- [25] **Cagnoni, S., Dobrzeniecki, A. B., Poli, R., & Yanch, J. C.** (1999). Genetic algorithm-based interactive segmentation of 3D medical images. *Image and Vision Computing*, 17(12), 881-895.
- [26] **Falkenauer, E.** (1998). *Genetic algorithms and grouping problems*. New York, John Wiley & Sons, Inc..
- [27] **Prastawa, M., Bullitt, E., Ho, S., & Gerig, G.** (2004). A brain tumor segmentation framework based on outlier detection. *Medical image analysis*, 8(3), 275-283. doi:10.1016/j.media.2004.06.007
- [28] **Shelke, V. R., Rajwade, R. A., & Kulkarni, M.** (2013). Intelligent Acute Brain Hemorrhage Diagnosis System, *Proc. of Int. Conf. on Advances in Computer Science*, 522-528.
- [29] **Al-Ayyoub, M., Alawad, D., Al-Darabsah, K., & Aljarrah, I.** (2013). Automatic detection and classification of brain hemorrhages. *WSEAS transactions on computers*, 12(10), 395-405.
- [30] **Otsu, N.** (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66. doi: 10.1109/TSMC.1979.4310076
- [31] **Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H.** (2009). The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1), 10-18. doi: 10.1145/1656274.1656278
- [32] **Devi, C. A., & Rajagopalan, S. P.** (2013). Brain Stroke Classification Based on Multi-Layer Perceptron Using Watershed Segmentation and Gabor Filter. *Journal of Theoretical & Applied Information Technology*, 56(3), 410-416.
- [33] **Stork, D. G., & Wilson, H. R.** (1990). Do Gabor functions provide appropriate descriptions of visual cortical receptive fields?. *JOSA A*, 7(8), 1362-1373.
- [34] **Svozil, D., Kvasnicka, V., & Pospichal, J.** (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and intelligent laboratory systems*, 39(1), 43-62. doi: 10.1016/S0169-7439(97)00061-0
- [35] **Fatima, Sridevi, M., Naaz, S., & Anjum, K.** (2015). Diagnosis And Classification Of Brain Hemorrhage Using Cad System. *Proceeding of NCRIET-2015 & Indian J.Sci.Res.*, 12(1), 121-125.
- [36] **Krishnammal, P. M., & Raja, S. S.** (2015) Automated Brain Image classification using Neural Network Approach and Abnormality Analysis. *International Journal of Engineering and Technology (IJET)*, 7(3), 876-886.
- [37] **Specht, D. F.** (1990). Probabilistic neural networks. *Neural networks*, 3(1), 109-118.

- [38] **Kharat, K. D., Kulkarni, P. P., & Nagori, M. B.** (2012). Brain tumor classification using neural network based methods. *International Journal of Computer Science and Informatics*, 1(4), 85-90.
- [39] **Zhu, Y., & Yan, Z.** (1997). Computerized tumor boundary detection using a Hopfield neural network. *IEEE transactions on medical imaging*, 16(1), 55-67. doi: 10.1109/42.552055
- [40] **Wettlaufer, J.** (1996). *Physical Principles of Medical Imaging*. Madison, Wis: Medical Physics Publishing.
- [41] **Colsher, J. G.** (1980). Fully-three-dimensional positron emission tomography. *Physics in medicine and biology*, 25(1), 103.
- [42] **Gordon, R., Bender, R., & Herman, G. T.** (1970). Algebraic reconstruction techniques (ART) for three-dimensional electron microscopy and X-ray photography. *Journal of theoretical Biology*, 29(3), 471-476.
- [43] **Mertler, A. A., Karadoğan, N., & Tatarhan, G.** (2015). Türkiye’de Tıbbi Cihazların Sayısal Durumu Ve Oecd Ülkeleri İle Karşılaştırmaları. *Uluslararası Sağlık Yönetimi Ve Stratejileri Araştırma Dergisi*, 1(1), 52-70.
- [44] **Computed Tomography – CT Scanner Aquilion One Technology.** (t.y.). Erişim: 25.05.2017, <https://medical.toshiba.com/products/computed-tomography/aquilion-one-family/technology.php>
- [45] **Arslan, B.,** (2005). *Bilgisayarlı Tomografi İle Görüntüleme Yöntemleri*, (Yüksek Lisans Tezi). Erişim adresi: <https://polen.itu.edu.tr/xmlui/handle/11527/784>
- [46] **Wang, S. Y., Huang, Y. B., Pereira, V., & Gryte, C. C.** (1985). Application of computed tomography to oil recovery from porous media. *Applied optics*, 24(23), 4021-4027.
- [47] **Allan, C. J., Keller, N. A., Lupton, L. R., Taylor, T., & Tonner, P. D.** (1985). Tomography: an overview of the AECL program. *Applied optics*, 24(23), 4067-4074.
- [48] **Beyin Kanaması.** (t.y.). Erişim: 01.06.2017, http://www.radyolojinet.com/hastalikbilgisi/hastalik_beyinkanamasi.html
- [49] **Beyin Kanamaları.** (t.y.). Erişim: 01.06.2017, <https://www.memorial.com.tr/saglik-rehberleri/beyin-kanamaları/>
- [50] **İntraserebral Kanama.** (t.y.). Erişim: 01.06.2017, tr.healthline.com/health/intraserebral-kanama
- [51] **İnme (Beyin Damar Hastalığı).** (t.y.). Erişim: 03.06.2017, <http://www.baburdora.com.tr/tr/m55.php>
- [52] **Beyin Enfarktüsü.** (t.y.). Erişim: 03.06.2017 <http://www.draysesagduyu.com/beyin-enfarktusu,DP-969.html>

- [53] **The University of Auckland, Department of Computer Science.** (2011). *Image Filtering* [Powerpoint slides]. Retrieved from https://www.cs.auckland.ac.nz/courses/compsci373s1c/PatricesLectures/Image%20Filtering_2up.pdf
- [54] **Maini, R., & Aggarwal, H.** (2010). A comprehensive review of image enhancement techniques. *Journal Of Computing*, 2(3), 8-13.
- [55] **Pratt, W. K.** (1989). *Digital image processing*. Prentice Hall.
- [56] **Russ, J.C.** (1992). *The Image Processing Handbook*. Boca Raton, FL., CRC Press.
- [57] **Image Processing Algorithms Part 5: Contrast Adjustment.** (t.y.). Erişim: 12.06.2017, <http://www.dfstudios.co.uk/articles/programming/image-programming-algorithms/image-processing-algorithms-part-5-contrast-adjustment/>
- [58] **Image Processing Algorithms Part 6: Gamma Correction.** (t.y.). Erişim: 12.06.2017, <http://www.dfstudios.co.uk/articles/programming/image-programming-algorithms/image-processing-algorithms-part-6-gamma-correction/>
- [59] **Pietikäinen, M., Hadid, A., Zhao, G., & Ahonen, T.** (2011). *Local binary patterns for still images*. London, Springer.
- [60] **Ojala, T., Pietikäinen, M., & Harwood, D.** (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1), 51-59. doi: 10.1016/0031-3203(95)00067-4
- [61] **Wang, L., & He, D. C.** (1990). Texture classification using texture spectrum. *Pattern Recognition*, 23(8), 905-910. doi: 10.1016/0031-3203(90)90135-8
- [62] **Ojala, T., Pietikainen, M., & Maenpaa, T.** (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, 24(7), 971-987. doi: 10.1109/TPAMI.2002.1017623
- [63] **Mäenpää, T., & Pietikäinen, M.** (2005). Texture analysis with local binary patterns. *Handbook of Pattern Recognition and Computer Vision*, 3, 197-216.

- [64] Ahonen, T., Hadid, A., & Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *IEEE transactions on pattern analysis and machine intelligence*, 28(12), 2037-2041.
- [65] Maenpaa, T. (2003). *The local binary pattern approach to texture analysis-extensions and applications*. University of Oulu.
- [66] Heikkilä, M., Pietikäinen, M., & Schmid, C. (2009). Description of interest regions with local binary patterns. *Pattern recognition*, 42(3), 425-436. doi: 10.1016/j.patcog.2008.08.014
- [67] Boswell, D. (2002). *Introduction to support vector machines*. University of California, San Diego.
- [68] Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- [69] Vapnik, V. N. (1998). *Statistical learning theory*. J (Vol. 3). Wiley, New York.
- [70] Vapnik, V. N. (1979). *Restoration of Dependences From Empirical Data*.
- [71] Schölkopf, B., Burges, C. J., & Smola, A. J. (1999). *Advances in kernel methods: support vector learning*. Cambridge, MIT press.

ÖZGEÇMİŞ



Ad-Soyad : Serdar KÜPLÜ
Doğum Tarihi ve Yeri : 30/12/1988 Osmangazi/BURSA
E-posta : serdarkuplu@hotmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2009, Uludağ Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektronik Mühendisliği Bölümü
- **Lisans** : 2013, Anadolu Üniversitesi, İşletme Fakültesi, İşletme Bölümü
- **Yüksek Lisans** : 2016, Ahmet Yesevi Üniversitesi, Sağlık Kurumları İşletmeciliği Programı
- **Yüksek Lisans** : 2017, Bursa Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Burtom Sağlık Grubu / 2009-Devam / Yönetici
-

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

-
-
-

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

-