



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

**MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
BEL BÖLGESİ RAHATSIZLIKLARININ
TANISI**

Yavuz ÜNAL

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalını

**Haziran - 2015
KONYA
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Yavuz ÜNAL tarafından hazırlanan “Makine Öğrenmesi Yöntemleriyle Bel Bölgesi Rahatsızlıklarının Tanısı” adlı tez çalışması 02/06/2018 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof.Dr. Bekir KARLIK

Danışman

Yrd.Doç.Dr. H. Erdinç KOÇER

Üye

Doç.Dr. Halis ALTUN


Üye

Yrd.Doç.Dr. Ömer Kaan BAYKAN

Üye

Yrd.Doç.Dr. Mehmet HACİBEYOĞLU

İmza



Yukarıdaki sonucu onaylarım.




Prof. Dr. Aşır GENÇ
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.


Yavuz ÜNAL
02.06.2015

ÖZET

DOKTORA TEZİ

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE BEL BÖLGESİ RAHATSIZLIKLARININ TANISI

Yavuz ÜNAL

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. H. Erdinç KOÇER
İkinci Danışman: Doç. Dr. Kemal POLAT

2015, 141 Sayfa

Jüri

Yrd. Doç. Dr. Hasan Erdinç KOÇER
Prof. Dr. Bekir KARLIK
Doç. Dr. Halis ALTUN
Yrd. Doç. Dr. Ömer Kaan BAYKAN
Yrd. Doç. Dr. Mehmet HACİBEYOĞLU

Bel bölgesi rahatsızlıklarının en belirgin ortak belirtisi bel ağrısıdır. Bel ağrısı modernleşen toplumların önemli sağlık problemlerinden biri olarak karşımıza çıkmaktadır. En sık görülen rahatsızlıklardan biri olan bel ağrısı insanların %80' inin hayatında en az bir kez karşılaştığı, kas ve iskelet sisteminde fonksiyon bozukluklarına sebep olan en önemli sağlık sorunlarından biridir. Bel ağrısı çalışan kesimi ileri derecede etkilemektedir. Özellikle gelişmiş ülkelerde işgücü ve ücret kayıplarına sebep olmakta ve bu ülkelerde milyar dolarlara varan maddi kayıplara sebep olmaktadır.

Bu çalışmada radyolog, uzman ve doktorların bel bölgesi rahatsızlıklarının teşhisine yardımcı olması amaçlanan bir bilgisayar destekli teşhis (BDT) sistemi geliştirilmiştir. Bu sistem ile bel bölgesi rahatsızlıklarından bel fıtığı, dejeneratif disk, omur kayması (spondilolisthesis), lomber spinal stenoz, rahatsızlıkları teşhis edilmektedir. Sistemin aşamaları; görüntü ön işleme, özellik çıkarımı, veri ağırlıklandırma ile özellik azaltımı ve sınıflandırma olarak sıralanabilir. Çalışmada kullanılan bel bölgesi axial ve sagittal MR görüntüleri Selçuk Üniversitesi Tıp Fakültesi Hastanesi Radyoloji bölümünden alınmıştır. Ön işlem aşamasında MR görüntülerine histogram eşitleme ve medyan filtreleme uygulanmıştır. Özellik çıkarımı aşamasında sagittal MR görüntülerine aktif şekil modelleme tekniği uygulanarak ilk özellik vektörü elde edilmiştir. Aksiyal MR görüntülerinde spinal kanal bölgesinde, spinal kanal ve lateral kanalın biçimsel ölçümleri manuel olarak yapılarak ikinci özellik vektörü elde edilmiştir. Ayrıca, California Üniversitesi Uluslararası Irvine Makine Öğrenme Veritabanından (UCI) alınan bel bölgesine ait vertebral veri kümesi de ayrı bir özellik vektörü olarak sınıflandırma aşamasında kullanılmıştır. Özellik azaltımı aşamasında F-Skor Tabanlı Özellik Seçme (FSTÖS) ve Korelasyon Tabanlı Özellik Seçme (KTÖS) yöntemleri uygulanarak ağırlıklandırılmış verilerden iyi özellikte olanlar seçilmiştir. Özellik seçimi yapılan verilere İkili Bulanık C-Ortalama tabanlı veri ağırlıklandırma ve bu tez çalışmasında geliştirilen Ortalama Kayma kümeleme tabanlı veri ağırlıklandırma işlemleri uygulanmıştır. Çalışmanın son aşamasında ise elde edilen veri kümelerinin sınıflandırılması işlemi yapılmıştır. Bu aşamada Destek Vektörü Makineleri (DVM), Çok Katmanlı Perseptron (MLP), LVQ sinir ağırları (LVQ-NN), Radyal Tabanlı Fonksiyon Sinir Ağları (RTFA), k-en yakın komşu (K-NN) sınıflandırma algoritmaları uygulanmış ve sonuçlar ayrı ayrı kaydedilmiştir. Sınıflandırma başarısına ait sonuçlar tezin ilgili bölümünde sunulmuştur.

Anahtar Kelimeler: Bel bölgesi rahatsızlıkları, Bilgisayar Destekli Teşhis Sistemleri, Lomber MR, Makine Öğrenmesi,

ABSTRACT

Ph.D THESIS

DIAGNOSIS OF LUMBAR DISEASE BY USING MACHINE LEARNING TECHNIQUES

Yavuz ÜNAL

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN COMPUTER ENGINEERING**

**Advisor: Asst. Prof. Dr. H. Erdinç KOÇER
Co-Advisor: Assoc. Prof. Dr. Kemal POLAT**

2015, 141Pages

Jury

**Asst. Prof. Dr. Hasan Erdinç KOÇER
Prof. Dr. Bekir KARLIK
Assoc. Prof. Dr. Halis ALTUN
Asst. Prof. Dr. Ömer Kaan BAYKAN
Asst. Prof. Dr. Mehmet HACIBEYOĞLU**

Backache is one of the most important health problems of the modernized societies. It is observed with the most frequency and is one of the most important health problems encountered at least by 80% of people in life causing functional deficiencies in the muscle and skeleton system. It also affects working people at a further level. It causes losses in labor force and in wages especially in developed countries. These countries experience million dollars of financial losses.

In this study, a Computer-Assisted Diagnosis System (CADS) is presented to help the radiologists, specialists and doctors. The diseases such as spinal disk herniation, degenerative disk, slipped disk (spondilolysthesis), central stenosis, lateral stenosis, ligament facet trophy are diagnosed with this system. The stages of the system may be listed as the pre-processing of the images, feature extraction, feature reduction by data weighting, and classification. The axial and sagittal used MR images that were obtained from Selçuk University, Faculty of Medicine Hospital Radiology Department. The MR imaging histogram equalization and median filtering were applied in the pre-processing stage. In the feature extraction stage, the feature of the waist area were obtained by using the Active Shape Modelling Technique. Axial MR imaging received formal measurements and the dataset of spinal channel were recorded. In addition, the vertebral dataset of the waist area from the International UCI Database was used in the classification stage as a separate feature vector. In the feature reduction stage, the FBFS (F-Score Based Feature Selection) and CBFS (Correlation Based Feature Selection) methods were used, and the better ones among the weighted data were selected. The pairwise Fuzzy C-Means-based data weighting techniques and the Mean Shift Set-based data weighting technique, which was developed in the process of this study, were applied to the data selected. In the latest stage of the study, the datasets obtained were classified. In this stage, the Support Vector Machines (SVM), Multi-Layer Perceptron (MLP), Learning Vector Quantization (LVQ), Radial Basis Function (RBF), K-Nearest Neighbor (K-NN) classification techniques were used and the results were recorded separately. The results of the classification accuracy are given in the relevant section of the thesis.

Keywords: Computer aided diagnosis systems, Data weigting, Lumbar disc disease, Lumbar MR, Machine Learning, Data weigting

ÖNSÖZ

Tez çalışmasına verdiği destekten dolayı tez danışmanım Yrd.Doç.Dr. H. Erdinç KOÇER'e ve ikinci danışmanım Doç.Dr. Kemal POLAT 'a, tez süresince belirttikleri değerli görüş ve önerilerle tezin yönlendirilmesine yardımcı olan Tez İzleme Komitesi üyeleri Prof. Dr. Bekir KARLIK ve Yrd.Doç.Dr. Ömer Kaan BAYKAN'a, MR görüntülerinin kaydedilmesi, incelenmesi ve yorumlanması aşamalarında bana destek veren Selçuklu Tıp Fakültesi Radyoloji Bölümü öğretim üyelerinden Doç. Dr. Ali Sami KIVRAK'a ve Selçuk Üniversitesi Teknik Eğitim Fakültesi'ndeki eski çalışma arkadaşlarıma ve özellikle manevi desteğini hiçbir zaman benden esirgemeyen ve her zaman yanımda olan aileme sonsuz teşekkür ederim.

Yavuz ÜNAL
KONYA-2015

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLER LİSTESİ	x
ÇİZELGELER LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Tezin Amacı Önemi ve Literatüre Katkısı	1
1.2. Kaynak Araştırması	3
1.3. Tezin Organizasyonu	9
2. BEL BÖLGESİ ANATOMİSİ ve RAHATSIZLIKLARI	10
2.1. Vücut Eksenleri.....	10
2.2. Omurga Yapısı	11
2.2.1. Intervertebral disk anatomisi	13
2.3. Bel Bölgesi Rahatsızlıkları	15
2.3.1. Bel fıtığı	16
2.3.2. Dejeneratif disk hastalığı	18
2.3.3. Omur kayması.....	19
2.3.4. Lomber spinal stenoz	20
2.4. Bel Bölgesinin Radyolojik Olarak Görüntülenmesi	21
2.4.1. Röntgen (X-ray).....	21
2.4.2. Magnetik rezonans görüntüleme (MRG).....	22
2.4.3. Bilgisayarlı tomografi	24
2.4.4. Myelografi	25
2.4.5. Diskografi	26
3. MATERYAL VE YÖNTEM.....	28
3.1. Tez Çalışmasında Kullanılan Medikal Veriler	28
3.1.1. Tez çalışması için elde edilen veritabanı	28
3.1.2. UCI makine öğrenmesi veritabanından alınan veriler	29
3.2. Tez Çalışmasının Aşamaları	31

4. MR GÖRÜNTÜLERİNİN ÖN İŞLENMESİ.....	33
4.1. Görüntü İyileştirme.....	33
4.1.1. Histogram eşitleme	34
4.1.2. Medyan filtreleme	36
4.1.3. İlgili bölgenin kesilmesi (Crop).....	37
5. ÖZELLİK ÇIKARIMI.....	39
5.1 Aktif Şekil Modeli	39
5.1.1 Şekil modelinin oluşturulması	39
5.1.2. Profil modelin oluşturulması	40
5.1.3. Aktif şekil modeli ile özellik çıkarımı	41
5.2 Biçimsel Özellik Çıkarma.....	41
6. ÖZELLİK SEÇİMİ	44
6.1 F-skor Tabanlı Özellik Seçme Yöntemi (F-score Based Feature Selection)	44
6.2 Korelasyon Tabanlı Özellik Seçimi (Corelation Based Feature Selection).....	46
7. VERİ AĞIRLIKLANDIRMA	48
7.1 Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma Yöntemi	49
7.2 İkili Bulanık C-Ortalama Tabanlı Veri Ağırlıklandırma Yöntemi	52
8. BEL BÖLGESİ RAHATSIZLIKLARININ SINIFLANDIRILMASI.....	55
8.1 Sınıflandırma Yöntemleri	55
8.1.1. Yapay sinir ağları.....	56
8.1.1.1. YSA'nın özellikleri.....	58
8.1.1.2. YSA'nın yapısı	58
8.1.1.3. Yapılarına göre yapay sinir ağları.....	60
8.1.1.4. Öğrenme algoritmalarına göre yapay sinir ağları	60
8.1.2. Çok katmanlı algılayıcı (MLP) sinir ağı	60
8.1.3. Destek vektör makineleri	61
8.1.3.1. Doğrusal ayrılabilen veriler için destek vektör makineleri.....	62
8.1.3.2. Doğrusal olmayan destek vektör makineleri: haritalama yaklaşımı ve çekirdek fonksiyonlarının kullanımı (Kernel trick)	65
8.1.4. K-en yakın komşu algoritması (k-NN)	65
8.1.5. Karar ağaçları (Decision tree).....	67
8.1.6. Naive bayes sınıflandırıcı	69
8.1.7. Radyal tabanlı fonksiyon ağları	71
8.1.8. LVQ yapay sinir ağları	73
8.2 Deneysel Sonuçlar ve Tartışma	75
8.2.1. Performans değerlendirme testleri	75
8.2.2 UCI makine öğrenmesi veritabanından alınan veriler ile ilgili sonuçlar	78
8.2.2. Hastaneden alınan veriler ile ilgili sonuçlar	85
9. SONUÇLAR VE ÖNERİLER.....	101
EKLER	117

EK-1 Etik Kurul Kararı.....	117
EK-2 Tezde Kullanılan Yazılımların Ekran Görüntüleri.....	118
EK-3 Tezde Geliştirilen Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma Yönteminin Matlab Kodları.....	122

ŞEKİLER LİSTESİ

Şekil 2. 1 Vücut eksenleri (Alapan, 2012).....	10
Şekil 2. 2. Bel bölgesi omuru (Sozlukanlaminedir, 2014).....	11
Şekil 2. 3. Bel ve sırt omurları (Şenköylü, 2010)	12
Şekil 2. 4. Omurga bölgeleri ve omur sayıları (Mehmetcuka, 2014)	12
Şekil 2. 5. Bel bölgesi omurları (Turanuslu, 2014)	13
Şekil 2. 6. Intervertebral disk anatomisi (Nml, 2014)	14
Şekil 2. 7. (a) Sağlam disk, (b) fıtıklı diskin sinire yaptığı bası (Physioworks, 2014)..	16
Şekil 2. 8. Bel fıtığının dört aşaması (Spinalstenosis, 2014).....	17
Şekil 2. 9. Bel fıtığının sagittal MR'da görüntülenmesi.....	18
Şekil 2. 10. Dejeneratif disk rahatsızlığının sagittal MR'da görüntülenmesi	19
Şekil 2. 11. Omur kayması (Omurgaomurilik, 2014).....	20
Şekil 2. 12. Bel bölgesi röntgen görüntüsü (Tronlyimage, 2014)	22
Şekil 2. 13. Bel bölgesi aksiyal MR görüntüsü	23
Şekil 2. 14. Bel bölgesi T1 ve T2 ağırlıklı sagittal MR görüntüleri (Neurologyindia, 2014).....	24
Şekil 2. 15. Bel bölgesi bilgisayarlı tomografi görüntüsü (Tumorlibrary, 2014).....	25
Şekil 2. 16. Myelografi uygulanmış hasta görüntüsü (Medicastore, 2014).....	26
Şekil 2. 17. İntervertebral disk e diskografi işleminin uygulanması (Gsmmedical, 2015) 26	
Şekil 3. 1. Tez çalışmasında kullanılan (a) aksiyal ve (b) sagittal MR görüntüleri.....	29
Şekil 3. 2. Tez çalışmasının blok diyagram ile gösterimi.....	31
Şekil 4. 1. (a) Gri seviyeli bir görüntü ve histogram grafiği (b) histogram eşitlemesi yapılmış bir görüntü ve görüntüye ait histogram grafiği (Homepages, 2014).....	35
Şekil 4. 2. Bel bölgesi aksiyal MR görüntüleri (a) histogram eşitleme uygulanmamış (b) histogram eşitlemesi uygulanmış.....	35
Şekil 4. 3. Bel bölgesi sagittal MR görüntüleri (a) histogram eşitleme uygulanmamış (b) histogram eşitlemesi uygulanmış.....	35
Şekil 4. 4 Medyan filtre örneği (Kazdal, 2013)	36
Şekil 4. 5. (a) Gürültülü görüntü (b) Gürültülü görüntüye medyan filtre uygulanmış hali (Kazdal, 2013)	36
Şekil 4. 6. Bel bölgesi aksiyal MR görüntüleri (a) ham (b) medyan filtresi uygulanmış	37
Şekil 4. 7. Bel bölgesi sagittal MR görüntüleri (a) ham (b) medyan filtresi uygulanmış	37
Şekil 4. 8. Kesme işlemi ekran görüntüsü	38
Şekil 5. 1. AŞM ile özellik çıkarımı için sınır noktalarının işaretlenmesi.....	41
Şekil 5. 2. Özellik çıkarımı için oluşturulan sınır çizgileri.....	42
Şekil 5. 3. Özellik vektörlerinin elde edildiği ölçüm alanları.....	42
Şekil 6. 1. F-skor tabanlı özellik seçme algoritması akış şeması (FSTÖS).....	45
Şekil 6. 2. Korelasyon tabanlı özellik seçimi akış şeması (KTOS).....	47
Şekil 7. 1. Özellik uzayında (a) lineer olarak ayrılabilen ve (b) lineer olarak ayrılamayan veri kümeleri (Sebastianraschka, 2015).....	48
Şekil 7. 2. Ortalama kayma algoritmasının şematik gösterimi (Derpanis, 2005).....	51
Şekil 7. 3. Ortalama kayma kümeleme tabanlı veri ağırlıklandırma yönteminin akış şeması.....	51
Şekil 8. 1. Biyolojik sinir hücresi (Felsefe, 2015)	57
Şekil 8. 2. Yapay sinir ağı yapısı (Fanntool, 2015).	59
Şekil 8. 3. Çok katmanlı algılayıcı sinir ağının yapısı (Kabalcı, 2013).....	61

Şekil 8. 4. Doğrusal ayrılabilen veriler için optimum ayırıcı hiperdüzlem (Tekin, 2013).	64
Şekil 8. 5. Veri kümesinin doğrusal olarak ayrılamaması durumu (Statsoft, 2015).....	65
Şekil 8. 6. K-en yakın komşu algoritması şematik gösterimi (Apinetree, 2015).	66
Şekil 8. 7. Karar ağacı örneği (Sezer, 2008).	68
Şekil 8. 8. Radyal tabanlı fonksiyon ağlarının yapısı (Cenaero, 2015).	72
Şekil 8. 9. LVQ sınır ağının yapısı (Afrinc, 2015).	75
Şekil 8. 10. ROC eğrilerinin performansa göre gösterimi (Gim, 2015).	77
Şekil 8. 11. Ham ve İBCOTVA ile ağırlıklandırılmış veri dağılımlarının grafiksel gösterimi	79
Şekil 8. 12. Bel bölgesi veri kümesine gruplamalı bulanık c-ortalama tabanlı veri ağırlıklandırma yönteminin uygulanması (DH: Disk Hernia, SL: spondylolisthesis, NO:Normal)	80
Şekil 8. 13. İkili olarak gruplandırılan ham ve İBCOTVA ile ağırlıklandırılmış verilerin dağılımlarının grafiksel gösterimi.....	80
Şekil 8. 14. Önerilen metodun blok diyagramı.....	81
Şekil 8. 15. Bel bölgesi veritabanının f-skor ile özellik seçimi uygulamasını gösteren akış şeması	88
Şekil 8. 16. Bel bölgesi veri kümesinin korelasyon tabanlı özellik seçimi uygulamasını gösterir akış şeması.....	91
Şekil 8. 17. İki özellik için (a) doğrusal olarak ayrılamayan ve (b) doğrusal olarak ayrılabilen veriler	96

ÇİZELGELER LİSTESİ

Çizelge 3.1. Alınan verilere ilişki istatistik değeri	29
Çizelge 3.2. UCI veritabanından alınan özelliklerin istatistik değeri	30
Çizelge 8.1. Karmaşıklık matrisi	75
Çizelge 8.2. UCI vertebral column veritabanındaki özelliklerin istatistik değeri	78
Çizelge 8.3. İkili gruplamaların 10 kat çapraz-geçerlilik testi sonuçları	82
Çizelge 8.4. Ham ve bulanık c-ortalama yöntemi ile ağırlıklandırılan verilerin 10 kat çapraz-geçerlilik testi ile sınıflama sonuçları	83
Çizelge 8.5. Ham ve bulanık c-ortalama yöntemi ile ağırlıklandırılan verilerin %50 test %50 eğitim verisi olarak ayrılmış sınıflama sonuçları	84
Çizelge 8.6. UCI vertebral column veri kümesinin literatürde yer alan sınıflama performans karşılaştırma sonuçları	84
Çizelge 8.7. Elde edilen hibrit özellik vektörlerinin eksenleri ve bölgeleri	85
Çizelge 8.8. Normal sınıflı verilerin istatistik değeri	86
Çizelge 8.9. Hasta sınıflı verilerin istatistik değeri	87
Çizelge 8.10. 27 özellik vektörünün f-skor değeri	89
Çizelge 8.11. 5 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları	90
Çizelge 8.12. 22 özelliğin korelasyon ve p değeri	92
Çizelge 8.13. 22 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları	93
Çizelge 8.14. 27 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları	94
Çizelge 8.15. 5, 22 ve 27 özellikli veri kümelerinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları	95
Çizelge 8.16. 27 özellikli ham veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları	96
Çizelge 8.17. Ham ve OKKTVA ile ağırlıklandırılmış verilerin k-NN ile sınıflama sonuçları	97
Çizelge 8.18. Ham ve OKKTVA ile ağırlıklandırılmış verilerin RTFA ile sınıflama sonuçları	98
Çizelge 8.19. 3 sınıflı ham verilerin MLP, DVM, naive bayes ve karar ağaçları ile sınıflandırma sonuçları	98
Çizelge 8.20. 3 sınıflı ikili bulanık c-ortalama ile ağırlıklandırılan verilerin MLP, DVM, naive bayes ve karar ağaçları ile sınıflandırma sonuçları	99
Çizelge 8.21. 3 sınıflı OKKTVA ile ağırlıklandırılan verilerin MLP, DVM, naive bayes ve Karar ağaçları ile sınıflandırma sonuçları	100

SİMGELER VE KISALTMALAR

Simgeler

λ : Öğrenme katsayısı
 Σ : Toplam
 Δ : Ortalama kayma vektörü
 ∇ : Yoğunluk yordama meyili
 ∞ : Sonsuz
 Φ : Özellik vektörü
 α : Momentum

Kısaltmalar

MR: Manyetik Rezonans
MRG: Manyetik Rezonans Görüntüleme
YSA: Yapay Sinir Ağları (Artificial Neural Networks)
DVM: Destek Vektör Makineleri (Support Vector Machine)
BT: Bilgisayarlı Tomografi
MLP: Multi Layer Perceptron
LSS: Lomber Spinal Stenoz
BDT: Bilgisayar Destekli Teşhis
DP: Doğru Pozitif
DN: Doğru Negatif
YP: Yanlış Pozitif
YN: Yanlış Negatif
GUI: Grafiksel kullanıcı arabirimi (Graphical user interface)
k-NN: k-en yakın komşu(k-nearest neighbor)
UCI: University of California, Irvine
MLP: Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
GRNN: Genel regresyon sinir ağları (General regression neural network)
PCA: Temel Bileşen Analizi (Principal component analysis)
JPEG: Birleşik Fotoğraf Uzmanları Grubu (Joint Photographic Experts Group)
AŞM: Aktif Şekil Modeli (Active Shape Model)
RTFA: Radyal Tabanlı Fonksiyon Sinir Ağları
OKKTVA: Ortalama kayma kümeleme tabanlı veri ağırlıklandırma
FSTÖS: F-skor tabanlı özellik seçme
KTÖS: Korelasyon tabanlı özellik seçme
LVQ-NN: LVQ Sinir Ağları
ROC: Alıcı Operasyon Karakteristiği - Receiver Operating Characteristic
İBCOTVA: İkili bulanık c-ortalama tabanlı veri ağırlıklandırma

1. GİRİŞ

Bel bölgesi rahatsızlıklarının en belirgin ortak belirtisi bel ağrısıdır. Bel ağrısı giderek modernleşmekte olan toplumlarda her geçen gün daha fazla önem arz eden sağlık sorunlarından biridir. Bel ağrısı baş ağrısından sonra tüm dünyada en sık görülen ikinci ağrı çeşididir. Tüm dünya nüfusunun %80' i hayatlarının bir döneminde en az bir kez bu ağrı ile karşılaşmışlardır (Borenstein, 2000).

Bel ağrısı hareket sınırlılıklarına sebebiyet veren, yürümeyi oturmaya ve hatta ayakta durmayı zorlaştıran, yaşam kalitesini düşüren, can sıkıcı ve oldukça da yaygın bir şikâyetir (Suyabatmaz, 1994).

Bel ağrısında sıklık ve şiddet mesleklere göre değişebilir (Üstün, 2014). Ağır bedensel iş gücü gerektiren meslekler, kaldırma-dönme-dönerek kaldırma, uzun süreli oturma ve araç kullanma gibi mesleklerde bu ağrı daha sık görülmektedir. Örnek: inşaat işçileri, hemşire, öğretmen, bilgisayar çalışanı, ağır vasıta sürücüler vs. Sigara içenlerde ise disk beslenmesi bozulduğundan bel rahatsızlığı riski artmaktadır (Sarıkaya, 2002).

Hastalarda ağrı süresinin uzaması depresyon gibi davranış bozuklukları da beraberinde getirmekte ve kişilerin yaşam kalitesi de bozulmaktadır (Sarıkaya, 2002).

Bu rahatsızlığın özellikle gelişmiş birçok ülkede teşhis ve tedavi masraflarının yanında çalışanlarda iş günü ve iş gücü kaybı, sakatlık, erken emeklilik, sakatlığa bağlı tazminat ödenmesi gibi milyarlarca dolarlık masraflara yol açtığı bilinmektedir.

Ülkemizde bu alanda yeterli istatistiki veri bulunmamakla birlikte Amerika Birleşik Devletlerinde bu rahatsızlıktan dolayı yılda 50 milyar dolar civarı harcandığı kaydedilmiştir (NINDS, 2014).

Bu tez çalışmasında bel bölgesi sagittal ve aksiyal MR görüntülerinden özellik çıkarımı, özellik seçimi ve bu özelliklerin ağırlıklandırılarak sınıflandırma performansının artırılmasını sağlayan ve dolayısı ile bel bölgesi rahatsızlıklarının tanısını koymaya yardımcı bir bilgisayar destekli teşhis sistemi tasarlanmıştır.

1.1. Tezin Amacı Önemi ve Literatüre Katkısı

Gerçekleştirilen tez çalışmasında bel bölgesi MR görüntülerini yorumlayan radyoloji uzmanlarına kesin tanı koyma veya tanıyı desteklemelerine yardımcı olabilecek yeni bir akıllı BDT sistemi tasarlanmıştır. Bu çalışma ile bel bölgesi MR

görüntülerini inceleyen radyolog ve uzmanlar bel fıtığı, kanal darlığı, omur kayması ve dejeneratif disk rahatsızlıklarını daha kolay teşhis edebilecektir.

Bel bölgesi rahatsızlıklarının insan yaşam kalitesini düşürmesi, erken emeklilik ve iş gücü kayıplarının yanı sıra hem teşhisinin hem de tedavi maliyetlerinin çok yüksek olması, doğru ve hızlı teşhis konulabilmesini de oldukça önemli hale getirmiştir.

Bel bölgesi rahatsızlıkları genellikle MR kullanılarak görüntülenmektedir. MR cihazlarından elde edilen görüntüler uzman radyologlar tarafından değerlendirilmektedir.

Radyologların, bel bölgesi rahatsızlıklarını MR görüntülerinden belirlerken karar vermelerini kolaylaştırmak amacı ile BDT sistemleri kullanılmaktadır. BDT sistemlerinin radyologların performansını geliştirdiği ve radyologların uzmanlık alanları ile bu alanda çalıştıkları yıl sayısına bağlı olarak yapılan teşhislerdeki doğruluğun arttığı bilinen bir gerçektir.

Gerçekleştirilen BDT sistemi ile uzman doktor ve radyologlara yardımcı, bel bölgesi rahatsızlıklarının teşhisini kolaylaştırıcı bir sistem tasarlanmıştır.

Uzman doktor yorgunluğu, tecrübe eksikliği, görüntüde oluşan yapıların ayrıştırılmasındaki zorluklar, ayrıca ülkemizin tıp alanında sahip olduğu kısıtlı maddi imkânlar ve yetişmiş uzman sayısındaki yetersizlikler düşünüldüğünde geliştirilen bu BDT sisteminin önemi ortaya çıkmaktadır.

Bu sistem iki aşamadan oluşmaktadır. İlk aşamada MR cihazından alınan ham görüntüler ön işlemden geçirilerek görüntü iyileştirilmesi yapılmıştır. İyileştirilen görüntüler üzerinde özellik çıkarım işlemi gerçekleştirilmiştir. Bu aşamasında sagittal MR görüntülerine aktif şekil modelleme tekniği uygulanarak özellik vektörleri elde edilmiştir. Bununla birlikte aksiyal MR görüntülerinin spinal kanal bölgesinde biçimsel ölçümler yapılarak spinal kanal, sağ ve sol lateral kanal yükseklikleri ölçülerek özellik vektörleri elde edilmiştir.

Sistemin ikinci aşamasında elde edilen özellik vektörleri f-skor tabanlı özellik seçme (FSTÖS) ve korelasyon tabanlı özellik seçme (KTÖS) yöntemleri uygulanarak iyi özellikte olanlar seçilmiştir. Özellik seçimi yapılan verilere ikili bulanık c-ortalama tabanlı veri ağırlıklandırma ve bu tez çalışmasında geliştirilen Ortalama Kayma kümeleme tabanlı veri ağırlıklandırma işlemleri uygulanmıştır. Çalışmanın son aşamasında ise elde edilen veri kümelerinin sınıflandırılması işlemi yapılmıştır. Bu aşamada destek vektörü makineleri (DVM), çok katmanlı perseptron (MLP), LVQ sinir

ağları (LVQ-NN), radyal tabanlı fonksiyon sinir ağları (RTFA), k-en yakın komşu (k-NN) sınıflandırma algoritmaları uygulanmış ve sonuçlar ayrı ayrı kaydedilmiştir.

Bel bölgesi rahatsızlıklarının teşhisinde radyolog doktor ya da uzmanlar teşhis koyabilmek için çoğu zaman hem sagittal hem de aksiyal görüntülerin her ikisine de bakarak karar vermektedirler. Geliştirilen bu bilgisayar destekli sistem ile hem aksiyal hem de sagittal görüntülerden alınan özellik vektörleri aynı anda kullanılmıştır. Bu bakımdan bu tez çalışması literatüre katkı anlamında özgün bir çalışmadır.

Ayrıca çalışmanın veri ağırlıklandırma kısmında kullanılan ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi bu çalışmada geliştirilmiştir.

1.2. Kaynak Araştırması

Bel bölgesi rahatsızlıklarının bilgisayar destekli teşhisi ile ilgili çeşitli çalışmalar literatürde mevcuttur.

Literatür araştırmasında, makine öğrenmesi ile medikal teşhis sistemleri, bel bölgesi MR görüntüleri üzerinden rahatsızlık teşhisi ve son olarak veri ağırlıklandırma ve boyut azaltımı veya özellik seçme yöntemleri ile ilgili yapılan çalışmalara yer verilmiştir.

İlk olarak literatürde var olan makine öğrenmesi yöntemleri ile medikal verilerin teşhisine yönelik çalışmalar aşağıda özetlenmiştir.

Özkan ve ark. (1990), yaptıkları çalışmada multi-spectral insan beyin MR'larını YSA kullanarak segmente etmişler ve yine yapay sinir ağları kullanarak sağlıklı ve hasta olarak sınıflandırmışlardır.

Rajapakse ve Acharya (1990), yaptıkları çalışmada kalp bilgisayarlı tomografi görüntülerini self organizing map yapay sinir ağları ile segmente etmişlerdir.

Miller ve ark. (1992), yaptıkları çalışmada göğüs kafesi elektriksel empedans tomografisi görüntülerini çeşitli yapay sinir ağları kullanarak organları sınıflandıran sistem tasarlamışlardır.

Hall ve ark. (1992), beyin MR görüntülerini segmente etmede yapay sinir ağları ve bulanık kümeleme yöntemlerini kullanarak bu yöntemlerin başarısını kıyaslamışlardır. Bu yöntemleri segmente etmenin yanında teşhis içinde kullanmışlardır.

Däsclein ve ark. (1994), iki katmanlı YSA kullanarak karın bölgesi bilgisayarlı tomografi görüntülerini segmente etmişlerdir.

Houston (1994), yaptığı çalışmada, MR ve tümör işaretlerini kullanarak kolorektal kanser teşhisi için uzman sistem ile yapay sinir ağını karşılaştırarak optimal bir teşhis stratejisi geliştirmiştir.

Karakas (1994), yapay sinir ağları ile mikroskoptan elde edilen resimlerdeki kan hücrelerini otomatik segmente etmiştir. Ağ 82 objeden 65 'ini doğru olarak sınıflamıştır.

Xing (1994), göğüs MR'larına yapay sinir ağları (YSA) uygulayarak desen tanıma yapmıştır.

Gözel (2001), yaptığı yüksek lisans tez çalışmasında elektromiyogram (EMG) işaretlerini sınıflayan bir bulanık k-en yakın komşuluk (BK-EYK) tabanlı bulanık ilişki matrisi (BİM) sınırlayıcısı önerilmiştir. Bu algoritma klasik BK-EYK sınıflayıcısı ve keskin k-En yakın komşuluk (K-EYK) sınıflayıcısı ile karşılaştırmıştır.

Kimyonok (2003), yaptığı yüksek lisans tez çalışmasında 50 yaş üstü 119 hastadan alınan PSA değerleri karar ağaçları algoritmalarından birini C4.5 ve J48 ile sınıflandırarak prostat kanser tanısı konulmuştur.

Özkaya (2006), yaptığı yüksek lisans tez çalışmasında EKG işaretlerinin sınıflandırılması ile aritmik kardiyak hastalıkların otomatik olarak teşhisini sağlayan bir sistem geliştirmiştir. Sınıflandırma algoritmalarından destek vektör makineleri (DVM) kullanmıştır. Çalışmasında kullanılan veriler UCI aritmi veritabanından elde edilmiş olup çok boyutlu EKG veri kümesinde boyut indirgeme için PCA ve ICA yöntemleri kullanılmıştır. Karşılaştırma amacıyla k-NN ve karar ağaçları yöntemleri de EKG veri kümesine uygulanmış ve deney sonuçlarına göre geliştirilmiş DVM yönteminin daha iyi sonuç verdiği belirlenmiştir.

Çevikcan (2007), yaptığı yüksek lisans tez çalışmasında, 30 hasta ve 30 sağlıklı bireyden yüzeysel EMG yöntemi ile alınan verileri welch yöntemi ile analiz etmiştir. Kasların kasılmasını sağlayan elektriksel aktiviteyi incelediği tez çalışmasında bel fıtığı rahatsızlığında sinirlerin elektrofizyolojik tetkiki olarak bası altında kalan sinirlerde hasar olup olmadığı ve varsa hasarın derecesini belirleyebilmek için welch yöntemini kullanmıştır. EMG verilerinin analizi sonucunda elde edilen spektrumları (PSD) incelediğinde bel fıtığı rahatsızlığı bulunan bireylerin bel ve karın kaslarının kasılma sırasında ürettiği aksiyon potansiyelinin daha yüksek olduğunu tespit edilmiş ve bel fıtığı hastalığı bulunan kişilerin bel fıtığı oluşumunda etkili olan bel ve karın bölgelerindeki kas fonksiyonlarının, sağlıklı bireylere göre daha zayıf olduğu sonucuna ulaşmıştır.

Erdoğan (2009), yaptığı yüksek lisans tez çalışmasında beyin MR görüntülerini çeşitli görüntü işleme yöntemleri ile ön işlemden geçirmiştir. Daha sonra MR resimleri 30x30 pikselden oluşan küçük karelere ayrılmıştır. Her karenin aritmetik ortalaması hesaplanarak, sistem girişi olarak kullanılacak olan öznitelik vektörü elde edilmiştir. İkinci kısımda ise, elde edilen öznitelikler YSA ile sınıflandırılmıştır.

Sarıkaya (2009), yaptığı yüksek lisans tez çalışmasında bilgisayarlı tomografi ile çekilmiş akciğer görüntülerindeki akciğer kütlelerinin kanserli olup olmadığını sınıflandırmak için destek vektörü makineleri ve dalgacık dönüşümünü kullanmıştır. Çalışmada 126 bilgisayarlı akciğer tomografi görüntüsü kullanılmıştır. Bilgisayarlı akciğer tomografileri üzerinde yapılan testlerden elde edilen sonuçlarda, dalgacık dönüşümü ile filtreleme yapıldıktan sonra, destek vektör makineleri ve radyal tabanlı fonksiyon çekirdeği kullanımı ile %76.74 sınıflandırma doğruluğuna erişmiştir.

Aydın (2011), yaptığı yüksek lisans tez çalışmasında kalp ritim bozukluğu olan hastaların tedavi süreçlerini desteklemek amaçlı makine öğrenmesine dayalı bir sistem geliştirmiştir. İnsan metabolizmanın çalışmasının bir sonucu olarak ortaya çıkan nabız, kan basıncındaki dalgalanmalar, kandaki oksijen miktarı vb. parametreleri okuyan bir cihaz kullanılmıştır. Bu cihazdan alınan veriler geliştirilen sisteme giriş olarak verilmiş ve makine öğrenmesi yöntemlerinden k-NN ile sınıflandırılmıştır.

Oktay (2011), hazırladığı doktora tezinde çeşitli tıbbi imgeler için nesne saptama ve kontur bulma işlemlerini farklı önsel bilgilerin eklenmesi ile gerçekleştiren makine öğrenmesi tabanlı yöntemler sunmuştur. Sunulan yöntemlerde, önsel bilgi hiyerarşik bir şekilde lokal ve global olarak ayırmıştır. Böylece farklı tiplerdeki bilgileri ekleyerek daha verimli, modüler ve etkin bir şekilde nesne saptama ve kontur bulma işlemlerini gerçekleştirmek amaçlamıştır. Tıbbi imge olarak bel bölgesi sagittal MR görüntülerini kullanmıştır. Bel omurları arasındaki disklerin yerlerini tespit eden bir doktora tez çalışması yapmıştır.

Uslu (2011), yaptığı yüksek lisans tez çalışmasında tıbbi verilerin yapay sinir ağları yolu ile analizi ve bu ağların tanı koyabilmedeki performansı ile ilgilidir. Ağlar eğitilirken fast artificial neural network isimli bir yapay sinir ağı kütüphanesini kullanan FannTool isimli ücretsiz dağıtım bir program kullanılmıştır. Farklı algoritmalarla eğitilmenin, farklı ağ tasarımlarının, farklı eğitim/test oranına sahip veri setlerinin kullanımının, farklı miktarlarda adımlarla eğitilmenin, farklı aktivasyon fonksiyonları kullanımının yapay sinir ağının performansını nasıl etkilediği araştırılmıştır.

Ekşi (2012), yaptığı yüksek lisans tez çalışmasında röntgen (X-ray) görüntüleri üzerinden görüntü işleme teknikleri ve yapay sinir ağları ile kırık tespiti yapan bir bilgisayar destekli teşhis sistemi tasarlamıştır.

Hacıfendioğlu (2012), yaptığı yüksek lisans tez çalışmasında makine öğrenmesi yöntemleri ile göz rahatsızlıklarından biri olan glokom hastalığının teşhisine yönelik bir çalışma yapmıştır. Makine öğrenmesi yöntemlerinden destek vektör makineleri, yapay sinir ağları ve karar ağaçlarını kullanmıştır. Yaptığı analizlerde destek vektör makinelerinin en yüksek sınıflama başarısına ulaştığını görmüştür.

Yalçın (2012), yaptığı yüksek lisans tez çalışmasında epilepsi teşhisini hızlı ve doğru bir şekilde gerçekleştirmek için hastalardan alınan EEG sinyallerini normalizasyon işlemine tabii tutulmuş ve YSA ile sınıflandırma işlemi gerçekleştirmiştir. YSA'nın eğitilmesinde farklı PSO versiyonları kullanılmış, performansı geri yayılım algoritması kullanan YSA ile karşılaştırılmıştır.

Kızılkaya (2013), yaptığı yüksek lisans tez çalışmasında üç farklı algoritma yardımı ile eğitilen çok katmanlı sinir ağları ile LDL kolesterolün tahmininde kullanmış ve en başarılı algoritmayı belirlemiştir.

İstanbulu (2013), yaptığı yüksek lisans tez çalışmasında bilgisayarlı tomografi görüntülerinden kemik erimesi teşhisine yardımcı bir bilgisayar destekli teşhis sistemi geliştirmiştir.

Çentik (2013), yaptığı doktora tez çalışmasında uykudaki kişinin bacak EMG ve polisomnografi sinyallerini makine öğrenmesi yöntemlerinden k-NN, naive bayes, YSA ve SOM yapay sinir ağı ile sınıflandırmıştır.

İkinci olarak literatürde var olan bel bölgesi MR görüntüleri üzerinden görüntü işleme ile hastalık teşhisi üzerine yapılan çalışmalar aşağıda özetlenmiştir.

Koompaiojn ve ark. (2006), yaptıkları çalışmada bel bölgesi röntgen (X-ray) görüntüleri üzerinden otomatik sınıflandırma yapan bir sistem tasarlamışlardır. Özellik çıkartmada active appearance modeling (AAM) kullanmışlardır. Kanal darlığı, Spondylolisthesis, dejeneratif disk rahatsızlığı gibi durumları sınıflandıran sistem tasarlamışlardır.

Kul (2008), yaptığı yüksek lisans tez çalışmasında bel bölgesi sagittal MR görüntülerinden yapay sinir ağları kullanarak bel fıtığı teşhis ve sınıflandırması yapan bir bilgisayar destekli teşhis (BDT) sistemi tasarlamışlardır. Özellik çıkarımını dalgacık dönüşümü ve average absolute deviation (ADD) ile yapmışlardır. Elde ettikleri

özellikleri MLP ile sınıflandırmışlardır. Çalışmalarında ortalama %94 sınıflama başarısı elde etmişlerdir.

Alomari ve ark. (2010), yaptıkları çalışmada bel bölgesi sagittal MR görüntüleri üzerinden aktif şekil model ile özellik çıkartımı yapmışlar ve gibbs distributions ile bel fıtığı rahatsızlığı için sınıflandırma gerçekleştirmişlerdir. Çalışmalarında %90 sınıflama başarısı elde etmişlerdir.

Koompairojn ve ark. (2010), yaptıkları çalışmada bel bölgesi aksiyal MR görüntülerinden YSA ile otomatik segmentasyon yaparak özellik vektörleri elde etmişlerdir. Elde ettikleri bu şekilsel özellikleri MLP ile sınıflandırarak bel bölgesi rahatsızlıklarından bel fıtığı, merkezi kanal darlığı ve lateral kanal darlığı ile hypertrophy of ligament flavum & facet rahatsızlıklarının sınıflandırmasını yapan tam otomatik bir bilgisayar destekli teşhis sistemi tasarlamışlardır.

Michopoulou (2011), yaptığı doktora tez çalışmasında sagittal MR görüntüleri üzerinden bel bölgesi disklerini atlas tabanlı segmentasyon yöntemi ile segmente etmiştir.

Al-Helo ve ark. (2011), yaptıkları çalışmada bel bölgesi sagittal bilgisayarlı tomografi (CT) görüntüleri üzerinden disk bölgelerini aktif şekil ve GVF-SNAKE yöntemleri ile segmente eden tam otomatik bilgisayar destekli sistem tasarlamışlardır.

Ghosh ve ark. (2011), yaptıkları çalışmada bel bölgesi sagittal MR görüntüleri üzerinden intervertebral disklerdeki anormallikleri tespit eden bir BDT sistemi geliştirmişlerdir. İntervertebral diskleri 8'e bölerek, yoğunluk, şekilsel ve desen özelliklerini kullanmışlardır. Elde edilen özellik vektörlerini DVM, PCA+LDA, PCA+Bayes, PCA+QDA, PCA+DVM gibi çoklu sınıflayıcıları ile sınıflandırmışlardır.

Birtane (2013), omurga eğriliğine sahip skolyoz hastalarına ait röntgenler üzerinde görüntü işleme teknikleri kullanarak röntgen görüntülerini iyileştirmiş ve bilgisayar destekli teşhis yapabilme kabiliyeti sağlayan hekime teşhiste yardımcı olabilecek bir sınıflandırma yazılımı geliştirmiştir.

Üçüncü olarak literatürde var olan veri ön-işleme ve veri ağırlıklandırma yöntemleri aşağıda özetlenmiştir.

Şahan ve ark. (2005), network (ağ) tabanlı yapay bağışıklık sistemlerinde sıklıkla kullanılan şekil uzay gösteriminde euclidean mesafesinin hesaplanmasında karşılaşılan negatif etkileri uzaklaştırmak için özellik ağırlıklandırma yapay bağışıklık sistemi sınıflama algoritması önerdiler ve kalp hastalığı veri kümesine uyguladılar ve bu önerilen sistemle %82.59 sınıflama doğruluğu elde etmişlerdir.

Polat ve ark.(2006), kalp hastalığını sınıflamak için bulanık mantık tabanlı veri ağırlıklandırma ön-işleme ile YBTS sınıflama algoritmalarını birleştirdiler ve 10 kat kez çaprazlama kullanarak kalp hastalığı teşhisinde %96.30 sınıflama doğruluğu elde etmişlerdir.

Akdemir ve ark. (2007), promoter gen dizilerini sınıflamak için özellik seçme, bulanık ağırlıklandırma ön-işleme ve C4.5 karar ağacına dayanan hibrid bir sistem önerdiler. C4.5 karar ağacı, bulanık ağırlıklandırma, ön-işleme ve C4.5 bulanık karar ağacının birleşiminden elde edilen sınıflama sonuçları sırasıyla %70.08, %88.88, %76.82 ve % 93.33' tür.

Polat ve ark. (2007), kalp hastalığını teşhis etmek için bilgi kazancına dayanan özellik seçme algoritması (BKÖS), bulanık ağırlıklandırma ön-işleme (BAÖ) ve yapay bağışıklık tanıma sistemlerine (YBTS) dayanan hibrid bir sistem önerdiler ve %50 eğitim ve %50 test veri kümesi ayırımı ile %92.59 sınıflama doğruluğu elde etmişlerdir.

Polat ve ark.(2007a), k-NN tabanlı veri ağırlıklandırma ön-işleme yöntemi, bulanık kaynak dağılım mekanizmalı YBTS sınıflama algoritması ile birleştirerek bir uzman sistem önerdiler ve kalp hastalığı veri kümesinin sınıflamasına uyguladılar. Oluşturdıkları uzman sistemle %87 sınıflama doğruluğu elde etmişlerdir.

Polat ve ark.(2007c), bilgi kazancına dayanan özellik seçme ve en az kareler destek vektör makinalarını kaskad birleştirerek promoter gen dizilerinin sınıflaması problemine uyguladılar ve 10 kat çapraz ile %100 sınıflama doğruluğu elde etmişlerdir.

Polat ve ark.(2007d), bilgi kazancına dayanan özellik seçme ve Fuzzy-AIRS sınıflandırıcıyı birleştirerek yeni bir hibrid sistem önerdiler ve promoter gen dizilerinin sınıflamasına uyguladılar. Fuzzy-AIRS sınıflayıcı %50 doğruluk elde ederken, önerdikleri sistem %90 sınıflama başarısı elde etmiştir.

Hacıbeyoğlu (2012), doktora tez çalışmasında, iki aşamadan oluşan lojik fonksiyon tabanlı bir özellik seçme yöntemi geliştirmiştir. Birinci aşamada veri kümesinin doğruluk tablo görüntüsü kullanılarak indirgenmiş fark fonksiyonu oluşturulur, ikinci aşamada ise elde edilen indirgenmiş fark fonksiyonu iteratif olarak bölünerek disjunktif normal forma çevrilir ve böylece işlenmekte olan veri kümesine ait özelliklerin minimal alt kümeleri elde edilir. Geliştirilen özellik seçme yöntemi bu özelliği sayesinde diğer özellik seçme yöntemleri ile işlenemeyen veri kümelerini de başarı ile işleyebilmektedir.

1.3. Tezin Organizasyonu

Tez çalışması on ana bölümden oluşmaktadır. Birinci bölümde, tez çalışmasının konusu hakkında genel bir özet bilgi verilmektedir. Tez konusunun tanıtılması, tez konusunun amacı ve önemi konularına değinilmektedir. Ayrıca yine bu bölümde literatürdeki mevcut çalışmalara ve çalışmanın literatüre olan katkısına değinilmektedir.

İkinci Bölümde, vücut eksenleri, insan omurga yapısı, bel bölgesindeki rahatsızlıklar ve bel bölgesinin radyolojik görüntülenmesi konuları anlatılmıştır.

Üçüncü bölümde, tez çalışmasında kullanılan veriler tanıtılmıştır. Tez çalışması için elde edilen verilerin yanında UCI veritabanından alınan veriler de tanıtılmıştır. Ayrıca tez çalışmasının aşamaları blok diyagram halinde gösterilmiştir.

Dördüncü bölümde, MR görüntülerinin ön işlemlerde kullanılan yöntemler ve bu yöntemlerin verilere uygulanması anlatılmıştır.

Beşinci bölümde, ön işlemden geçirilen MR görüntülerinin özellik çıkarım yöntemleri ve özellik çıkarım aşamaları anlatılmıştır.

Altıncı bölümde, MR görüntüleri üzerinden elde edilen özellik vektörlerine uygulanan özellik seçme yöntemleri anlatılmış ve f-skor tabanlı özellik seçme ve korelasyon tabanlı özellik seçme yöntemlerinin çalışma prensipleri açıklanmıştır.

Yedinci bölümde, tezde kullanılan veri ağırlıklandırma yöntemleri tanıtılmış ve özelliği azaltılmış verilere, veri ağırlıklandırma yöntemlerinin uygulanma aşamaları anlatılmıştır.

Sekizinci bölümde, tezde kullanılan sınıflandırma yöntemleri anlatılmış ve bel bölgesi rahatsızlığının makine öğrenmesi yöntemleri ile sınıflandırılması anlatılmıştır.

Dokuzuncu bölümde, sonuçlar ve öneriler tartışılmıştır.

Son bölümde ise, tez çalışması sırasında faydalanılan bilimsel literatürün listesi yer almaktadır.

2. BEL BÖLGESİ ANATOMİSİ ve RAHATSIZLIKLARI


Bu kısımda çalışmamızda konusu geçen medikal bilgiler kısaca tanıtılacaktır. Mümkün olduğunca tıbbi terimler az kullanılmaya çalışılmıştır.

Bölüm 2.1’de vücut eksenleri, bölüm 2.2’de omurga yapısı, bölüm 2.3’de tez çalışmasında teşhis edilen bel bölgesi rahatsızlıkları anlatılmıştır.

Omurga anatomisini tanıtmadan önce vücut eksenlerinin bilinmesi önem arz etmektedir.

2.1. Vücut Eksenleri

Anatomik yapıların konumunu ve yönünü tanımlamak için birbirine dik üç düzlemden oluşan bir koordinat sistemi tanımlanmıştır. Bu koordinat sistemlerinden biri sagittal, diğeri koronal veya yanal, bir diğeri de transvers veya eksenel (aksiyal) olarak adlandırılmaktadır (Alapan, 2012). Şekil 2.1’de üç ana düzlem görülmektedir.



Şekil 2. 1 Vücut eksenleri (Alapan, 2012)


Bu tez çalışmasında sagittal ve aksiyal (transvers) MR görüntülerinden faydalanılmıştır. Ayrıca karar aşamasında sagittal ve aksiyal (transvers) MR görüntüleri bir arada kullanılmıştır.

2.2. Omurga Yapısı

Vertebral column (columna vertebralis) olarak isimlendirilen omurga, omur denen kemiklerin üst üste sıralanması ile oluşmuş içinde omuriliği barındıran kemiksi yapıdır (Dönmez, 2011).

Omurga sadece insanların değil aynı zamanda hayvanların çatısını, duruşunu destekleyen temel yapısını meydana getiren kemiksi sistemdir. Sağlıklı yetişkin bir insanda omurgaya yandan bakıldığında ‘S’ harfine benzer bir şekli vardır (Megep, 2012).


Omur, yani vertebra, omurgayı oluşturan 33-34 kemikten her birine verilen addır (Şekil 2.2). Omurlar yapıları itibarıyla ortası boşluk olan, dışa doğru çıkıntıları bulunan kemiklerdir. Omurların üst üste gelmesi ile bir kanal oluşur. Bu kanal merkezi sinir sisteminin önemli bir bölümü olan omurilik kanalıdır.



Şekil 2. 2. Bel bölgesi omuru (Sozlukanlaminedir, 2014)

Omurlar, taşıdığı yüke göre aşağıya doğru gittikçe büyür. Bel omurları aşağıda konumlanmış olmaları hasebiyle en büyük gövdeli omurlardır. Omurganın en hareketli bölümü boyun bölgesidir (Megep, 2012).


Omurlar bulundukları bölgelere göre küçük de olsa şekilsel ve fonksiyonel farklılıklar gösterebilir (Çetinkaya, 2005). Şekil 2.3’de boyun ve bel omurları görülmektedir. Omurga bu 33-34 omurun (vertebra) yanı sıra bu omurları birbirine bağlayan eklemler ve bağ dokulardan oluşmuştur (Bülbul, 2012).



Şekil 2. 3. Bel ve sırt omurları (Şenköylü, 2010)


Omurganın 3 temel görevi vardır. Bunlar: Omuriliğin korunması, dönme hareketini sağlaması ve vücut yükünün taşınmasıdır (Orman, 2009).

Omurga insanlarda yukarıdan aşağıya doğru beş ayrı bölgeye ayrılır. Sırasıyla; 7 boyun (servikal), 12 sırt (torakal), 5 bel (lomber), 5 kuyruk sokumu (sakral) ve 4-5 tanesi ise koksigeal omurdan (vertebradan) oluşmuştur (Çöl, 2011). Bunların ilk 24 tanesi hareketli son 9'u hareketsizdir (Şekil 2.4).



Şekil 2. 4. Omurga bölgeleri ve omur sayıları (Mehmetcuka, 2014)

Bel omurlarını diğer omurlardan ayıran en önemli özellikleri, büyüklükleri, gövdelerinin yan taraflarında eklem yapacak yüzeyleri bulunmayışı ve foramen transversariumlarının olmayışıdır (Çetinkaya, 2005).



Şekil 2. 5. Bel bölgesi omurları (Turanuslu, 2014)

Bel omurları yukarıdan aşağıya doğru L1, L2, L3, L4 ve L5 olarak isimlendirilirler (Şekil 2.5). En alt omur olan L5 omuru “sakrum” adı verilen kuyruk sokumu kemiğiyle eklem yapar. Sakrum üçgen biçimindedir ve beş kemiğin birleşmesinden oluşur. Hekimler sakrumun L5 omuruyla eklem yapan üst bölümünü S1 olarak adlandırır ve numaralandırırlar. Bazı insanlarda bel bölgesinde ilave bir altıncı omur var olabilir (Aydın, 2014). Omurlar arasındaki yastık işlevi gören yapıya ise disk ya da intervertebral disk adı verilir.

2.2.1. Intervertebral disk anatomisi


Bel bölgemizde omur (vertebra) kemikleri arasında disk adı verilen kıkırdaklar bulunmaktadır. Disk adı verilen özelleşmiş kıkırdaklar, omurlar arasında yastık görevi yaparak hem omurganın hareketliliğini sağlarlar hem de omurgaya binen yükü çekerler. Diskler aslında omurların birbirine sürtünmesini engelleyen ve jöle kıvamında amortisörlerdir (Doğan, 2013).

Disk, omurganın dayanma gücünü artırmakta, hareketliliğini ve zorlamalara karşı daha dirayetli olmasını, omurgaya uygulanan şok darbelerin emilmesini ve kuvvetin çevre dokulara dengeli bir şekilde dağıtılmasını sağlamaktadır (Çetinkaya, 2005; Orman, 2009; Bülbül, 2012).

Intervertebral disklerin beslenmesi lenfatikler ve ekstrasellüler yardımıyla sıvıdan ozmoz yoluyla olmaktadır. Bunun sebebi diskteki kan damarlarının erken dönemde ortadan kalkmış olmasıdır. Genç insanlarda diskin su içeriği %88’lerde iken, yaşlılarda bu oran %70’lerin altına inmektedir (Çetinkaya 2005; Orman, 2009; Bülbül, 2012).

Diskler bel bölgesine binen yükleri dağıtmaları bakımından amortisörlere, diskler arasındaki sıvının sızmasını önlemelerinden dolayı da musluk contalarına benzetilebilir. Diskler, şekil değiştirme kabiliyetine sahip olup, omurların hareketi ile belin bir bütün olarak çalışmasını sağlarlar (Çevikcan, 2007).

Sipinal kolonun ortasında yer alan boş bölgede bulunan spinal kanalda omurilik ve diğer sinir kökleri bulunmaktadır. Disklerin iç kısmında nükleus pulpozus denen jöle kıvamında yumuşak bir bölüm, bunun dışında annulus fibrozus adı verilen daha sert bir fibröz tabaka (Şekil 2.6), omur kemiklerine bakan yüzlerde ise her iki tarafta son plak olarak adlandırılan kıkırdak yapıları vardır (Çevikcan, 2007).



Şekil 2. 6. Intervertebral disk anatomisi (Nml, 2014)

Nukleus Pulpozus: Nukleus pulpozus büyük oranda notokord kaynaklıdır. Çocuklarda nukleus pulpozus yetişkinlere göre daha yumuşak, daha akışkan ve oransal olarak daha büyüktür. Histolojik olarak miksoid veya kondroid bazofilik bir proteoglikan matriks ve bu matriks içerisinde gelişigüzel dağılmış ince kollagen liflerden oluşur. Kitlesinin % 80-90'nını su oluşturur. Kuru ağırlığının % 65'ini proteoglikanlar, % 20'sini kollajenler ve kalanını da elastin oluşturur (Çakır, 2009).

Annulus Fibrozus: Doku yapısı olarak, kollajenöz yapıda fibröz doku ve kıkırdaktan oluşur. Hücreleri, kondrositlerden fibroblastlara kadar varan bir spektrum gösterir. Kitlesinin % 60-70'ini su oluşturur. Kuru ağırlığının %60'ı kollajen, %20'si proteoglikanlardan oluşur. Minör komponent olarak elastin içerir. Normal koşullarda nukleusu hapseden annulus fibrozus ve kıkırdak uç plakları, büyük yüklenmeler karşısında engelleyecek güçtedir. Buna rağmen, bütün disklerde potansiyel olarak iki zayıf nokta bulunur: 1) Kıkırdak uç-plakları 2) Annulusun arka segmenti. Annulusun posterior bölümü ön bölümüne göre daha incedir ve kemiklere daha zayıf yapışır. İşte

disk bu iki yerden fıtıklaşır. Nukleusun ön ve yanlardan fıtıklaşması çok nadirdir (Çakır, 2009).

İnsan belinde bulunan beş adet omur (L1,L2,L3,L4 ve L5) ve aralarındaki diskler, birbirine kenetlenmiş olarak bir bütün oluştururlar. Ayrıca omurganın arka kısmında bulunan eklemler de (Bunlar faset eklemler olarak adlandırılmaktadır.) kapsül denilen eklem zarı ile kuşatılır ve bağlarla güçlendirilmişlerdir. Faset eklemleri vücut yükünün % 5-20'sini taşımaktadırlar (Anonim, 2013). Yanlış şekilde ve fazla miktarda yük kaldırma gibi durumlarda, zamanla faset eklemlerinde bozulmalar ve ayrılmalar oluşur.

Her bir omurun sağında ve solunda küçük deliklerden çıkarak aşağıya uzanan sinirler yer almaktadır. Bu sinirlere omurilik sinirleri denilmektedir. Omurilik sinirleri özellikle bacak kaslarımızın kuvvetini ve ilgili derinin duyusunu sağlarlar. Bir başka deyişle, bu sinirler sayesinde hareket sağlayabiliriz. Bunun yanında ısı, basınç ve ağrı gibi duyuları algılayabiliriz. Bu sinirler bir nevi alarm sistemine benzerler. Örneğin; vücudumuzda bazı yapıların hasara uğradığını veya hasara maruz kalabileceğini bildiren, ağrı duyusudur. Siyatik sinir, bu sinirlerin birkaçının bir araya gelmesinden oluşur. Bu sinirler her iki bacağa dallar verir ve basıya maruz kaldığında veya hasara uğradığında dizin aşağısına doğru yayılan bacak ağrısı oluştururlar (Anonim, 2013).

2.3. Bel Bölgesi Rahatsızlıkları

Bel rahatsızlıkları, bir kaza, ani bir zorlama ya da tehlikeli bir aktivite ile oraya çıkabileceği gibi belirgin bir neden olmadan da ortaya çıkabilir. Bel rahatsızlıkları sürekli bir ağrı ile bizi rahatsız edebileceği gibi hayatımızın belli bir döneminde ortaya çıkıp yok olabilir. Dünyada yapılan araştırmalar insanların %80'inin hayatları boyunca en az bir kez bel ağrısı yaşadıklarını ortaya koymuştur. Genel popülasyonda hekime başvurma ve işgücü kaybı açısından soğuk algınlığından sonra ikinci sırada yer almaktadır (Üstün, 2014).


Travmaya maruz kalanların dışında hareketsiz bir yaşam şekline sahip olanlar, dengesiz ve yanlış ağır kaldıranlar, uzun yol şoförleri, uzun süre oturan ofis çalışanları, fazla kilolular, yanlış duruş pozisyonuna sahip olanlar, zayıf karın ve bel kaslarına sahip olanlar, hamileler, halter gibi sporlar ile uğraşanlar, bel ağrısı için riskli grubu oluşturmaktadırlar (Üstün, 2014).

Tez çalışmasında incelenen bel rahatsızlıkları aşağıda açıklanmıştır.

2.3.1. Bel fıtığı

Bel bölgesi omurları insan vücut ağırlığının büyük kısmını çekmektedir. Bel fıtığı diğer birçok bel rahatsızlığında olduğu gibi bel omurlarına fazla yük binmesi ile oluşmaktadır. Ağır yük kaldırmak, yana dönerek eğilmek, ağır bir yükü itmek, çekmek, yüksekte düşmek, bel bölgesine darbe almak vb. nedenlerle ortaya çıkabilmektedir. Eğilerek yerden kaldırdığımız 10 kg.'lık bir yük, diskin üzerine 100 kg.'lık bir ağırlık bindirir (Çakır, 2009).

Bel fıtığı; disk içerisindeki jöle kıvamlı yapının (nukleus pulpozusun), diski çevreleyen daha katı yapıda (annulus fibrozusdaki) oluşan yırtıklar yoluyla spinal kanala doğru uzanım göstermesidir (Şekil 2.7). Fıtıklaşan bu kısım sinir köklerine bası yaparak ağrıya sebep olmaktadır. Ayrıca fıtıklaşmış diskten ortama salınan bazı kimyasal maddeler de sinir köklerini etkileyerek ağrıya neden olurlar. Bel fıtığı (disk hernisi) en sık lomber bölgede görülür ve bel ağrısının en sık nedenlerinden biridir. Bel ağrısı, iş gücü kaybına yol açan hastalıklar arasında ilk sıralarda yer almaktadır. Bel ağrısı şikâyeti ile sağlık kuruluşlarına başvuran hastaların ortalama %2-5'inde bel fıtığı saptanmıştır (Çakır, 2009).




Şekil 2. 7. (a) Sağlam disk, (b) fıtıklı diskin sinire yaptığı bası (Physioworks, 2014)

Bel fıtığı tıpta dört şekilde sınıflandırılır. Bunlar;

- 1) Bulging: Nukleus pulpozusun annulus fibrozusa doğru yer değiştirmesidir.
- 2) Protrüzyon (prolapsus): Nukleus pulpozusun yırtılan annulus fibrozus lifleri içine doğru yer değiştirmesidir. Annulus fibrozusun dış lifleri sağlamdır.
- 3) Ekstrüzyon: Nukleus pulpozusun annulus fibrozusu yırtarak spinal kanal içine doğru taşmasıdır. Annulus fibrozusun tüm lifleri yırtılmıştır.


- 4) Sekestrasyon: Disk materyalinin koparak serbest materyal halinde spinal kanal içinde bulunmasıdır (Çetinkaya, 2005). Şekil 2.8’de bel fıtığının dört aşaması görülmektedir.



Şekil 2. 8. Bel fıtığının dört aşaması (Spinalstenosis, 2014)

Klinik Belirtileri: Bel fıtığının en belirgin belirtisi belin belli kısımlarında ki lokal ağrılardır. Bu ağrı zamanla giderek artmakta, hareket ettikçe batma hissi oluşturmaktadır. İstirahat halinde ise azalma eğilimi gösterir. İkinci en önemli belirtisi ise bası gören sinir kökünün konumuna göre sağ ya da sol ayağa doğru yayılan ağrılardır. Azalan ağrı arkaya eğilme, öne eğilme ya da ters bir hareketle tekrar şiddetlenebilmektedir. Bazı durumlarda kişilerde hareket dahi edememe durumu (kilitlenme) ve bel tutulmalarına dahi yol açabilmektedir. Ayakta uzun süre durmak, yine uzun süre oturmak, ıkınmak, öksürmek, araç kullanmak ağrının artmasına sebebiyet verirken yatmak ve bel bölgesinin desteklenmesi ağrının azalmasını sağlar (Çetinkaya, 2005).

Omurgadaki fıtıklar sadece bel bölgesinde olmaz, omurgadaki oluştukları bölgeye göre adlandırılırlar. Örneğin bir insanda bel bölgesi fıtıkları olabileceği gibi boyun fıtıklarına da rastlanabilir. Bel bölgesindeki fıtıklar daha çok alt omurlar arasındaki disklerde görülür. Fıtıklar görüldükleri disk aralıklarına göre isimlendirilirler. Bel fıtıklarının %90’ı L4-L5 ya da L5-S1 omurları arasındaki disklerde görülmektedir (Kul, 2008). Şekil 2.9’da sagittal MR görüntü üzerinde L5-S1 omurları arasında oluşmuş bel fıtığı görülmektedir.



Şekil 2. 9. Bel fıtığının sagittal MR'da görüntülenmesi

2.3.2. Dejeneratif disk hastalığı

Disk dejenerasyonunun birçok sebebi olmasına rağmen, dejenerasyon temel olarak hücreler arası matrisi üreten hücresel aktivitenin azalması veya durmasıyla oluşur (Alapan, 2012).

Dejeneratif disk hastalığı (DDH), disk dokusunun morfolojik ve biyokimyasal yapısındaki değişikliklerin klinik olarak ağrı oluşturmaları ile karakterize olan bir hastalıktır (Yavuz, 2010).

Dejenere olmuş nucleus pulposusun içeriğindeki sıvı oranı azalır ve anulus fibrozusda genellikle çatlaklar görülmekle beraber biyomekanik özellikleri de değişebilir.

Diskteki su kaybı diskin incelmesine sebep olmakta ve böylece disk yüksekliğinde azalma meydana gelmektedir. Disk dejenerasyonu düzensiz son plak oluşumu, diskte skleroz gelişimi, osteofit oluşumu ve faset eklem osteoartrit oluşumu gibi bozuklukları da beraberinde getirmektedir.

Disk dejenerasyonu aynı yaş aralıkları için erkeklerde kadınlara oranla daha çok görülmekle birlikte, bütün disklerin yaşlanmayla birlikte dejenere olduğu tespit edilmiştir. Yapılan bir çalışmada incelenen 600 lomber intervertebral disklerde 50 yaş ve üzerindeki disklerin %90'ında dejenerasyon tespit edilmiştir (Alapan, 2012).




Şekil 2. 10. Dejeneratif disk rahatsızlığının sagital MR'da görüntülenmesi

Disk dejenerasyonu MR ile görüntülenerek tespit edilebilir. Sagital MR görüntüleme ile incelenen hastanın bel bölgesinde normal olan diskler parlak görünürken, dejeneratif diskler ise koyu olarak görünmektedir. Şekil 2.10’da normal ve dejeneratif disk’e sahip bir sagital MR görülmektedir.

2.3.3. Omur kayması

Omur kayması(spondilolistezis), iki komşu omurdan üstteki omurun alttaki omura göre öne doğru kayması veya yer değiştirmesi olup ve bel bölgesini kasteden bir omurga rahatsızlığıdır (Şekil 2.11). Bu rahatsızlık halk arasında “omur kayması” ya da “bel kayması” olarak adlandırılmaktadır.

Omur kayması, bel ağrısının en önemli nedenlerinden biridir. Spondilolistezis ağrının yanında kayma miktarına bağlı olarak daha ciddi sorunlara neden olabilir. Ağrı ile hastaların yaşam kalitesi, mesleki performansı ve yaptığı spor aktiviteleri engellenir. Bu durum hastaların yaşamlarında psikolojik bozukluklar, bireysel ve sosyal ilişkilerde bir takım sorunları da beraberinde getirmektedir (Özlü, 2012; Varyemez, 2010).



Şekil 2. 11. Omur kayması (Omurgaomurilik, 2014)

Başka omurlarda görülmekle beraber omur kayması en sık L5 omurun S1 omuru üzerinde kayması şeklinde görülmektedir. Bel ağrısı şikâyeti ile doktora başvuran hastaların %5 ila 10'unda bel kayması olduğu tespit edilmiştir (Anonim, 2012).

2.3.4. Lomber spinal stenoz

Lomber spinal stenoz (LSS), omurga kanalının lomber parçasının değişik sebeplerle oluşan daralmasıdır (Tekin, 2010). LSS stenozun anatomik lokalizasyonuna göre veya etiyolojiye göre iki şekilde sınıflandırılabilir. Anatomik lokalizasyona göre LSS ikiye ayrılır; santral ve lateral stenoz.

Lomber spinal stenoz (LSS); santral spinal kanal veya sinir kökü kanallarının fokal, segmental veya diffüz daralmasına bağlı sinir kökü kompresyonu sonucu görülen bir klinik durumdur. Lomber omurganın ekstansiyona gelmesiyle artan sinir kökü kompresyonu sonucu gelişen bel ağrısı alt ekstremiteye yayılan radiküler ağrı LSS'nin karakteristik özellikleri olarak tanımlanmaktadır. Ancak LSS ile en çok özdeşleştirilen klinik bulgu nörojenik kladikasyo veya başka bir deyişle psödokladikasyodur. Nörojenik kladikasyo; kalça ve uyluk ön yüzünden bacak arkasına doğru yayılan ağrı, uyuşma ve parestezi ile karakterize bir durumdur.

LSS'li hastalarda sık rastlanan muayene bulguları:

- Lomber lordozda azalma
- Alt lomber omurgada tutukluk, lomber omurga ve kalça eklem hareket açıklığı (EHA)'nda azalma
- Anormal refleksler

- Duyu ve motor deęişiklikleridir

LSS tanısı; genellikle belirti ve bulguların varlığı ile daralmanın olduęu düzeyde spinal kanalın ön-arka çapının ve bu düzeyde spinal kanal alanının azalmasının ölçülmesi ile konulmaktadır. Bu ölçümler sıklıkla bilgisayarlı tomografi (BT) veya manyetik rezonans görüntüleme (MRG) ile yapılmaktadır. Spinal kanal ön-arka çapının 10-12 mm arasında olması rölatif spinal stenoz, 10 mm'den az olması ise kesin spinal stenoz olarak kabul edilir. Ancak radyolojik ölçümler ile hastalığın kliniğı arasında bir korelasyon olmadığı gösterilmiştir (Bekci, 2010).

2.4. Bel Bölgesinin Radyolojik Olarak Görüntülenmesi

Bel rahatsızlıklarının teşhisinde dięer rahatsızlıklarda olduęu gibi, iyi bir sorgulama ve fizik muayene şarttır. Belde ağrı, ayaklarda uyuşma ve bacaklarda güç kaybı gibi şikâyetlerin bulunması hastada bel rahatsızlığının ciddi oranda bulunma riskini artırmaktadır. Hasta genellikle yol yürümede, ayakta durmada ve oturmakta zorlanır. Kesin Tanı için radyolojik görüntüleme yöntemleri gerekmektedir.

Bel rahatsızlıkları teşhisi için, klinik muayene bulguları ile direkt röntgen (X-ray), MR (manyetik rezonans), CT (bilgisayarlı tomografi) tetkikleri sıklıkla kullanılmaktadır. Sinirlerin elektro fizyolojik tetkiki olan miyografi ise bası altında kalan sinirlerde hasar olup olmadığı ve varsa hasarın derecesini belirleyebilmek için nadiren kullanılan bir yöntemdir (Çevikcan, 2007).

2.4.1. Röntgen (X-ray)

Bel ağrısının araştırılmasında düz röntgen filmlerinin önemi günümüzde azalmıştır. Hastanın radyasyona maruz kalmasına yol açan bu teknik ile sert kemik yapısı görüntülenmekte yumuşak doku ise röntgen ile görüntülenememektedir. Omurgada kırık ya da narrowed disk space gibi durumlar röntgen ile tespit edilebilir (Kul, 2008). Yeni görüntüleme tekniklerinin ortaya çıkması ve bu yeni yöntemlerin detaylı avantajlar getirmesi ve röntgen yönteminin radyasyon gibi zararlarının bulunması bu görüntüleme yönteminin gözden düşmesine sebep olmuştur. Şekil 2.12'de bel bölgesi röntgen görüntüsüne ait bir örnek görülmektedir.



Şekil 2.12. Bel bölgesi röntgen görüntüsü (Tronlyimage, 2014)

2.4.2. Magnetik rezonans görüntüleme (MRG)

MR inceleme, nörolojik hastalıklara ait semptom ve bulguları olan hastalarda primer görüntüleme yöntemidir. MR görüntüleme, çoğu diğer nörolojik görüntüleme yöntemlerinin (konvansiyonel anjiyografi ve myelografi gibi) yerini almıştır. Özellikle batin, pelvis, kardiyovasküler sistem ve kas-iskelet sistemini ilgilendiren MR görüntüleme, sürekli gelişen bir inceleme modalitesidir. MR incelemenin modern tıpta büyük bir etkisi olduğu şüphesizdir (Kayar, 2011).

Vücudumuz primer olarak yağ ve sudan oluşmakta ve bu oluşumların moleküler yapısında ağırlıklı olarak hidrojen atomları bulunmaktadır. Manyetik rezonans görüntüleme; su ve yağın, dolayısı ile de vücudumuzun büyük bir bölümünün yapısında mevcut bulunan (%63) hidrojen atomlarının, güçlü bir manyetik alan içerisinde, kendilerini rezonansa uğratacak bir radyo frekans (RF) dalgası ile uyarılıp titreştirilmesinden elde edilen sinyallerin görüntüye dönüştürüldüğü doku kontrast rezolüsyonu en yüksek ileri radyolojik görüntüleme tekniğidir (Oyar, 2008).


Manyetik rezonans görüntüleme; yumuşak doku kontrast çözümleme gücü en yüksek görüntüleme yöntemi olduğundan dolayı tercih edilmektedir. Vücudun büyük bölümünü oluşturan yumuşak dokuların yüksek kontrast çözünürlüğü altında birbirinden ayrıştırılması, içyapılarının daha iyi bir şekilde ortaya konmasını sağlamaktadır. MRG ile hastanın pozisyonunu değiştirmeden çok düzlemden görüntüler elde edilebilir (Oyar, 2008).

MRG detaylı bir görüntüleme sağlar. Aynı zamanda acısız ve radyasyonsuz bir çekim sağlamaktadır. Her bir MR görüntüsü kesit (slice) denen dilimler ile taranır ve böylece birçok MR resmi elde edilir.

Pratikte MR çekimlerinin %60-80'lik bölümünü santral sinir sistemi (beyin, beyin sapı, beyincik, omurga-omurilik-disk hastalıkları) incelemeleri oluşturmaktadır. Geri kalan yaklaşık %15-20'lik bir bölümünü kas-iskelet sistemi (diz, kalça, omuz, el-ayak bileği, dirsek), geri kalanını ise abdomen (karaciğer), pelvik, baş-boyun ve toraks incelemeleri oluşturmaktadır (Oyar, 2008).

MRG ile disklerin hem morfolojik hem de biyokimyasallıkları hakkında bilgi edinebilir. Nükleus annulustaki azalma, disk aralığındaki daralmalar, diskteki şişkinlikler gibi birçok morfolojik değişiklikler MR ile rahatlıkla gözlemlenebilmektedir (Kul, 2008; Michopoulou, 2011).

MRG'nin dezavantajları, başlıca incelemenin yapıldığı cihazın manyetik alan gücü ve tekniğin yarattığı etkenlere bağlıdır. Bunların başında da üzerinde kalp pili, nörostimülatör, infüzyon pompası gibi aygıtları taşıyan hastalar üzerindedir. Bu cihazlar manyetik alandan etkilenerek işlev göremez hale gelebilir ve hastanın hayatını tehlikeye sokabilmektedirler (Oyar, 2008). Şekil 2.13'de bel bölgesi aksiyal MR görüntüsü görülmektedir.




Şekil 2. 13. Bel bölgesi aksiyal MR görüntüsü

Magnetik rezonans ile dokuların karakterize edilmesinde, dokudaki proton miktarı ile T_1 ve T_2 relaksasyon sürelerindeki farklılıktan faydalanılır. Dokulardaki proton miktarlarının farklı olmasına bağlı olarak elde edilen görüntülere, “proton ağırlıklı”, sürelerinin farklı olmasına bağlı olarak elde edilen görüntülere “ T_1 ağırlıklı” ve T_2 sürelerinin farklı olmasına bağlı olarak elde edilen görüntülere de “ T_2 ağırlıklı” görüntüler adı verilmektedir (Asyalı, 2006; Oyar, 2008).

Görüntü oluşturma amacıyla gönderilen radyo frekans sinyallerinin arasındaki süre (Time Repetition) ile sinyal dinleme süresi (Time Echo) değiştirilir.

- T1 ağırlıklı görüntülerde radyo frekans pulsu arka arkaya kısa aralıklarla gönderilir ve Time Echo kısa tutulur.
- T2 ağırlıklı görüntülerde Time Repetition ve Time Echo uzun tutulmaktadır.
- Proton ağırlıklı görüntülerde Time Repetition uzun, Time Echo kısa tutulur.

Protonların eski durumlarına dönüş süresindeki farklılıklar dikkate alınırsa T1 görüntü oluşur. T1 ağırlıklı görüntülerde su siyahtır. Sinyalin sönüş süresi dikkate alırsa T2 görüntü oluşur. T2 ağırlıklı görüntülerde su beyaz görünür. Yağ dokusu T1 ve T2 'de beyaz görünür (Anonim, 2014). Şekil 2.14'de T1 ve T2 ağırlıklı sagittal MR görüntüleri görülmektedir.



Şekil 2. 14. Bel bölgesi T1 ve T2 ağırlıklı sagittal MR görüntüleri (Neurologyindia, 2014)

2.4.3. Bilgisayarlı tomografi

Bilgisayarlı tomografi kemik ve omurga yapısının gayet iyi görüntülenebilmesini sağlayan görüntüleme yöntemidir.

Bilgisayarlı tomografi, radyolojinin iyonizan enerji kullanan bir yöntemidir. Bilgisayarlı tomografide temel olarak, X ışını üreten bir tüp ve hastadan geçen X ışınlarını saptayarak elektriksel sinyallere dönüştüren bir detektör takımı vardır. Bu detektör takımının sayısı, yerleşim yeri ve hareket açıları, BT'nin gelişim jenerasyonlarına bağlı olarak değişiklik göstermiştir. İlk ortaya çıktığında tek detektörle çok yavaş görüntüler oluşturabilen BT, artık bir saniyede birden fazla görüntü oluşturabilecek kapasitelere gelmiştir.

Bilgisayarlı tomografi üç boyutlu vücut bölümlerinden iki boyutlu kesitsel görüntüler oluşturan bir sistemdir. Üç boyutlu bir yapının iki boyutlu görüntüsü

oluşturulurken rekonstrüksiyon olarak adlandırılan matematiksel teknikler kullanılır. Görüntüler genellikle aksiyal (transvers) düzlemlerden elde edilir. Hastaya pozisyon verilerek koronal kesitler de elde edilebilir. Multidetektör BT sistemlerinde tek plandan elde edilen görüntüler, reformat tekniklerle, belirgin netlik ve keskinlik kaybı olmaksızın farklı düzlemlere dönüştürülebilmektedir (Boztok Özgermen, 2014). Şekil 2.15’de bel bölgesi bilgisayarlı tomografi görüntüsü görülmektedir.




Şekil 2. 15. Bel bölgesi bilgisayarlı tomografi görüntüsü (Tumorlibrary, 2014)

2.4.4. Myelografi

Belden iğne yardımı ile bel bölgesine kontrast etken madde verilerek film çekilmesi tekniğine myelografi denilmektedir. Myelografinin kullanımı günümüzde neredeyse kalmamıştır. Günümüz görüntüleme tekniklerinin çok ilerlemiş olması ve büyük riskler içeren hastanın belinden iğne yapılması uygulamasına gerek bırakmamıştır.

Günümüzde myelografi; MR cihazına giremeyen hastalar, dar spinal kanalı kök basısı konfirme edilemeyen bel fıtığı saptanan hastalar ve çok seviyede bel fıtığı bulunan hastalarda semptomlara neden olan en yüksek olasılıklı düzeyi tanımlamak için uygulanmaktadır. Ancak myelografinin birçok dezavantajları bulunmaktadır. Radyasyon riski taşır, kullanılan intratekal kontrast maddelerin bulantı, baş ve boyun ağrısı gibi bazı yan etkileri bulunmaktadır. Ayrıca, enfeksiyon ve kanama riski bulunan invazif inceleme yöntemidir (Erdem ve ark., 2004). Şekil 2.16’da myelografi uygulanmış hasta görüntüsü verilmiştir.




Şekil 2. 16. Myelografi uygulanmış hasta görüntüsü (Medicastore, 2014)

Bu dezavantajlarından dolayı myelografiden mümkün mertebe uzak durmakta yarar vardır. Bunun yerine güçlü manyetik rezonans cihazları tercih edilmelidir.

2.4.5. Diskografi

Diskogram da denilen diskografi, bel ağrısının bir veya birkaç diskten kaynaklandığını belirlemek için kullanılan bir tanısal işlemdir. Bu işlem, etkilenen disklere steril sıvı enjekte ederek basınçlarını arttırmayı ve ağrıyı uyarmayı içerir (Aşık, 2014). Diskografi, doktorun bir tedavi planlamasına yardımcı olur.

Diskogram sırasında, birkaç omuriliğinin merkezine alçak basınç altında bir sıvı enjekte edilir (Şekil 2.17). Daha sonra, disklerin zarar görüp görmediğini anlamak için bir röntgen veya BT taraması yapılır.



Şekil 2. 17. İntervertebral disk e diskografi işleminin uygulanması (Gsmedical, 2015)

Hastalar floroskopi ünitesi olan bir masanın üzerinde yüzüstü veya yan yatırılırlar ve açılan damar yolundan hastayı rahatlatmak için ilaç başlanır. Burada

hastanın ne hissettiğini doktora anlatabilecek kadar uyanık olması önemlidir. Uygulanan lokal anestezi, cildi ve disk alanına kadar olan dokuları uyuşturur.

Doğru yeri belirlemek için floroskopi kullanılarak, anestetize yol boyunca diskin dış kenarına kadar rehber iğne girilir. Rehber iğnenin içinden diskin merkezine kadar daha ince bir iğne sokulur. Bu, birden fazla disk için tekrarlanabilir.

Tüm iğneler yerleştirildiğinde, kontrast madde enjeksiyonu ile disklere basınç verilir. Her enjeksiyon ile hasta ağrı veya basınç hisseder. Eğer ağrı hissedilirse, bu ağrının hastanın daha önceki ağrısı ile kıyaslanması istenir. Eğer aynıysa, bu hastalıklı diski gösterebilir.

Her disk kontrol edildikten sonra, floroskopi ünitesinde görüntüler alınır. Disklerin ek görüntülerinin alınması için röntgen veya BT çekilebilir (Aşık, 2014). Bu yöntemin de yine dezavantajları bulunmaktadır. Hasta radyasyona maruz kalmaktadır. Ayrıca enjeksiyon ile kanama ve enfeksiyon riski bulunmaktadır. Bu dezavantajlarından dolayı bu yöntemin kullanımı azalmıştır (Ertan, 2002).

3. MATERYAL VE YÖNTEM

3.1. Tez Çalışmasında Kullanılan Medikal Veriler

Bu tez çalışmasında iki farklı veritabanı kullanılmıştır. Bunlardan birincisi Selçuk Üniversitesi Tıp Fakültesi Radyoloji Bölümünden alınan bel bölgesi rahatsızlıkları veritabanıdır. Tez çalışmasında kullanılan ikinci veritabanı ise California Üniversitesi uluslararası irvine makine öğrenmesi veritabanından (UCI) alınan vertebral column dataset'dir. Bu veritabanları bölüm 3.1.1 ve 3.1.2'de detaylı olarak açıklanmıştır.


3.1.1. Tez çalışması için elde edilen veritabanı

Bu veritabanı Selçuk Üniversitesi Tıp Fakültesi Hastanesi Radyoloji Bölümünden alınan bel bölgesi rahatsızlıkları veritabanıdır. Bu veritabanında hem aksiyal hem sagittal MR görüntüleri yer almaktadır. MR'lar T2-ağırlıklı midsagittal görüntülerden oluşmaktadır. Görüntülerin alınması için kullanılan cihaz Siemens Magnetom Symphony 1.5 Tesla scanner cihazıdır. Görüntü koleksiyonu, uzman radyolog doktorun gözetimi altında her bir görüntü kesiti tek tek incelenerek oluşturulmuştur. Kaydedilen bu görüntülere ait radyoloji raporu kullanılarak da görüntülerin doğru bir şekilde etiketlenmesi sağlanmıştır.

Bel bölgesi aksiyal ham MR görüntüleri gri seviye olup, JPEG formatındadır. Görüntüler 512x512 pikseldir ve görüntülerde ilgisiz arka plan alanlar bulunmaktadır.

Benzer şekilde sagittal ham MR görüntüleri de gri seviye olup, JPEG formatındadır. Görüntüler 512x512 pikseldir ve görüntülerde ilgisiz arka plan alanlar bulunmaktadır.

Tez çalışması için elde edilen ham sagittal ve aksiyal MR görüntülerinde birer örnek Şekil 3.1'de verilmiştir.



Şekil 3. 1. Tez çalışmasında kullanılan (a) aksiyal ve (b) sagittal MR görüntüleri

Toplam 55 hastanın her birinden bir adet sagittal MR görüntüsü alınmıştır. Yine bu 55 hastanın her bir disk aralığından L1-L2, L2-L3, L3-L4, L4-L5 ve L5-S1'den birer tane olmak üzere toplamda $55 \times 5 = 275$ adet aksiyal MR görüntüsü alınmıştır. Toplamda $275 + 55 = 330$ adet aksiyal ve sagittal MR görüntüsü elde edilmiştir.

Tez çalışmasında kullanılan MR'ların alındığı hastalara ilişkin istatistiki bilgiler Çizelge 3.1'de görülmektedir. Buna göre 55 hastanın 26 kişisi erkek, 29 kişisi ise kadınlardan oluşmaktadır. Erkek hastaların yaş ortalaması 33.84, kadın hastaların yaş ortalaması ise 36.52'dir. Yine erkek hastaların kilo ortalaması 68.34, kadın hastaların kilo ortalaması ise 66'dır. Toplam 26 adet erkek hastanın 13 tanesinde anormalite vardır. Yine toplam 29 olan kadın hastanın 17 sinde ise anormalite vardır.

Çizelge 3.1 Alınan verilere ilişkin istatistiki değerler

Cinsiyet	Kişi Sayısı	Ortalama Yaş	Ortalama Kilo	Anormalite	Normal
Erkek	26	33.84	68.34	13	13
Kadın	29	36.52	66	17	12

3.1.2. UCI makine öğrenmesi veritabanından alınan veriler

İnsan omurga alanındaki problemleri içeren bir veri kümesidir. Bu veri kümesinde 3 sınıflı (normal, bel fıtığı, omur kayması) ve 2 sınıflı (normal ve anormal) olan iki farklı veritabanı mevcuttur. 3 sınıflı olan veri setinde 100 kişi normal, 60 kişi bel fıtığı ve 150 kişi de ise omur kayması durumu vardır. 2 sınıflı veri setinde ise 100 kişi normal ve 210 kişi anormal (rahatsız) olmak üzere organize edilmiştir.

Her hastadan:

- Pelvik görülme sıklığı (Pelvic_incidence)
- Pelvik eğimi (Pelvic_tilt),
- Lomber lordosis açısı (Lumbar_Lordosis_Angle),
- Sakral eğim (Sacral_slope),
- Pelvik yarıçapı (Pelvic_radius),
- Spondilolistezis derecesi (degree_spondylolisthesis),

olmak üzere 6 özellik vektörü alınmıştır. Veri setlerinde etiketler şu şekilde belirlenmiştir: DH (Disk Hernia), Spondylolisthesis (SL), Normal (NO) ve Abnormal (AB). 3 sınıflı UCI vertebral column datasetin istatistiki bilgileri Çizelge 3.2’de görülmektedir (UCI, 2015).

Çizelge 3.2. UCI veritabanından alınan özelliklerin istatistiki değerleri

	Sınıflar		
	<i>Bel Fıtığı (Disc Hernia)</i>	<i>Spondylolisthesis</i>	<i>Normal</i>
Birinci Özellik <i>Pelvic_incidence</i>			
Ortalama	47.6375	71.511	51.6786
Standart Sapma	10.6179	15.0629	12.3124
Ağırlıklı Toplam	60	150	100
Kesinlik	0.3356	0.3356	0.3356
İkinci Özellik <i>Pelvic_tilt</i>			
Ortalama	17.397	20.7447	12.8154
Standart Sapma	6.9559	11.4675	6.7344
Ağırlıklı Toplam	60	150	100
Kesinlik	0.1812	0.1812	0.1812
Üçüncü Özellik <i>Lumbar_Lordosis_Angle</i>			
Ortalama	35.4719	64.1057	43.5395
Standart Sapma	9.6615	16.341	12.2925
Ağırlıklı Toplam	60	150	100
Kesinlik	0.4005	0.4005	0.4005
Dördüncü Özellik <i>Sacral_slope</i>			
Ortalama	30.2575	50.7869	38.8601
Standart Sapma	7.5055	12.269	9.5732
Ağırlıklı Toplam	60	150	100
Kesinlik	0.3859	0.3859	0.3859

	Sınıflar		
	<i>Bel Fıtığı (Disc Hernia)</i>	<i>Spondylolisthesis</i>	<i>Normal</i>
Beşinci Özellik <i>Pelvic_radius</i>			
Ortalama	116.4663	114.5173	123.8883
Standart Sapma	9.2839	15.5397	8.9667
Ağırlıklı Toplam	60	150	100
Kesinlik	0.3009	0.3009	0.3009
Altıncı Özellik <i>degree_spondylolisthesis</i>			
Ortalama	2.5025	51.9044	2.2384
Standart Sapma	5.56	39.9608	6.2791
Ağırlıklı Toplam	60	150	100
Kesinlik	1.3903	1.3903	1.3903

3.2. Tez Çalışmasının Aşamaları

Tez çalışması beş aşamadan oluşmaktadır. Bunlar sırası ile ön işlem, özellik çıkarımı, özellik seçimi, veri ağırlıklandırma ve son olarak sınıflandırma aşamalarıdır. Tez çalışmasının aşamalarını gösteren blok diyagram Şekil 3.2’de görülmektedir.



Şekil 3. 2. Tez çalışmasının blok diyagram ile gösterimi

Ön işlem aşamasında ham olarak elde edilmiş olan MR görüntüler üzerinde, gereksiz alanların atılması, gürültü giderme ve görüntü iyileştirilmesi gibi işlemler yapılmıştır. Bu aşamada histogram eşitleme, medyan filtreleme ve kesme işlemleri uygulanmıştır. Bu sayede daha kaliteli ve temiz MR görüntüleri elde edilmiştir.

Özellik çıkarımı aşamasında hastalığın teşhisine etki edecek gerekli ölçümler elde edilmiştir. Bu aşamada sagittal MR görüntülerinde aktif şekil modeli kullanılarak özellik vektörleri elde edilmiştir. Aksiyal MR görüntülerinde ise spinal kanal bölgesi

biçimsel özellikleri ölçülmüştür. Bu ölçümler sınıflandırma aşamasına giriş olarak kullanılmıştır.

Özellik seçimi aşamasında hangi özelliklerin daha önemli olduğu belirlenerek önemli özellikler seçilmiş ve daha az önemli özellikler veri kümesinden çıkartılmıştır. Bu aşamada f-skor tabanlı özellik seçimi ve korelasyon tabanlı özellik seçim yöntemleri uygulanmıştır.

Veri ağırlıklandırma aşamasında ise önceki aşamada seçilmiş olan özellik vektörleri ikili bulanık c-ortalama ve ortalama kayma kümeleme algoritmaları kullanılarak daha kolay sınıflandırılabilir hale getirilmiştir. Böylece sınıflama başarısı arttırılmıştır.

Sınıflandırma aşamasında ise veri kümesindeki sağlıklı ve hasta veriler çeşitli makine öğrenmesi yöntemi ile sınıflandırılmıştır. Bu aşamada destek vektör makineleri, çok katmanlı perseptron, öğrenme vektör quantalama, k-en yakın komşulu algoritması ve radyal tabanlı fonksiyon sinir ağları yöntemleri uygulanmıştır.

Burada bahsi geçen tüm yöntemler ilerleyen bölümlerde detayları ile açıklanmıştır.

4. MR GÖRÜNTÜLERİNİN ÖN İŞLENMESİ

Görüntü bir nesnenin sunumudur. Görüntü işleme ise görüntü üzerinde çeşitli teknikler kullanılarak başka bir görüntü elde etme sürecidir. Görüntü işleme teknikleri görüntü iyileştirme, gürültü azaltma gibi çok çeşitli sebeplerle görüntünün insan veya bilgisayar tarafından anlaşılabilmesi veya yorumlanabilmesini sağlamak için kullanılır (Gonzales ve Woods, 2002). Görüntü işleme analizi ve bilgisayar görmesi, son on yılda hem teorik hem de uygulama alanında çok büyük gelişmeler sergilemiş ve birçok teknolojik alanda uygulama imkânı bulmuştur. Sayısal haberleşme, internet, tıp, çoklu ortam sistemleri, biyoloji, malzeme bilimi, robotik ve akıllı algılama sistemleri en fazla ilgi gören alanlar olmuştur (Türkoğlu ve ark, 2003).

Ham görüntülerin daha belirgin ve anlaşılır hale getirilerek bir sonraki aşama için kolay işlenebilir hale getirilmesi sürecine ön işlem (pre-processing) denmektedir.

Ön-işleme yöntemlerinden bazıları şunlardır:

- Görüntüyü belirginleştirmek,
- Görüntüde bulunan kirlilikleri (gürültüyü) filtrelemek,
- Görüntü üzerindeki yapısal bozuklukları yok etmek veya minimize etmek.

Ön işleme ile sayısal haldeki görüntü üzerinde teşhisi zorlaştıran gürültü, kontrast düşüklüğü gibi problemlerin ortadan kaldırılması amaçlanmaktadır. Bu sayede sistemin daha iyi sonuç vermesi sağlanmış olur. Bunun yanında teşhiste işimize yaramayan özellikler azaltılır (Er ve Temurtaş, 2005).

MR görüntülerinde, ön işlem ile yaygın olarak yapılmak istenen ilgili alanların (region of interest) ayrıntılarının belirginleştirilmesi, arka planın ise temizlenmesi olarak gerçekleştirilmektedir (Özşen, 2004).

4.1. Görüntü İyileştirme

Bu tez çalışmasında kullanılan bel bölgesi MR görüntüleri çekim yapılan cihazdan kaynaklanan gürültülere sahiptir. Ayrıca bu ham görüntüler kontrast aralığı dar olarak çekilmiş görüntülerdir. Çekilen görüntü sadece bel bölgesine ait veriler içermemekte aynı zamanda gereksiz alanlar da içermektedir. Dolayısı ile gürültülerin ve

gereksiz alanların MR görüntüleri üzerinden yok edilmesi amacıyla medyan filtreleme, histogram eşitleme ve ilgili bölgenin kesilmesi işlemleri uygulanmıştır.


İlk aşamada, alınan MR görüntülerinin kontrast farklılıklarından kaynaklanan disk bölgesinin net olarak görülememesi sorununu ortadan kaldırmak için histogram eşitleme işlemi uygulanmıştır. Bu sayede karanlık bölgeler daha parlak hale getirilerek seçilebilirliği arttırılmıştır. İkinci aşamada hem çekim sırasında oluşan gürültüler hem de histogram eşitleme sonrası oluşan beneklerin yok edilmesi amacıyla medyan filtre uygulanmıştır. Son aşamada ise ilgili bölgenin (disk bölgesi) MR görüntüsü içerisinde kesilip alınması (crop) işlemi gerçekleştirilmiştir. Aksiyal MR görüntülerinde spinal kanal, sağ ve sol lateral kanalları da içine alacak şekilde 165x165 piksel boyutlarında kesme işlemi uygulanmıştır. Sagittal MR görüntülerinde ise her bir disk aralığı (beş adet) 70x40 piksel boyutlarında kesme işlemi uygulanmıştır.

4.1.1. Histogram eşitleme

Histogram görüntüdeki piksel değerlerinin ağırlığını gösteren grafiklerdir. Histogramlarda konum yerine frekans bilgileri yer almaktadır. Gri seviyeli bir resme ilgili histogram değeri sayesinde maskeleme yapılabilir. Histograma bakılarak ilgili resmin parlaklığı veya tonları hakkında bilgi edinilebilir.


Histogram grafiğinden faydalanılarak görüntü iyileştirme ya da önileşim seçimi yapılabilir. Eşikleme yöntemi yapılırken histogram grafiklerinden yararlanılır. Histogram frekans dağılımlarını gösterdiğine göre, histogram eşitleme de bu frekansların bir yerde yığılmalarını önleyerek düzgün bir şekilde dağılımlarının sağlanması olarak tanımlanabilir. Histogramdan faydalanarak renk değerleri düzgün dağılımlı olmayan görüntülerin renk değeri dağılımları düzeltilebilir. Histogram eşitleme ile belirli bir yoğunluk etrafında toplanan histogram eğrisi minimum ve maksimum yoğunluk değerleri arasına düzgün bir şekilde dağıtılır. Böylece görüntünün yoğunluk dağılımının homojen olarak yapılandırılması sağlanır (Çelik, 2011).

Şekil 4.1’de, gri seviye resmin orijinal hali ve histogram eşitlenmiş hali ile histogram grafikleri görülmektedir.




Şekil 4.1. (a) Gri seviyeli bir görüntü ve histogram grafiği (b) histogram eşitlemesi yapılmış bir görüntü ve görüntüye ait histogram grafiği (Homepages, 2014).

Tez çalışmasında MR görüntülerine önce histogram eşitleme uygulanmıştır. Histogram eşitlemesi yapılan MR görüntülerinden aksiyal Şekil 4.2 sagittal ise Şekil 4.3'te görülmektedir.




Şekil 4. 2. Bel bölgesi aksiyal MR görüntüleri (a) histogram eşitleme uygulanmamış (b) histogram eşitlemesi uygulanmış



Şekil 4. 3 Bel bölgesi sagittal MR görüntüleri (a) histogram eşitleme uygulanmamış (b) histogram eşitlemesi uygulanmış


4.1.2. Medyan filtreleme

Gürültü, görüntü işlemede karşılaşılan problemlerin başında gelmektedir. Medyan filtreleme gürültü azaltma ve görüntü iyileştirme işlemleri için oldukça sıkça kullanılan yöntemlerin başında gelmektedir. Dijital görüntü üzerinde medyan filtreleme uygulanırken, pikselin komşuluğundaki piksel değerlerinin ortancasının o pikselin değeri ile değiştirilmesi işlemi yapılır (Çelik, 2011). Merkezi (x, y) olan bir noktanın komşuluğunda bulunan diğer nokta değerlerinin büyükten küçüğe veya küçükten büyüğe sıralanması ile oluşan kümenin ortancası olan değer, o noktanın yeni değeri olarak değiştirilir (Özşen, 2004; Kazdal, 2013). Örneğin 3×3 büyüklüğünde bir komşuluk için medyan değeri listenin beşinci elemanıdır (Çelik, 2011). Medyan filtrelemeye bir örnek aşağıdaki Şekil 4.4’de verilmiştir.




Şekil 4. 4 Medyan filtre örneği (Kazdal, 2013)

Şekil 4.5’de gürültülü bir görüntü ve bu görüntüye medyan filtre uygulanmış sonuç görülmektedir.




Şekil 4. 5. (a) Gürültülü görüntü (b) Gürültülü görüntüye medyan filtre uygulanmış hali (Kazdal, 2013)

Bu tez çalışmasında MR görüntülerine histogram eşitlemeden sonra medyan filtreleme işlemi de uygulanmıştır. Bunun sebebi histogram eşitleme işlemi sonrası ortaya çıkan gürültüdür. Medyan filtreleme işlemi uygulanan aksiyal MR görüntülerinden biri Şekil 4.6'da görülmektedir.



Şekil 4.6. Bel bölgesi aksiyal MR görüntüleri (a) ham (b) medyan filtresi uygulanmış

Medyan filtre işlemi uygulanan sagittal MR görüntülerinden biri de Şekil 4.7'de görülmektedir.




Şekil 4. 7. Bel bölgesi sagittal MR görüntüleri (a) ham (b) medyan filtresi uygulanmış

4.1.3. İlgili bölgenin kesilmesi (Crop)

Özellik çıkarımı aşamasından önce MR görüntülerinden gereksiz alanların atılması gerekmektedir. Bu amaçla üzerinde çalışılan disk bölgesinin belirlenerek görüntüden kesilmesi işlemi uzman doktor gözetiminde manuel olarak yapılmıştır.

Aksiyal MR görüntülerinde spinal kanal, sağ ve sol lateral kanalları da içine alacak şekilde 165x165 piksel boyutlarında kesme işlemi uygulanmıştır. Sagittal MR görüntülerinde ise her bir disk aralığı (beş adet) 70x40 piksel boyutlarında kesme işlemi uygulanmıştır (Şekil 4.8).



Şekil 4. 8. Kesme işlemi ekran görüntüsü

Aksiyal ve sagittal MR görüntülerinden kesilen resimler bir sonraki aşamada özellik çıkarımı işleminden geçirilerek özellik vektörleri elde edilmiştir.

5. ÖZELLİK ÇIKARIMI

Özellik çıkarma, üzerinde karar verme veya sınıflandırma gibi işlemlerin yapılacağı bölgeye ait niteleyici bileşenlerin oluşturduğu vektörel kümenin elde edilmesidir. Bu aşama, karar verme aşamasından önce gelen ve doğru sonucun elde edilmesinde önemli bir etkiye sahiptir. Zira hatalı olarak elde edilecek bir özellik vektörü karar verme işleminin de hatalı olmasına yol açacaktır.

Bu çalışmada ön işlem aşamasından geçmiş aksiyal ve sagittal MR görüntüleri üzerinde iki farklı özellik çıkarma işlemi yapılmıştır. Sagittal MR görüntülerinde aktif şekil model yöntemi kullanılarak disk bölgelerine ait ilk özellik vektörleri oluşturulmuştur. Aksiyal MR görüntülerinde ise spinal kanal bölgesi ile sağ ve sol lateral kanalların biçimsel özellikleri manuel olarak ölçülerek ikinci özellik vektörü oluşturulmuştur. Ayrıca yine sagittal MR görüntülerinden her bir disk için yükseklik, genişlik ve parlaklık değerleri ölçülmüştür. Aşağıda özellik çıkarma işlemleri detaylı olarak anlatılmıştır.

5.1 Aktif Şekil Modeli

Aktif şekil modeli (AŞM) görüntü bölütleme, özellik çıkarma, görüntü içinden nesne ayırt etmek gibi durumlarda kullanılan imgeler üzerinde konumlandırma yapan popüler bir yöntemdir. AŞM model tabanlı yaklaşımlardan biridir. Şekil ve profil olmak üzere iki modelden oluşmaktadır. Şekil modeli eğitim setinde yer alan şekillerin değişimlerini tanımlar (Oktay, 2011). Profil modeli ise profil şeklini oluşturan her bir nokta etrafındaki gri seviyeli doku bilgisini temsil eden istatistiksel verileri oluşturur. Şekil ve profil modelleri eğitim aşamasında oluşturulur. Arama aşamasında deneme resimleri şekillerin konumlandırılmasında kullanılır (Ayhan, 2013).

5.1.1 Şekil modelinin oluşturulması

Şekil modelinin oluşturmaktaki amaç aktif şekil modeli kullanarak bir objeyi sinama imgeleri üzerinde konumlandırmadır. Şekil modelini oluşturmak için tarz değişimleri iyi yansıtan bir eğitim seti kullanılmalıdır.

Şekil modeli üç adımda oluşturulmaktadır:

- Nirengi noktalarının eğitim setindeki imgeler üzerinde el ile işaretlenmesi,
- İşaretleme işlemi ile oluşturulan, şekillerin hizalanması (ölçek, konum ve dönme açısı farklılıklarının ortadan kaldırılması işlemi)
- Şekil değişimlerine ilişkin istatistiki verinin elde edilmesi

Şekillerin işaretlenmesi şöyle olur:

Önce N adet d boyutlu nirengi noktalarından oluşan bir küme bir objenin şeklini meydana getirmektedir. Sonra bu noktalar (nirengi noktaları) seçilirken eğitim setindeki bütün imgeler için değişmeyen bölgeler üzerinden ya da etrafından seçilmelidir. Bu bölgeler genellikle, objenin genel şeklini ve karakteristiğini yansıtmalıdır.

Objenin şeklinin iyi bir şekilde tanımlanabilmesi için uygun sayıda ve en iyi tanımlayacak sayıda ve nitelikte noktalar belirlendikten sonra, veri setinde yer alan bütün imgeler üzerinde bu noktalar tek tek el ile işaretlenmelidir. İşaretleme yapanlar noktaların tutarlı ve özenli bir şekilde işaretlenmesi için gerekli dikkati göstermelidirler.

Bir objeyi, $N \times d = \Omega$ uzunluğunda bir vektör ile matematiksel ifade edebiliriz. Örneğin, 2 boyutlu noktalardan oluşan ($d=2$) bir s şekilde Eşitlik 5.1'deki gibi gösterilebilir:

$$s = (x_1, x_2, \dots, x_N, y_1, y_2, \dots, y_N)^T \quad (5.1)$$

Burada (x_i, y_i) , i -inci noktanın koordinatlarıdır. T , ters alma işlemidir. Eğitim setinde yer alan K tane imge için şekil vektörleri $(s_j, j = 1, 2, 3, \dots, K)$ elde edilir (Ayhan, 2013).

5.1.2. Profil modelin oluşturulması



Profil modelin oluşturulma sebebi, nirengi noktalarının etrafındaki dokunun öz niteliğini çıkartmaktır. Profil model bir diğer ifade ile bir nirengi noktasının etrafındaki görünümün nasıl olması gerektiğini belirlemek için oluşturulur.

Sınama imgelerinde şekli konumlandırılırken, noktalar etrafında örneklenen doku ile profil model ile elde edilen doku bilgisi karşılaştırılır ve bu karşılaştırma sonucunda noktanın konumu güncellenir. Böylece, noktalar her adımda en uygun yere taşınarak objeye en benzer şekil elde edilir (Ayhan, 2013).

5.1.3. Aktif şekil modeli ile özellik çıkarımı

Aktif şekil model medikal verilerde özellik çıkarımı ve segmentasyon için başarıyla uygulanabilmektedir.

Bir diskin şekli, onların sağlık durumları hakkında önemli ipuçları verir. Sağlıklı lomber intervertebral disklerin sagittal görünümü elips şeklindedir. Disklerde meydana gelen anormalite durumlarına göre bu elips şekli değişip bozulmaktadır. Diskteki şekil değişmelerinin tespiti için çalışmada aktif şekil modeli ile özellik çıkarımı yapılmıştır. Bu amaçla disk üzerinde sekiz adet sınır noktası belirlenmiştir (Şekil 5.1).




Şekil 5.1. AŞM ile özellik çıkarımı için sınır noktalarının işaretlenmesi

Belirlenen 8 adet sınır noktasının iki boyutlu koordinat değerleri ($2 \times 8 = 16$) özellik vektörü olarak alınmıştır. Bu özellik vektörü her bir resim için ayrı ayrı elde edilmiştir.

5.2 Biçimsel Özellik Çıkarma

Biçimsel özellik çıkarımı işleminde manuel olarak sınırlar belirlenmiştir. Bu sınırlar içerisinde uzman doktorun teşhiste göz önünde bulundurduğu 8 adet ölçüm gerçekleştirilmiştir. Ölçümler yapılırken dikkat edilen sınır çizgileri (Şekil 5.2) aşağıda belirtilmiştir:


- İntervertebral disk ile spinal kanal arası (A Sınırı).
- Spinal Kanal ile sağ ligamentin kesişen kısım (B Sınırı).
- Spinal kanal ile sol ligamentin kesişen kısmı (C Sınırı).
- Spinal kanalı çevreleyen sınır (D Sınırı).



Şekil 5. 2 Özellik çıkarımı için oluşturulan sınır çizgileri

Bu sınırlara göre manuel olarak 8 adet ölçme yapılmıştır (Şekil 5.3). Bunlar:

- 1) A sınırı ile B sınırı arasında kalan ve sol lateral kanal genişliği
- 2) A sınırı ile C sınırı arasında kalan sağ lateral kanal genişliği
- 3) D sınırı içerisinde (spinal kanal bölgesi) kanalın orta noktası referans alınarak 6 adet ölçme yapılmıştır. Bunların 3 tanesi dikey uzunluk, 3 tanesi ise yatay genişlik değerlerini vermektedir.
- 4) Spinal kanalın dikey orta noktasına göre sol kısımda kalan dikey uzunluk
- 5) Spinal kanalın dikey orta noktasına göre sağ kısımda kalan dikey uzunluk
- 6) Spinal kanalın dikey orta noktasına göre sol kısımda kalan yatay genişlik
- 7) Spinal kanalın orta noktasından geçen yatay genişlik
- 8) Spinal kanalın dikey orta noktasına göre sağ kısımda kalan yatay genişlik



Şekil 5. 3. Özellik vektörlerinin elde edildiği ölçüm alanları

Özellik vektöründe yer alan sekiz adet özelliğin isimleri şu şekildedir:

1. Sağ lateral kanal genişliği
2. Sol lateral kanal genişliği
3. Kanal sağ yüksekliği
4. Kanal dikey çapı
5. Kanal sol yüksekliği
6. Kanal üst genişliği
7. Kanal yatay çapı
8. Kanal alt genişliği

6. ÖZELLİK SEÇİMİ

Özellik seçimi yetmişli yıllardan beri üzerinde çalışılan ve geliştirilen, veri madenciliği ve makine öğrenmesi, örüntü tanıma, istatistik gibi alanlarda sık sık kullanılan veri ön işleme yöntemlerindendir. Özellik seçme işleminde veri kümelerindeki özelliklerden önem derecesi yüksek olanlar ile sınıflamayı daha kolay hale getiren özellikler seçilir. Özellik seçimi işlemi sonunda veri kümesinden gereksiz ve önemsiz özellikler çıkartılmış, elemine edilmiş olur. Bu sayede makine öğrenmesi algoritmalarının sınıflama verimliliğinin artmış olması sağlanır (Hacıbeyoğlu, 2012).

Görüntü işleme, müşteri ilişkileri yönetimi ve gen analizi gibi alanlarda kullanılan veritabanlarında hem özellik sayıları hem de örnek sayıları oldukça fazla olabilmektedir. Bu gibi büyük veritabanları ile çalışabilmek makine öğrenmesi algoritmaları için problem teşkil edebilmektedir. Bu problemlerden biri sınıflama sürelerinin uzamasıdır. Başka bir problemde çok sayıdaki gereksiz ve önemsiz özellikler makine öğrenmesi algoritmalarının performansını düşürmektedir. Bu sebeplerden dolayı özellik seçme yöntemleri, yüksek boyutlu veri kümeleri ile çalışan makine öğrenmesi algoritmaları için gerekli ve önemli bir konu haline gelmiştir (Hacıbeyoğlu, 2012). Özellik seçme algoritmaları, medikal veri kümelerinin sınıflandırılmasında daha yüksek genelleştirme yeteneği ve örüntü tanıma problemlerinin çözümünde daha iyi sonuçlar sunarlar (Polat, 2008).

Bu tez çalışmasında, özellik seçme ve boyut azaltımı yöntemleri olarak, f-skor tabanlı özellik seçme yöntemi ile korelasyon tabanlı özellik seçme yöntemleri kullanılmıştır.

6.1 F-skor Tabanlı Özellik Seçme Yöntemi (F-score Based Feature Selection)

F-skor yöntemi, gerçek değerleri ile iki sınıf arasındaki özelliklerin ayırt edici gücünü ölçen basit bir tekniktir. F-skor yönteminde, veri kümesi içindeki her özelliğin f-skor değerleri denklem 6.1'e göre hesaplanır.

Veri kümesi içerisinde özellikleri seçmek için öncelikle tüm özelliklerin f-skor değeri hesaplanıp ortalaması alınır bu değer eşik değer olarak adlandırılır. Veri kümesindeki herhangi bir özelliğin f-skor değeri eşik değerden yüksek ise o özellik


seçilir. Aksi takdirde f-skör değeri eşik değerdan küçük ise bu özellik seçilmez (Polat ve Özbay, 2009).

Verilen eğitim vektörleri $x_k, k=1,...,m$, Pozitif ve negatif örneklerin sayısı n_+ + n_- ise i . (i inci) özelliğın f-skör değeri şu şekilde hesaplanır: (Chen ve Lin, 2003; Scholkopf ve Smola, 2002).

$$F(i) = \frac{(\bar{x}_i^{(+)} - \bar{x}_i)^2 + (\bar{x}_i^{(-)} - \bar{x}_i)^2}{\frac{1}{n_+ - 1} \sum_{k=1}^{n_+} (x_{k,i}^{(+)} - \bar{x}_i^{(+)})^2 + \frac{1}{n_- - 1} \sum_{k=1}^{n_-} (x_{k,i}^{(-)} - \bar{x}_i^{(-)})^2} \quad (6.1)$$

Burada $\bar{x}_i, \bar{x}_i^{(+)}, \bar{x}_i^{(-)}$ i . (i inci) özelliğın bütün ortalama ve negatif veri setleri, $x_{k,i}^{(+)}$ k . (k ıncı) pozitif örneğın i . (i inci) özelliğı ve $x_{k,i}^{(-)}$ ise k . (k ıncı) negatif örneğın i . (i inci) özelliğıdır.

Yukarıdaki eşitlikte kesirin payında pozitif ve negatif kümelerin diskirminantını gösteriyor. Payda da ise iki küme her birinde birini tanımlamaktadır. F-skör değeri daha büyük olan özellik muhtemelen daha ayırt edicidir. F-skör metodunun dezavantajı ise özellikler arasında karşılıklı bilgi almamasıdır (Polat ve Özbay, 2009; Chen ve Lin, 2003). Şekil 6.1’de, F-skör Tabanlı Özellik Seçimi (FSTÖS) yönteminin akış şemasını göstermektedir.



Şekil 6. 1 F-skör tabanlı özellik seçme algoritması akış şeması (FSTÖS)

Buna göre ilk olarak veri kümesi yüklenmekte, daha sonra veri kümesindeki her özelliğin f-skör değeri hesaplanmaktadır. Bütün özellikler için ortalama f-skör değeri de hesaplanır. Her bir özellik için hesaplanan f-skör değeri, ortalama f-skör değeri ile karşılaştırılır. Her bir özelliğin f-skör değerinin ortalama f-skör değerinden büyük olup olmadığına bakılır. Eğer bir özelliğin f-skör değeri ortalama f-skör değerinden büyük ise o özellik sınıflama için ayrılır. Eğer bir özelliğin f-skör değeri ortalama f-skör değerinden küçük ise o özellik vektörü göz ardı edilir ve veri kümesinden çıkartılır. Bu şekilde hangi özelliklerin sınıflamaya dâhil edilip edilmeyeceği yani özellik seçme işlemi gerçekleştirilmiş olur.

Tez çalışmasında sagittal ve aksiyal MR görüntülerinden elde edilen 27 özellik vektörü normal veya anormal olarak sınıflamak için elde edilmiş ve f-skör tabanlı özellik seçme işlemine tabi tutulmuştur. Sonuçlar Bölüm 8’de verilmiştir.

6.2 Korelasyon Tabanlı Özellik Seçimi (Corelation Based Feature Selection)

Korelasyon, veri kümesindeki bir özelliğin çıkışlar (sınıflar) ile ya da diğer özellikler (features) ile ilgili ve alakalı olup olmadığını ölçmek için kullanılan bir kriterdir. Buradan yola çıkılarak veri kümesindeki özellikler ile veri kümesi çıkışları arasındaki korelasyon katsayılarına dayalı bu yöntem özellik seçimi yöntemi olarak kullanılabilir. Çıkışlar ile alakalı olan, diğer gerekli özellikler ile çelişmeyen özellikler seçilebilir özellik olarak tanımlanabilir.


Korelasyon uygulandığında önemli olan özellik çıkış sınıfları ile yüksek korelasyonlu (alakalı) olmalı, diğer özellikler ile ise yüksek korelasyonlu olmayandır (Durduran 2010; Polat ve Kırmacı 2011). R (değişkenler arasındaki korelasyon katsayısı) değeri -1 ile +1 arasında değişir. + ve - işaretleri sırasıyla pozitif lineer korelasyon ve negatif lineer korelasyon için kullanılır. Değişkenler arasındaki üç tip korelasyon şu şekilde açıklanır (Durduran 2010; Polat ve Kırmacı 2011).

Korelasyon boyutsuz bir büyüklüktür; diğer bir deyişle, kullanılan birimler bağımlı değildir. Mükemmel bir korelasyon ancak tam düz bir çizgi üzerinde ± 1 şeklinde olabilir. Eğer, $R = +1$ ise bu çizginin eğimi pozitifdir. Eğer $R = -1$ ise bu çizginin eğiminin negatif olduğunu gösterir (Durduran 2010; Polat ve Kırmacı 2011).

Korelasyon katsayılarının hesaplanmasında, p değeri, $N-2$ özgürlük derecesine sahip t-istatistiğini üretmek için korelasyonun dönüştürülmesiyle hesaplanır. Burada N

değeri, X' in satır sayısıdır. $p(i, j)$ değeri 0.05' den küçük ise, korelasyon istatistiksel olarak önemlidir (Durduran 2010; Polat ve Kırmacı 2011).

Tez çalışmasında sagittal ve aksiyal MR görüntülerinden elde edilen 27 özellik vektörü normal veya anormal olarak sınıflamak için elde edilmiş ve KTÖS ile özellik azaltımı yapılmıştır. Şekil 6.2'de korelasyon tabanlı özellik seçimi yönteminin akış şeması görülmektedir.



Şekil 6. 2. Korelasyon tabanlı özellik seçimi akış şeması (KTOS)

Yukarıdaki akış şemasına göre ilk olarak veri kümesi yüklenmektedir. Daha sonra özellikler ile çıkışlar arasındaki korelasyon katsayısı hesaplanır. Korelasyon katsayısı r ile ifade edilir. Korelasyon katsayısının matematiksel ifadesi Eşitlik 6.2'deki gibidir:


$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (6.2)$$

Korelasyon katsayısı -1 ile +1 arasında değer alır. Korelasyon katsayısının işareti + ise değişkenler arası doğru ilişki vardır. Eğer Korelasyon katsayısının işareti + ise değişkenler arası doğru ilişki vardır. Biri artıyorken, diğeri de artar veya biri azalırken diğeri de azalır. Eğer korelasyon katsayısının işareti eksi ise ters ilişki vardır. Yani değişkenlerden biri azalırken diğeri artar veya biri artarken diğeri azalır. R 'nin sıfır olması durumunda ise, değişkenler arasında doğrusal bir ilişki olmadığı söylenir.

7. VERİ AĞIRLIKLANDIRMA

Sınıflama algoritmaları, medikal verilerin sınıflara ayrılmasında, verilerin lineer olarak ayıramayan yapıya sahip olmaları gibi nedenlerden dolayı iyi bir performans gösteremeyebilirler. Bu sorunu ortadan kaldırma yöntemlerinden biri de veri ağırlıklandırma yöntemleridir (Polat, 2008).

Veri ağırlıklandırma veya özellik ağırlıklandırmadaki amaç: Özellik uzayındaki dağılımları lineer olarak ayıramayan veri kümelerinin lineer olarak ayrılabilir hale getirilmesidir. Veri ağırlıklandırma metotları veri kümesi içerisindeki özelliklerin varyansını azaltarak bunu sağlar. Bu sayede benzer özelliğe sahip özellik vektörleri bir araya toplanır ve sınıflayıcıların bu verileri daha kolay sınıflandırması sağlanmış olur (Polat, 2008). Şekil 7.1’de lineer olarak ayıramayan ve lineer olarak ayrılabilen iki özellikli veri kümeleri görülmektedir



Şekil 7.1. Özellik uzayında (a) lineer olarak ayrılabilen ve (b) lineer olarak ayıramayan veri kümeleri (Sebastianraschka, 2015).

Bu bölümde tez çalışması aşamalarından biri olan veri ağırlıklandırma yöntemi olarak bu tez çalışmada geliştirilen *ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi* ve *ikili bulanık c-ortalama tabanlı veri ağırlıklandırma yöntemleri* anlatılmıştır.

7.1 Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma Yöntemi

Tez çalışmasında kullanılmak üzere iki ve daha fazla sınıflı veri kümelerini sınıflamak için yeni bir ortalama kayma kümeleme (mean shift clustering) algoritmasına dayalı bir veri ağırlıklandırma yöntemi önerilmiştir. Bu kısımda önerilen bu yeni veri ağırlıklandırma yöntemi açıklanacaktır. Öncelikle ortalama kayma kümeleme (mean shift clustering) algoritmasının çalışma prensibi açıklanacaktır. Daha sonra önerilen ortalama kayma kümeleme tabanlı veri ağırlıklandırma (Mean shift clustering based attribute weighting) yöntemi açıklanacaktır.

Ortalama kayma kümeleme algoritması parametrik olmayan istatistiksel bir yöntemdir ve nokta dağılımının en yoğun olduğu yeri bulmayı sağlar (Xie ve Cheng, 2014). Bu algoritma ilk olarak Fukunaga ve Hostedler (1975) tarafından önerilmiş ve sonra Comanicu (Comanicu ve Meer, 2002) tarafından geliştirilmiştir (Comanicu ve ark., 2003).

Geleneksel ortalama kayma algoritması, ortalama kayma vektörünü Δx hesaplayarak nesne merkezinin gerçekleştirmiş olduğu hareketi değerlendirir. Başlangıç nesne pozisyonunun $\hat{x}$ ve hesaplamak istediğimiz yeni nesne pozisyonunun $\hat{x}'$ olduğunu düşünürsek, $\hat{x}' = \hat{x} + \Delta x$ olur. Buna göre ortalama kayma vektörü denklem 7.1'de gösterildiği gibi hesaplanır.

$$\Delta x = \frac{\sum_i K(x_i - \hat{x}) w(x_i) (x_i - \hat{x})}{\sum_i K(x_i - \hat{x}) w(x_i)} \quad (7.1)$$

Ortalama kaymanın arkasındaki ana fikir, d-boyutlu noktaları ve özellikler uzayındaki yoğunluk alanlarını, temel dağılım modları veya lokal maksimum değerler için uygun olan deneysel ve olası yoğunluk fonksiyonu olarak işlemektir. Özellikler uzayındaki her bir özellik veri noktası için lokal olarak yordanan yoğunlukta bir yakınsama sağlanıncaya kadar artan eğilimli bir prosedür gerçekleştirilir. Bu prosedürün sabit noktaları dağılımın modlarını göstermektedir. Ayrıca aynı sabit noktayla ilgili veri noktaları aynı kümenin üyeleri olarak ele alınır.

$x_i \in R^d$ 'de n sayıda veri bulunsun. Simetrik çekirdeği radyal bir şekilde kullanarak (Epanechnikov ve Gauss çekirdekleri) çok-değişkenli çekirdek (kernel)

yoğunluk yordaması eşitlik 7.2'deki gibi gösterilebilir (Wu ve Yang 2007, Derpanis 2005):

$$\hat{f}_K = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (7.2)$$

Yukarıdaki eşitlikte; h (band genişliği olarak 'sweat') çekirdeğin çapını göstermektedir. Radyal olarak simetrik çekirdek aşağıdaki gibi tanımlanır (Denklem 7.3) (Derpanis, 2005):


$$K(x) = c_k k(\|x\|^2) \quad (7.3)$$

Yukarıdaki 7.3 ile numaralı eşitlikte c_k , normalizasyon sabitini göstermektedir. Yoğunluk yordama meyili ile birlikte aşağıdaki eşitlik 7.4 elde edilir, (Derpanis, 2005):

$$\nabla \hat{f}(x) = \frac{2c_{k,d}}{nh^{d+2}} \left[\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right) \right] \left[\frac{\sum_{i=1}^n x_i g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|\right)} - x \right] \quad (7.4)$$


Yukarıdaki eşitlikte $g(x) = -k(x)$ seçilen çekirdek profilinin derivasyonunu (türevini) göstermektedir. İlk terim, x 'teki $(G = c_g g(\|x\|^2))$ kernel ile hesaplanır) yoğunluk yordamıyla orantılıdır. "*m ortalama kayma*" vektörü olarak adlandırılan ikinci terim, yoğunluktaki maksimum artış yönünde işaretlenmiştir ve K çekirdeğiyle elde edilen x noktasındaki eğilim yordamasıyla orantılıdır. Bir x_i noktası "*ortalama kayma*" prosedürü aşağıdaki gibidir (Wu ve Yang 2007; Derpanis 2005):

- i. $m(x_i^t)$ Ortalama kayma vektörü hesaplayın.
- ii. $x_i^{t+1} = x_i^t + m(x_i^t)$ yoğunluk yordaması penceresini dönüştürün.
- iii. $\nabla f(x_i) = 0$ yakınsaması oluşana kadar 1. ve 2. adımları tekrarlayın.



Şekil 7. 2. Ortalama kayma algoritmasının şematik gösterimi (Derpanis, 2005).

Şekil 7.2’de, *ortalama kayma* prosedürünün şematik temsilini göstermektedir. Bu şekilde x_i veri noktasında başlamakta ve yoğunluk fonksiyonunun uygun noktalarını bulmak amacıyla *ortalama kayma* algoritmasını işletmektedir. Üst damgalar *ortalama kayma* algoritmasının iterasyonunu göstermektedir. Gölge ve siyah noktalar, sırasıyla giriş noktalarını ve başarılı pencere merkezlerini göstermektedir. Noktalı daireler yoğunluk yordama pencerelerini göstermektedir (Wu ve Yang 2007; Derpanis, 2005):



Şekil 7. 3. Ortalama kayma kümeleme tabanlı veri ağırlıklandırma yönteminin akış şeması

Tez çalışması için geliştirilen ortalama kayma kümeleme tabanlı veri ağırlıklandırma algoritmasının akış diyagramı Şekil 7.3’de verilmiştir. Buna göre ilk olarak ortalama kayma algoritması kullanılarak veri kümesinin merkezi bulunmaktadır. Daha sonra veri kümesindeki her özelliğin ortalama değeri hesaplanmaktadır. Algoritmada ağırlık oranının bulunması şu şekilde gerçekleşmektedir: bir üst adımda hesaplanan veri kümesindeki her özelliğin ortalama değerinin, küme merkezine oranlanması ile ağırlık oranı bulunur. Ağırlık oranı bulunduğundan sonra her bir özellik ağırlık ile çarpılır. Elde edilen bu yeni değerler ağırlıklandırılmış veriler olmaktadır. Böylece veri kümesi ağırlıklandırılmış olur.

7.2 İkili Bulanık C-Ortalama Tabanlı Veri Ağırlıklandırma Yöntemi

Tez çalışmasında kullanılmak üzere, çok sınıflı veri kümelerini ikili olarak gruplayıp bulanık c-ortalama yöntemi yardımı ile özellikleri ağırlıklandırılan *ikili bulanık c-ortalama tabanlı veri ağırlıklandırma yöntemi* (pairwise fcm based feature weighting method) ismi verilen yöntem geliştirilmiştir. Bu kısımda önerilen bu yeni veri ağırlıklandırma yöntemi açıklanacaktır.

Bu yöntem isminden anlaşılacağı üzere bulanık c-ortalama tabanlı bir veri ağırlıklandırma yönteminin gelişmiş halidir. Bu sebeple öncelikle bulanık c-ortalama tabanlı veri ağırlıklandırma yönetiminin bilinmesinde fayda vardır. Daha sonra önerilen *ikili bulanık c-ortalama tabanlı veri ağırlıklandırma yöntemi* (pairwise fcm based feature weighting method) açıklanacaktır.

Bulanık c-ortalamlar (fuzzy c-means clustering) kümeleme algoritması, bulanık bölünmeli kümeleme tekniklerinden en iyi bilinen ve yaygın kullanılan yöntemidir. Bulanık c-ortalamlar algoritması 1973 yılında Dunn tarafından ortaya atılmış ve 1981’de Bezdek (1981) tarafından geliştirilmiştir (Dunn, 1973; Işık ve Çamurcu, 2007). Bulanık c-ortalamlar algoritması amaç fonksiyonunu küçültmeyi hedefler. Bulanık c-ortalamlar yöntemi, nesnelerin iki veya daha fazla kümeye ait olabilmesine izin verir. Bulanık mantık prensibi gereği her veri, kümelerin her birine $[0,1]$ arasında değişen birer üyelik değeri ile aittir. Bir verinin tüm sınıflara olan üyelik değerleri toplamı bayes teoremindeki gibi 1 olmalıdır. Nesne hangi küme merkezine yakın ise o kümeye ait olma üyeliği diğer kümelere ait olma üyeliğinden daha büyük olacaktır. Amaç fonksiyonun belirlenen minimum değere yakınsamasıyla kümeleme işlemi tamamlanır

(Işık ve Çamurcu, 2007). Bulanık c-ortalama yöntemini ötelemeli bir algoritmadır ve en küçük kareler yönteminin genellemesi olan aşağıdaki amaç fonksiyonunu küçültmeye çalışır (Höppner ve ark., 2000).

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty \quad (7.5)$$

U üyelik matrisi rasgele atanarak algoritma başlatılır. İkinci adımda ise merkez vektörleri hesaplanır. Merkezler (7.6) no'lu eşitlik ile hesaplanır (Höppner ve ark., 2000).

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (7.6)$$

Hesaplanan küme merkezlerine göre, U matrisi (7.7) no'lu eşitlik kullanılarak yeniden hesaplanır. Eski U matrisi ile yeni U matrisi karşılaştırılır ve fark ε 'dan küçük olana kadar işlemler devam eder (Moertini, 2002).

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_i\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (7.7)$$

Kümeleme işlemi sonucunda bulanık değerler içeren U üyelik matrisi kümelemenin sonucunu yansıtır. İstenirse, berraklaştırma yapılarak bu değerler yuvarlanıp 0 ve 1'lere dönüştürülebilir (Işık ve Çamurcu, 2007).

Bulanık c-ortalama tabanlı veri ağırlıklandırma yöntemi şu şekilde çalışmaktadır:

- Bulanık c-ortalama yöntemi kullanılarak her kümenin merkezi hesaplanır.
- Küme merkezleri hesaplandıktan sonra, her bir özelliğin kendi küme merkezine olan ortalama oranı hesaplanır.
- Bu oranlar, her özelliğin verileri ile çarpılır.

Yukarıdaki adımlar takip edildiğinde yani öncelikle her sınıftaki her bir özellik için ortama değer hesaplanır. Daha sonra bulanık c-ortalamlar yöntemi ile her bir sınıf için küme merkezleri hesaplanır. Daha sonra her bir özellik için bulunan ortalama değer, küme merkezine bölünerek o özellik için bir ağırlık katsayısı elde edilir. Daha sonra her bir sınıftaki her bir özellik değeri ağırlık katsayısı ile çarpılarak veri kümesi ağırlandırılmış olur.

Bulanık c-ortalama Tabanlı veri ağırlıklandırma yönteminin sözde kodu (pseudo code) aşağıda verilmiştir.

Toplam değerleri (girişler, çıkışlar ve mesafeler) sıfırla

A veri kümesini yükle n özellik ve m çıkış

Veri kümesindeki her özellik için

Adım 1. Bulanık C-ortalama yöntemi kullanılarak her kümenin merkezi hesaplanır.

Küme merkezleri hesaplandıktan sonra, her bir özelliğin kendi küme merkezine olan ortalama oranı hesaplanır.

Bu oranlar, her özelliğin verileri ile çarpılır.

Döngüyü bitir

İkili bulanık c-ortalamlar yönteminin çalışması şu şekildedir: Öncelikle çıkıştaki çoklu sınıflar ikili olarak gruplandırılmışlardır. İkili olarak gruplandırılan çıkışlar daha sonra bulanık c-ortalamlar yöntemi ile ağırlıklandırılmışlardır.

8. BEL BÖLGESİ RAHATSIZLIKLARININ SINIFLANDIRILMASI

Makine öğrenmesi, bilgisayarların girilmiş verilerden öğrenme gerçekleştirerek, karşılaştığı durumlar hakkında tahmin ve modelleme yapmasını sağlayan bir yapay zekâ alanıdır. Başka bir tanımda ise bilgisayarların karşılaştığı olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak benzeri olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesi olarak da ifade edilmiştir. Makine öğrenmesi alanındaki araştırmalar daha çok örüntü tanıma, karar mekanizmaları ve sınıflama gibi alanlarda bilgisayara beceri kazandırmaktır. Aynı zamanda makine öğrenimi veri madenciliği, yapay zekâ, örüntü tanıma gibi alanlarla da yakında ilişkilidir (Çentik, 2013).

8.1 Sınıflandırma Yöntemleri

Sınıflandırma verilerde bulunan ortak özelliklere göre verilerin ayrıştırılması olarak tanımlanabilir. Sınıflandırma bir öğrenme algoritmasına dayanmaktadır ve öğrenmenin amacı bir sınıflandırma modelinin oluşturulmasıdır. Tüm veriler kullanılarak öğrenme işi yapılmamaktadır. Verilerin bir kısmı öğrenme, bir kısmı ise test için kullanılmaktadır. Sınıflandırma öğrenme ve sınıflama olmak üzere iki aşamadan oluşmaktadır. Öncelikle bir adet bağımlı (sınıf ya da hedef değişken olarak da adlandırılır) ve birden çok bağımsız değişkenden oluşan veri kümesi öğrenme ve test kümesi olmak üzere ikiye ayrılır. İlk aşamada algoritma öğrenme kümesi üzerinde çalışır ve öğrenme işlemini gerçekleştirir. İkinci aşamada ise test kümesini kullanarak sınıflandırma kuralları belirlenir ve oluşturulan sınıflandırma modeli test verilerine uygulanarak, doğruluk oranına göre modelin doğru sınıflandırma yapıp yapmadığı sınanır. Eğer doğruluk oranı kabul edilebilir ise elde edilen model yeni veri kümelerinin sınıflandırılmasında kullanılabilir (Atılğan, 2011).

Tezde kullanılan makine öğrenmesi yöntemleri ve sınıflama algoritmaları izleyen kısımda ayrıntılı olarak açıklanmıştır.

8.1.1. Yapay sinir ağıları

Bu tez çalışmasında kullanılan sınıflandırma algoritmalarından ilki yapay sinir ağıları algoritmasıdır. Bu sebeple bu sınıflama algoritması bu kısımda açıklanacaktır.

Yapay sinir ağıları, insan beyninin yapısı ve sinir sisteminin özelliklerinden esinlenerek ortaya çıkartılmış, örnekler üzerinden öğrenme ile yeni bilgiler elde edebilen ve yeni durumlara göre sonuçlar üretme, karar verme gibi yeteneklere sahip olan paralel işlem sistemlerine verilen genel addır (Çentik, 2013).

Bir diğer tanımda ise yapay sinir ağıları (neural networks), insan beyninin çalışmasından esinlenerek oluşturulan ve insan beyin ve sinirlerinin yaptığı işlemleri yazılımla gerçekleştirmeyi amaçlayan bir mantıksal programlama tekniğidir. Bilgisayar ortamında, beynimizin yaptığı basit işlemleri yapabilen, karar verip sonuç çıkaran, yetersiz veri gibi durumlarda bile çalışan ve sonuca ulaşan, öğrenen ve tekrar hatırlayabilen bir bilgisayar programı olarak da adlandırılır (Elbistanlı, 2007; Özdemir, 2013; Civalek, 1998).

Yapay Sinir ağlarını oluşturan işlem elemanları değişik şekillerde birbirlerine bağlanarak YSA'yı oluştururlar. Bu bağlanma genellikle katmanlı yapı ile olmaktadır. Tıpkı insan beyinde olduğu gibi YSA'da da bilgi toplama, bağlantı ağırlıkları yardımı ile bu bilgiyi saklama ve genelleme yapma gibi yeteneklere sahiptir (Çentik, 2013).


YSA'lar aşağıdaki konularda başarılı bir şekilde uygulanmaktadır.

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Tahmin
- Özellik Belirleme
- Optimizasyon (Emir, 2013).

YSA, biyolojik sinir ağlarından esinlenerek ortaya çıkartıldığı için öncelikle biyolojik sinir sistemi yapısının öğrenilmesinde fayda vardır.

Biyolojik sinir: Bir insan beyinde, sayısı milyarı bulan biyolojik sinir (nöron)ler bulunmaktadır. Bu sinirler birbirlerine bağlı ve iletişim halindedirler. Biyolojik sinirlerin görevleri içerisinde en önemlisi bilgi iletişimini gerçekleştirmeleridir. Her bir

nöronun aksonu ayrıştırılmıştır ve bir sinaps olarak adlandırılan bir kavşak vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Her bir nöronun diğer nöronlarla bağlantıya sahip olduğu bu yapı, biyolojik sinir ağı olarak adlandırılmaktadır. Bu çok geniş bir hesaplama gücü ve hafıza sağlamaktadır. Bir biyolojik nöron (sinir hücresi) temel olarak dört ana bölüme ayrılabilir. Bunlar; dendrit, soma, akson ve sinapslardır. Şekil 8.1’de biyolojik sinir hücresi görülmektedir (Felsefe, 2014).



Şekil 8. 1. Biyolojik sinir hücresi (Felsefe, 2015)

Girişler (Dendritler): Dendritler, kısa lifler olup diğer sinirlerden gelen bilgileri alan yapılardır.

Soma (Hücre gövdesi): Soma, gelen bilgileri toparlayan, birleştiren ve biçimini değiştirerek diğer sinirlere gönderen yapıdır.

Çıkış (Aksonlar): Aksonlar, uzun lifler olup bilgiyi diğer sinirlere transfer etmekte kullanılan yapılardır.

Sinapslar: Akson ile diğer bir nöronun dendritinin birleşme noktası sinaps olarak adlandırılır (Hacıfendioğlu, 2012).

Yapay sinir hücreleri, gerçek sinir hücrelerinin simüle edilmesiyle elde edilir. Yapay sinir hücreleri, aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Yapay sinir hücrelerinin biyolojik sinir hücreleri ile olan benzerliğini şu şekildedir:

- Akson – Çıktı,
- Dendrit-Toplama Fonksiyonu,
- Çekirdek - Aktivasyon fonksiyonu,
- Sinaps –Ağırlıklar (Yalçın, 2012).


8.1.1.1. YSA'nın özellikleri

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Genel karakteristik özellikler şunlardır (Öztemel 2006; Sağıroğlu ve ark., 2003; Allahverdi, 2002):

- Yapay sinir ağları öğrenme gerçekleştirirler. Olayları öğrenerek benzer olaylar karşısında benze kararlar vermeye çalışırlar.
- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veritabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dâhil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA'lar eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilirler.
- Hata toleransı özelliğine sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık bellek özelliğine sahiptirler. Yapay sinir ağında bilgi ağa yayılmış durumdadır.
- Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir (Koçer, 2007).

8.1.1.2. YSA'nın yapısı

YSA, yapay sinir hücrelerinin bir araya gelmesi sonucu oluşan yapılardır. YSA, Şekil 8.2.'de görüldüğü üzere üç bölümde incelenmektedir (Kakıcı, 2009):



Şekil 8. 2. Yapay sinir ağı yapısı (Fanntool, 2015).

Giriş Katmanı: Bu katman sistemin girişidir. Girdiler ağı bu kısımdan giriş yaparlar. Giriş katmanında bir işlem yapılmadan girdiler, gizli katmana geçmektedir. Giriş katmanında her bir girdiye karşılık bir hücre bulunmaktadır. Buradaki hücreler birer giriş ve çıkışa sahiptir. Giriş katmanındaki hücreler gizli katmandaki bütün hücelere bağlıdır.

Gizli Katmanlar: Giriş katmanından alınan veriler gizli katmana gelirler. Buraya gelen veri gizli katmandan işlenir ve kendisinden sonraki katmana aktarılır. Gizli katmandaki hücrelerin sayısı, girdi ve çıktı sayılarına bağlı olmaksızın değişebilir. Hücre sayıları farklı olabileceği gibi, YSA'daki gizli katman sayıları da farklı olabilir. Gizli katman sayısının ve buradaki hücre sayılarının artması, YSA'nın hesaplama sürelerini ve karmaşıklığını artırsa da, daha karmaşık problemleri çözebilmesini de sağlamaktadır.

Çıkış Katmanı: Gizli katmandan aldığı veriyi işler ve girişten gelen girdilere uygun olarak çıktı üretir. Çıkış katmanında hücre sayısı tek olmak zorunda değildir. Çıkış katmanındaki her hücre, kendinden önceki katmanın her hücresine bağlı olmak zorundadır (Kakıcı, 2009; Yalçın, 2012).

8.1.1.3. Yapılarına göre yapay sinir ağları

İleri beslemeli YSA: İleri beslemeli yapay sinir ağlarında gelen bilgi, giriş katmanından ara katmana, ara katmandan da çıkış katmanı şeklinde iletilir. İleri beslemeli yapay sinir ağlarında girişten çıkışa kadar düzenli nöron ve katman sıralaması mevcuttur. Bir katman sadece kendinden sonraki katmanlar ile bağ yapmaktadır. İleri beslemeli YSA'da bir hücrenin çıktısı sadece kendisinden sonra gelen hücreye giriş olarak verilir.

Geri Beslemeli YSA: Geri beslemeli yapay sinir ağlarında bir hücrenin çıktısı kendinden sonra gelen hücrenin girdisi olabileceği gibi, kendinden önceki katmanda bulunan bir hücreye de girdi olarak verilebilir (Çayıroğlu, 2010).

8.1.1.4. Öğrenme algoritmalarına göre yapay sinir ağları

Danışmanlı Öğrenme: Bu sistemde olayın öğrenilebilmesi için bir danışmana yani öğreticiye ihtiyaç vardır. Bu öğretici ile sisteme, öğretilmesi istenilen olay ile ilgili örnekler girdi-çıkı seti olarak verilir. Yani sisteme her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar gösterilir. Ağın görevi girdilerin öğreticinin belirlediği çıktılara haritalamaktır. Bu sayede olayın girdileri ile çıktıları arasındaki ilişkiler öğrenilmektedir (Öztemel, 2006).


Danışmansız Öğrenme: Bu sistemde öğrenmeye yardımcı olan herhangi bir danışman veya öğretici yoktur. Sisteme sadece girdiler verilir, örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Danışmanlı öğrenmeye göre çok daha hızlıdır ve matematik algoritmaları daha basittir. ART (Adaptif rezonans teori) ağları örnek olarak verilebilir (Yalçın, 2012).

Karma öğrenme: Kısmen danışmanlı veya kısmen danışmansız olarak öğrenme yapan ağlardır. Radyal tabanlı yapay sinir ağları (RBN) ve olasılık tabanlı ağlar (PBN) bunlara örnek gösterilebilir (Öztemel, 2006).

8.1.2. Çok katmanlı algılayıcı (MLP) sinir ağı

Çok katmanlı algılayıcı sinir ağları (MLPNN) doğrusal olmayan olayları çözmek amacıyla geliştirilen bir YSA modelidir. Bunu doğrusal olmayan aktivasyon fonksiyonuna sahip nöronların hiyerarşik olarak bağlanması ile sağlamaktadır. Çok

katmanlı Öğrenme sistemi olarak danışmanlı öğrenme sistemi içerisinde yer alan genelleştirilmiş delta kuralını kullanmaktadır. Ağa, hem örnekler hem de örneklerden elde edilmesi gereken çıktılar verilmektedir. Yapısına göre ise geri beslemeli YSA modeline dâhildir (Kabalcı, 2013). Çok katmanlı algılayıcı sinir ağlarının yapısı Şekil 8.3’de görülmektedir.



Şekil 8. 3. Çok katmanlı algılayıcı sinir ağının yapısı (Kabalcı, 2013).

Çok katmanlı algılayıcı sinir ağlarında sık kullanılan iki aktivasyon fonksiyonu vardır. Bunlar: sigmoid ve hiperbolik tanjant'tır. Aktivasyon fonksiyonlarının matematiksel gösterimi Eşitlik 8.1 ve Eşitlik 8.2’ de verilmiştir (Öztemel, 2006):

Sigmoid:

$$y = \frac{1}{1 + e^{-net}} \quad (8.1)$$

Hiperbolik tanjant:

$$y = \frac{1 - e^{-2net}}{1 + e^{2net}} \quad (8.2)$$

8.1.3. Destek vektör makineleri

Bu tez çalışmasında kullanılan sınıflandırma algoritmalarından bir diğeri destek vektör makineleri algoritmasıdır. Bu sebeple bu sınıflama algoritması bu kısımda açıklanacaktır.

Destek vektör makineleri (DVM) etkili bir veri sınıflandırma yöntemlerinden biridir. Sınıflandırma ve regresyon hesaplarında sıkça kullanılan bu yöntem Vapnik tarafından 1960'ların sonlarına doğru geliştirilmiştir (Çomak, 2004). Destek vektör makineleri istatistiksel öğrenme ve yapısal risk minimizasyonu ilkesine dayanan, iki sınıflı veri kümelerini sınıflandırabilen ve regresyon problemlerinin çözümü amacıyla ortaya çıkartılmış bir makine öğrenmesi tekniğidir (Tayyar ve Tekin, 2013).

Bir sınıflandırma işleminde genellikle test ve eğitim amacıyla veriler kullanılır. Eğitim verilerinden her biri bir hedef değeri (sınıf etiketi) ve birçok özellik (öznitelik) içerir. DVM'nin amacı, test edilecek veri setindeki örneklerin hedef değerini (sınıfını) tahmin edebilen bir model geliştirmektir (Vapnik 1995, 1998).

DVM'nin en önemli avantajı, karmaşık problemlerin çözümünde iyi bir performans göstermesidir ve uygulama kolaylığı sağlamasıdır. Çünkü DVM'ler doğrusal bir diskriminant fonksiyonuna dayanmaktadır ve geniş marj sınıflandırıcısı ve Vapnik-Chervonenkis teorisi tarafından ispat edilebilir durumdadır. Sahip olduğu bu özellik sayesinde verinin hatasız ayrılabilmesi problemiyle başa çıkabilmektedir (Erastö, 2001).

DVM'ler marjini maksimize etmek üzere eğitilmişlerdir. Bu nedenle eğitim verilerinin çok az olduğu durumlarda bile genelleme kabiliyetleri iyidir.

Sağladığı kolaylıklardan dolayı pek çok alanda uygulanmalarına rağmen DVM'lerin bir takım zayıf yönlerinden de söz edilebilir. Örneğin; veri sayısının çok fazla ya da yüksek boyutlu olduğu problemlerde, veri kümesi üzerinde DVM'nin eğitimi, zaman alır. Ayrıca DVM'ler doğrudan karar fonksiyonları kullanır. Bu nedenle çoklu sınıf problemleri doğrudan genişletilemez ve çok fazla formülasyonu vardır (Abe, 2005).

DVM'ler hem doğrusal olarak ayrılabilen, hem de doğrusal olarak ayrılamayan verilere uygulanabildiğinden iyi bir sınıflandırıcıdır (Tekin, 2013).

DVM, verileri optimal olarak iki kategoriye ayıran n -boyutlu bir hiperdüzlem oluşturmaktadır. DVM modelleri yapay sinir ağlarıyla yakından ilişkili olup, sigmoid bir kernel fonksiyonu kullanan DVM; iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir (Ercan, 2011).

8.1.3.1. Doğrusal ayrılabilen veriler için destek vektör makineleri

Destek vektör makineleri şu şekilde sınıflandırma gerçekleştirmektedirler: Eğitim verisi ve karar fonksiyonu sayesinde, $\{+1, -1\}$ şeklinde sınıf etiketlerine sahip

veriler birbirinden ayrılması amaçlanır. Karar fonksiyonu yardımı ile verileri en uygun şekilde ayıracak hiperdüzlemi bulmaya çalışmaktadır. İki sınıflı verileri birbirinden ayıracak pek çok hiperdüzlem mevcuttur. DVM kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkartan hiperdüzlemi aramaktadır. Veri kümeleri arasındaki sınırın maksimum olanı, optimum hiperdüzlem olarak adlandırılmaktadır. Sınır genişliğini sınırlandıran noktalar destek vektörler olarak isimlendirilirler (Kavzoğlu ve Çölkesen, 2010).

DVM'nin eğitimi için kullanılacak l elemandan oluşan veri kümesinin $\{x_i, y_i\}, i = 1, 2, \dots, l$ olduğunu varsayalım. Burada $y_i \in \{-1, 1\}$ etiket değerleri ve $x_i \in R^d$ özellikler vektörüdür. Doğrusal olarak ayrılabilme durumunda, bu veriler doğrudan bir hiperdüzlem ile ayrılabilir. Bu hiperdüzleme ayırıcı hiperdüzlem adı verilir. DVM'nin amacı bu hiperdüzlemin iki örnek grubuna eş uzaklıkta olmasını sağlamaktır (Tayyar ve Tekin, 2013).

Hiperdüzlem üzerindeki herhangi bir x noktası, w ağırlık vektörü (hiperdüzlemin normali), $|b|/\|w\|$ hiperdüzlemin orijine dik uzaklığı ve $\|w\|$, w 'nin öklit normu olmak üzere,

$$w \cdot x + b = 0 \quad (8.3)$$

koşulunu sağlar. d_+ ve d_- 'nin ayırıcı hiperdüzleme en yakın olan pozitif ya da negatif örneklerin hiperdüzleme olan uzaklığını gösterdiği varsayıldığında, d_+ d_- ayırıcı hiperdüzlemin sınırı (marjini) olarak tanımlanır. DVM'nin amacı, örnekler doğrusal olarak ayrılabilirse, optimum ayırıcı hiperdüzlemi bulmaktır. Bunun için tüm eğitim setinin aşağıdaki koşulları sağladığı varsayıldığında;


$$y_i = +1 \text{ için } w \cdot x_i + b \geq +1 \quad (8.4)$$

$$y_i = -1 \text{ için } w \cdot x_i + b \leq -1 \quad (8.5)$$

Bu eşitsizlikleri bir arada ifade edecek olursak:

$$y_i (w \cdot x_i + b) \geq +1 \quad (8.6)$$

İfadesi elde edilir. Optimum ayırıcı hiperdüzlem, sınırı maksimum yapan hiperdüzlemdir (Şekil 8.4). Optimum ayırıcı hiperdüzlemi bulmak için uygun w ve b değerleri hesaplanacaktır.




Şekil 8. 4. Doğrusal ayrılabilen veriler için optimum ayırıcı hiperdüzlem (Tekin, 2013).

(8.4) ve (8.5)'deki eşitsizlik durumu göz önüne alındığında, $w.x_i + b = +1$ olması durumunda Şekil 8.4'deki H_1 hiperdüzleminin orijine dik uzaklığı $|1-b|/||w||$ ve $w.x_i + b = +1$ olması durumunda ise H_2 hiperdüzleminin orijine uzaklığı $|-1-b|/||w||$ olacaktır. Dolayısıyla $d_+ = d_- = 1/||w||$ kadar olur. Yani H_1 ve H_2 hiperdüzlemlerinin optimum hiperdüzleme uzaklığı $1/||w||$ kadardır. Burada sınır değeri ise $2/||w||$ kadardır. H_1 ve H_2 hiperdüzlemlerinin birbirlerine paralel olmalarından dolayı aralarında hiçbir eğitim noktası bulunmamaktadır. Bu iki hiperdüzlem arasındaki maksimum uzaklık, (8.6)'daki koşula bağlı olarak, $||w||^2$ değerinin minimize edilmesi ile bulunabilir. Eşitsizlik (8.6)'da gösterilen ve değerinin kaldırılması, elde edilen çözümün değişmesine yol açabilen eğitim noktalarına (aralarındaki sınır maksimum olan H_1 ve H_2 hiperdüzlemlerin üzerinde yer alan noktalar) destek vektörleri (DV) adı verilmektedir (Tekin, 2013).

8.1.3.2. Doğrusal olmayan destek vektör makineleri: haritalama yaklaşımı ve çekirdek fonksiyonlarının kullanımı (Kernel trick)

Doğrusal olmayan DVM, veri setinin doğrusal bir fonksiyonla tam veya belirli bir hata ile ayrılamaması durumunda kullanılan algoritmalardır. Gerçek yaşam problemlerinde bir veri setinin hiperdüzlem ile doğrusal olarak ayrılması çoğunlukla mümkün değildir. Dolayısıyla sınıfları ayırma işlemi, ayırma eğrisinin tahmin edilmesiyle mümkün olmaktadır. Ancak uygulamada eğrinin tahmin edilmesi oldukça zordur. Veri setinin doğrusal ayrılamama durumunun geometrik gösterimi Şekil 8.5’de verilmiştir.



Şekil 8. 5. Veri kümesinin doğrusal olarak ayrılamaması durumu (Statsoft, 2015).

Bu durumda p -boyutlu girdi vektörü x 'in P -boyutlu özellik vektörü Φ 'ye dönüştürülmesi gerekmektedir (Cortes ve Vapnik, 1995). p -boyutlu girdi vektörü x 'in P -boyutlu özellik vektörü Φ 'ye dönüştürülebilmesi için en uygun ayırma düzleminin özellik uzayında tanımlanabilmesi gerekir. Bu amacı gerçekleştirmek için doğrusal olmayan haritalama yaklaşımından yararlanılır (Busuttil, 2003).


8.1.4. K-en yakın komşu algoritması (k-NN)

Bu tez çalışmasında kullanılan sınıflandırma algoritmalarından bir diğeri de k en yakın komşu algoritmasıdır. Bu sebeple bu sınıflama algoritması bu kısımda açıklanacaktır.

K-en yakın komşu (k-NN) algoritması öznitelik uzayındaki en yakın eğitim kümesindeki örneklerle bakılarak nesneleri sınıflandırabilen basit ve kullanışlı örüntü

tanıma yöntemlerinden birisidir. K-en yakın komşu algoritması geniş bir uygulama alanına sahiptir (Alpaydin, 2004; Özkan 2008).

En geniş kullanım alanı sınıflama problemleridir. Denetimli öğrenme kullanarak sınıflama problemlerini başarı ile çözen algoritmalarından biridir. Denetimli öğrenmeden kasıt, sınıflandırma için öğrenme kümesi kullanıyor olmasıdır (Çalışkan, 2008). Sınıflandırma, örneğe katılacak yeni bir nesnenin, öznelitliklerine göre bunu önceden tanımlı sınıflardan birine dâhil etme sürecidir. Dâhil edilecek olan sınıfın özelliklerinin biliniyor olması çok önemlidir (Çalışkan, 2008).



Şekil 8.6 K-en yakın komşu algoritması şematik gösterimi (Apinetree, 2015).

K en yakın komşu yönteminde örnek kümesindeki her bir verinin, sınıflardan birine dâhil edilmesi gereken yeni veriye olan uzaklıkları hesaplanır. En yakın uzaklığı sahip k adet verinin seçilmesi kuralına dayanmaktadır (Özkan, 2008; Çölkesen, 2011). Şekil 8.6’da k-en yakın komşu algoritmasının şematik olarak gösterimi verilmiştir.

Örnek olarak; k=2 alındığında en yakın iki komşunun, k=3 alındığında en yakın 3 komşunun ya da k=5 alındığında en yakın 5 komşunun yakınlığına bakılarak seçilen elemanın hangi sınıfta yer alması gerektiğine karar verilir. Bu yakınlıkların hesaplanmasında çoğunlukla Pisagor temelli uzaklıklar kullanılır. Öklid mesafesi bunlardan yaygın kullanılanlar arasındadır (Alpaydin, 2004).

Bu algorithmada atılacak ilk k parametresinin belirlenmesidir. İkinci adımda ise gözlemler arasındaki uzaklıklar hesaplanmalıdır. i ve j gözlemleri arasındaki uzaklıkların belirlenmesinde aşağıdaki Öklid uzaklık bağıntısı kullanılabilir:

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (8.7)$$

Uzaklıklar göz önüne alınarak $\min d(i, j)$ seçilir. Söz konusu uzaklıkla ilgili satırlar birleştirilerek yeni bir küme elde edilir. Bu durumda yeni uzaklıkların tekrardan hesaplanması gerekir.

Tek gözlem değerine sahip olan kümeler arasındaki uzaklıkları yukarıdaki formül ile hesaplayabiliriz. Ancak birden fazla gözlem değerine sahip olan iki küme arasındaki uzaklığın belirlenmesi gerektiğinde farklı bir yol izlenir. İki kümenin içerdği gözlemler arasında “birbirine en yakın olanların uzaklığı” iki kümenin bir birine olan uzaklığı kabul edilir (Özkan, 2008).

Algoritmanın performansını etkileyen kriterler şunlardır;


- K en yakın komşu sayısı (benzerlik ölçümü için seçilecek komşu sayısı: k),
- Eşik değer (etiketleme işlemi için verinin k en yakın komşuya olan benzerliklerinden hesaplanan ortalama değerinin kıyaslanmasında kullanılır)
- Benzerlik ölçütü
- Öğrenme kümesindeki normal davranışların yeterli sayıda olması (öğrenme kümesi yeterli çeşitlilikte ve sayıda normal davranış verisi içermiyorsa, test kümesinde yer alan yeni normal davranış verileri anormal olarak algılanabilir.)

8.1.5. Karar ağaçları (Decision tree)

Tez çalışmasında kullanılan sınıflandırma algoritmalarından bir diğeri de karar ağaçları(decision tree) algoritmasıdır. Bu sebeple bu sınıflama algoritması bu kısımda açıklanacaktır.

Karar ağaçları sınıflandırma alanında oldukça sık kullanılan anlaşılması ve kullanımı oldukça kolay olan bir algoritmadır (Agrawal ve ark, 1993). Karar ağacı, büyük veri kümelerini kendine has bir takım kurallar ile bölerek küçük veri kümelerine ayırmak için kullanılan bir algoritmadır (Sezer, 2008). Karar ağaçları büyük veritabanlarının kullanıldığı sınıflama problemlerinde başarı ile uygulanabilmektedir (Büyükışıklar, 2008).

Karar ağaçları yapı olarak akış şemalarına benzetilebilirler. Her bir düğüm her bir niteliği temsil eder. En üstteki yapı kök olarak adlandırılır ve onun hemen altında kalan yapılar dal, en alttaki yapılar ise yaprak olarak adlandırılır (Atılğan, 2011;Özkan, 2008). Şekil 8.7’de bir karar ağacının şeması görülmektedir (Atılğan, 2011).



Şekil 8. 7. Karar ağacı örneği (Sezer, 2008).

Karar ağacı kökten yapraklara doğru yinelemeli olarak veriyi bölerek kazanma yöntemine göre inşa edilir. Başlangıçta bütün veriler ağacın kökünde toplanır (Sezer, 2008). Karar ağaçları yinelemeli olarak çalışmaktadır. Döngüden çıkılabilmesi için öğelerin aynı sınıfa dâhil olması şartı vardır.

Sınıflandırılacak eleman kalmadı ise veya elemanların hepsi bir sınıfa aitse döngü sonlandırılır ve karar ağacı oluşturulmuş olur. Ağaç inşası sonunda elde edilen ağaç büyük ağaç olarak adlandırılır ve öğrenme kümesindeki deney ünitelerine en uygun ağaçtır (Sezer, 2008).

Karar ağaçlarının avantajları şu şekildedir:

- Karar ağacı oluşturmak zahmetsizdir, yorumlamak kolaydır.
- Anlaşılabilir kurallar oluşturulabilir.
- Sürekli ve ayrık nitelik değerler kullanılabilir.

Dezavantajları ise;

- Sürekli nitelik değerlerini tahmin etmekte çok başarılı değil.
- Sınıf sayısı fazla ve öğrenme kümesi örnekleri sayısı az olduğunda model oluşturma çok başarılı değil (Sezer, 2008).

Karar ağaçlarında hangi değişkenin ilk düğüm, yani kök düğüm olacağının belirlenmesinde çeşitli görüşler vardır. Bu görüşlerin her biri karar ağaçlarında ayrı bir algoritma olarak karşımıza çıkmaktadır. Bunlardan başlıcaları şunlardır:

ID3, C4.5, C5.0, CART, CHAID ve QUEST (Atılgan, 2011).

8.1.6. Naive bayes sınıflandırıcı

Tez çalışmasında kullanılan sınıflandırma algoritmalarından bir diğeri de naive bayes algoritmasıdır. Bu sebeple bu sınıflama algoritması bu kısımda açıklanacaktır.

Bayes sınıflayıcıları istatistiksel sınıflandırma teknikleri arasında yer alırlar (Özkan, 2008). Bayes sınıflayıcılarının temeli bayes teoremine dayanmaktadır. Bayes sınıflayıcılar bayes teoremine dayanarak sınıflama yaparlar (Özkan, 2008).

Bayes yada bayesian teoremi ise olasılık temelli bir teoremdir. Bu teoremi anlayabilmek için T_1 gibi bir olayı örnek olarak alalım. Bu olayın başka bir olayla bağdaşmaz olaylar olduğunu, yani $T_1 \cap T_N = \Phi$ olduğunu varsayalım (Özkan, 2008; Ural, 1978).

Bir A olayını T_1 cinsinden ifade etmek istersek koşullu olasılık bağıntısından yararlanılır. Yani $P(T_1 | A)$ olasılığı,

$$P(T_1 | A) = \frac{P(A | T_1)}{P(A)} \quad (8.8)$$

biçimindedir. Naive bayes modeli öğrenirken, her çıktının öğrenme kümesinde kaç kere meydana geldiğini hesaplar. Bulunan bu değere öncelikli olasılık ismi verilmiştir (Akbulut, 2006; Gülce, 2010). Banka üzerinden örnek verecek olursak: müşterilerin kredi kartı başvurularını “sağlam” “tehlikeli” olarak sınıflandırmak istemektedir. Sağlam risk çıktısı toplam 5 vaka içinde 2 kere meydana geldiyse sağlam risk için öncelikli olasılık 0,4’tür. Bu durumda kredi kartı isteyen müşteri hakkında hiç bir şey bilinmese bile, bu kişi 0,4 olasılıkla sağlam risk grubunda olduğu çıkarımı elde edilir.

Naive bayes bağımlı ve bağımsız değişkenlerin meydana gelme sıklıklarını bulur. Bu sıklıklar kullanılarak tahminler gerçekleştirilebilir (Yumak, 2011).

Bayes sınıflayıcısının birçok sınıflama problemlerinde çok başarılı sonuçlar verdiği görülmüştür (Çentik, 2013).

Naive bayes yaklaşımını bir örnek üzerinde inceleyecek olursak:

A ve B rasgele olaylar olsun;

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (8.9)$$

$P(A)$: A olayının bağımsız olasılığı

$P(B)$: B olayının bağımsız olasılığı

$P(B | A)$: olayının olduğu bilindiğinde A olayının olasılığı (Posterior, Artçıl Olasılık).

Naive bayes kuralına dayanarak $P(A | B)$ 'yi maksimum yapan durumlar hesaplanabilir.

“E” A olayının bütün durumlarının kümesi;

$$\begin{aligned} A_{MAX} &= \arg \max_{A \in E} P(A | B) \\ &= \arg \max_{A \in E} \frac{P(B | A)P(A)}{P(B)} \\ &= \arg \max_{A \in E} P(B | A)P(A) \end{aligned}$$

Burada $P(B)$ sabit olarak göz ardı edilebilir. Sınıflandırıcının görevi yeni bir örnek için doğru sınıfı tahmin etmek olacaktır. Sınıflandırma problemi öncül (a-priori) olasılıklar kullanılarak şu şekilde formüle edilebilir:

$P(v | X)$ = örnek durum için olasılık

$X = \langle a_1, \dots, a_k \rangle$ v sınıfının örnekleri

$P(\text{sınıf} = \text{tahmin edilen sonuç} | \text{parametre1, parametre2, parametre3, } \dots)$

X örneğine $P(v | X)$ olasılığını maksimum yapan sınıf etiketi atanır.

Bayes Teoremi:

$$P(v | X) = P(X | v)P(v) / P(X) \quad (8.10)$$

$P(X)$ bütün sınıflar için sabittir.

$P(v)$ = sınıfının bütün örneklerle karşı görel frekansı

$P(v | X)$ maksimum = $P(v | X)P(v)$ maksimum

$P(a_1, \dots, a_k | v) = P(a_1 | v) \dots P(a_k | v)$

Eğer i . Özellik kesikli değerde ise $P(a_i | v)$, v sınıfında i . özellik olarak a_i değerine sahip örneklerin görel frekansı olarak tahmin edilir.

Eğer i .ci özellik sürekli ise;

1. Kesikli hale getirilebilir


2. veya $P(a_i | v)$ Gauss (Normal) dağılımına sahip olduğu varsayılarak tahmin edilip, sadece ortalama varyans gereklidir. İki durumda da hesaplanabilir (Çentik, 2013).

8.1.7. Radyal tabanlı fonksiyon ağları

Tez çalışmasının hastalık tespit kısmında kullanılan sınıflama algoritmalarından biri de radyal tabanlı fonksiyon ağları algoritmasıdır. Bu bölümde bu algoritma anlatılacaktır.

Radyal tabanlı fonksiyon ağları ileri beslemeli yapay sinir ağlarının danışmanlı öğrenme gerçekleştiren bir modelidir. Daha basit ifade ile radyal tabanlı fonksiyon ağları (RTFA), yapay sinir ağlarının, değişik bir formudur da denilebilir. Diğer yapay sinir ağlarından iki önemli özelliği sayesinde ayırt edilebilir. Birincisi yapay sinir ağlarından daha farklı aktivasyon fonksiyonu kullanmalarıdır (Akbiğiç, 2011). Yapay sinir ağlarından bir diğer farkı da girdi nöronlarından gizli katman nöronlarına bilginin değiştirilmeden aktarılmasıdır. Diğer bir ifade ile girdi katmanı ile gizli katman arasındaki tüm bağlantı ağırlıklarının “1” olduğu söylenebilir.

RTFA Şekil 8.8’de görüldüğü üzere üç katmandan oluşmaktadır. İlk katman giriş katmanı olup kaynak düğümlerden (source nodes) oluşur. İkinci katman, yeteri kadar yüksek boyuta sahip ve aktivasyon olarak RTF kullanan gizli katmandır. Üçüncü katman ise giriş katmanından ağa gösterilen bir girdi vektörüne göre ağın çıktısının üretildiği çıkış katmanıdır. RTFA’da giriş katmanından gizli katmanına doğrusal olmayan, gizli katmandan çıkış katmana doğrusal bir dönüşüm söz konusudur (Çetinkaya, 2011).



Şekil 8. 8. Radyal tabanlı fonksiyon ağlarının yapısı (Cenaero, 2015).

Radyal tabanlı fonksiyon ağlarının mimarisi basittir. Bu basitlik sayesinde RTFA önemli avantajlara sahiptir. Bu avantajlardan birisi, diğer geriye yayılım algoritmalarına göre daha hızlı eğitilebilmeleri olarak ifade edilebilir. Hızlı eğitilebilmesinin sebebi değeri değiştirilecek parametre sayısının az olmasıdır dolayısı öğrenme hızlanır. Belirlenmesi gereken tek parametre gizli katmanda bulunacak nöron sayısıdır. Ayrıca diğer modellere göre kullanıcı tarafından deneme yanılma ile belirlenen parametrelerin az oluşu, RTFA'nın daha kullanışlı olmasını sağlamaktadır (Özkan, 2008).

RTFA'nın çalışması şu şekildedir: girdi katmanından gelen bilgi gizli katmanda radyal tabanlı fonksiyonlar aracılığıyla işlendikten sonra ilgili ağırlık değerleri ile çarpılarak çıktı katmanına iletilir. RTFA' da bilgi akışına ilişkin ifade edilenlere göre, gizli katmanda bulunan nöron sayısı ve herhangi bir p ' inci nörona atanmış RTF h_p ile gösterilmek üzere, tek çıktılu bir radyal tabanlı fonksiyon ağının x girdisin karşılık ürettiği değer, doğrusal bir model oluşturacak şekilde (8.11) ile ifade edilmektedir.

$$f(x, w) = \sum_{p=1}^P w_p h_p(x) = w_1 h_1(x) + w_2 h_2(x) + \dots + w_p h_p(x) \quad (8.11)$$

$f(x, w) \in R$ ağın çıktısını, $x \in R$ ağın girdisini, $\{h_p(x)\}_{p=1}^P$ gizli katman nöronlarının çıktılarını ve $\{w_p\}_{p=1}^P$ parametreleri ise gizli katmanı çıktı katmanına

bağlayan ağırlık parametrelerini göstermektedir. Eşitlik (8.11)'deki notasyonunun kullanılmasıyla tek çıktılı RTFA modelinin çıktısı, Eşitlik (8.12) ile verilen tipik bir doğrusal modele dönüşür (Haykin, 1994).

$$y = Hw \quad (8.12)$$

Radyal tabanlı fonksiyon ağlarına ismini veren radyal fonksiyonları aşağıda listelenmiştir:

Gaus RTF:

$$h_j = e^{-\sum_{k=1}^p \frac{(x_k - c_{jk})^2}{r_{jk}}} \quad (8.13)$$

Cauchy RTF:

$$h_j = \frac{1}{1 + e^{-\sum_{k=1}^p \frac{(x_k - c_{jk})^2}{r_{jk}}}} \quad (8.14)$$

Çoklu Kuadratik RTF:

$$h_j = \sqrt{1 + e^{-\sum_{k=1}^p \frac{(x_k - c_{jk})^2}{r_{jk}}}} \quad (8.15)$$

Ters Çoklu Kuadratik RTF:

$$h_j = \frac{1}{\sqrt{1 + e^{-\sum_{k=1}^p \frac{(x_k - c_{jk})^2}{r_{jk}}}}} \quad (8.16)$$

8.1.8. LVQ yapay sinir ağları

LVQ Yapay sinir ağlarının farklı bir modelidir. LVQ birçok YSA modelinde olduğu gibi sınıflandırma problemlerinde başarı ile uygulanabilmektedir. LVQ sinir ağları, destekleyici öğrenme yöntemi kullanmaktadır.

LVQ yapay sinir ağı 1984 yılında Kohonen tarafında geliştirilmiştir. LVQ ağının öğrenme kuralına geliştiricisinin adı olan Kohonen öğrenme kuralı da denmektedir.

Bu kurala göre: Kohonen katmanında yer alan işlem elemanları birbirleri ile yarışmaktadırlar. Girdi vektörüne en yakın olmayı başaran referans vektörüne sahip proses elemanı yarışmayı kazanır. Girdi vektörümüzün X olduğunu referans vektörümüzün ise A olduğunu varsayalım. Bu ikisi arasındaki mesafeyi d ile gösterelim. Buna göre i . proses elemanın uzaklığı Eşitlik 8.17 deki gibi olmaktadır (Öztemel, 2006).

$$d_i = \|A_i - X\| = \sqrt{\sum_j (A_{ij} - x_j)^2} \quad (8.17)$$

LVQ ağınnın ağırlıklarının değiştirilmesi Eşitlik 8.18'e göre yapılmaktadır. Bu eşitlikte λ öğrenme katsayısıdır. Öğrenme katsayısının değeri zamanla sıfırı alacak şekilde azalmaktadır. Böyle olmasının sebebi girdi vektörünün, referans vektörüne çok yaklaştıktan sonra tekrar uzaklaşmaması içindir.

$$A_y = A_e + \lambda(X - A_e) \quad (8.18)$$


Bazı durumlarda kazanan proses elemanı yanlış sınıfa ait olabilmektedir. Bu durumun önüne geçmek için ağırlık vektörü, girdi vektöründen uzaklaştırılmaktadır. Aynı örnek tekrar sisteme girildiğinde, yarışı tekrar yanlış sınıfa ait proses elemanı kazanmasın diye bu işlem gerçekleştirilir. Eşitlik 8.19'daki gibi ağırlıklar değiştirilir (Demetgül, 2008).

$$A_y = A_e - \lambda(X - A_e) \quad (8.19)$$

LVQ sinir ağınnın çıktısı şu şekilde hesaplanmaktadır: proses elemanlarını çıktı katmanına bağlayan ağırlık değerleri ile kohonen katmanındaki proses elemanlarının çıktıları çarpılır (Eşitlik 8.20).

$$C_i = \sum_j C_j^k \alpha_{ki} \quad (8.20)$$

LVQ sinir ağlarının yapısı Şekil 8.9'da görülmektedir.



Şekil 8. 9. LVQ sinir ağının yapısı (Afrinc, 2015).

8.2 DeneySEL Sonuçlar ve Tartışma

Bu kısımda hem UCI'den alınan veri kümesi hem de tez çalışması için Selçuk Üniversitesi Tıp Fakültesi Hastanesinden elde edilen veri kümesinin sonuçları tartışılacaktır.

8.2.1. Performans değerlendirme testleri

Makine öğrenmesi algoritmalarının performansını değerlendirmek için karmaşıklık matrisi kullanılır. Bu karmaşıklık matrisi Çizelge 8.1'de tanımlanmıştır.

Çizelge 8.1 Karmaşıklık matrisi

Verilerin Gerçek Sınıfı	Sınıflayıcının Sonucu	
	Sağlıklı Teşhisi	Hasta Teşhisi
Doğru	Doğru Pozitif	Yanlış Pozitif
Yanlış	Yanlış Negatif	Doğru Negatif

Biyomedikal bilgi sistemleri üzerine uygulanan makine öğrenmesi algoritmaları, aşağıda yer alan ölçümler kullanılarak değerlendirilirler (Kohavi ve Provost 1998):

Doğru Pozitif (DP):Uzman tarafından hasta olarak etiketlenmiş bir verinin sistem tarafından hasta olarak sınıflandırılması.

Doğru Negatif (DN): Uzman radyolog tarafından sağlıklı olarak etiketlenmiş bir verinin sistem tarafından sağlıklı olarak sınıflandırılması.

Yanlış Pozitif (YP): Uzman tarafından sağlıklı olarak etiketlenmiş bir verinin sistem tarafından hasta olarak sınıflandırılması.

Yanlış Negatif (YN): Uzman radyolog tarafından hasta olarak etiketlenmiş bir verinin sistem tarafından sağlıklı olarak sınıflandırılması.

Sınıflayıcıların, sınıflama performansları ise DP, DN, YP ve YN kriterlerini kullanarak formüle edilen duyarlılık, belirlilik, ortalama belirleme oranı ve doğruluk kavramları ile değerlendirilirler (Şengür 2006). Bu kavramlar:

Duyarlılık: Sınıflayıcının hastalığı belirleyebilme oranıdır.

$$Duyarlılık = \frac{DP}{DP + YN}$$

Belirlilik: Sınıflayıcının sağlıklıyı belirleyebilme oranıdır.

$$Belirlilik = \frac{DN}{DN + YP}$$

Ortalama Belirleme Oranı: Duyarlılık ve belirliliğin ortalamasıdır.

$$Ortalama\ Belirleme\ Oranı = (Duyarlılık + Belirlilik) / 2$$

Doğruluk: Testin hasta ve sağlıklıyı toplam belirleme oranıdır.

$$Doğruluk = \frac{DP + DN}{DP + YP + YN + DN}$$

Yukarıda verilen kriterlere ek olarak pozitif tahmin değeri ve negatif tahmin değeri kriterleri de sınıflayıcı performansını değerlendirebilmek amacı ile kullanılmaktadır.

Pozitif Tahmin Testi: Pozitif testte bir kişinin hasta olma olasılığı

$$Pozitif\ Tahmin\ Testi = \frac{DP}{DP + YP}$$

Negatif Tahmin Testi: Negatif testte bir kişinin sağlıklı olma olasılığı

$$Negatif\ Tahmin\ Testi = \frac{DN}{DN + YN}$$

f-ölçütü: Duyarlılık ile Hassasiyet in harmonik ortalamasıdır.


$$f\text{-ölçütü} = \frac{2DP}{(2DP + YP + YN)}$$

Roc Eğrisi

ROC eğrisi doğru pozitif orana karşılık, yanlış pozitif oranın noktalar halinde çizilmesi ile ortaya çıkan eğri olarak ifade edilebilir. ROC eğrisi, medikal tanı testlerinin doğruluğunun kontrolünde, testlerin güvenilirlik ve karşılaştırma gibi durumlarında başarı ile kullanılmaktadır. Ayrıca tanı testinin performansını ölçerek yeni tanı testlerinin geliştirilmesini de sağlar. ROC eğrisi, yapılan tanı testlerinin değerlendirilip sayısal sonuçlarla açıklanması ve tahminlerin doğruluğunun karşılaştırılmasını sağlar. Eşik değerin belirlenmesini sağlar. Günümüzde klinik alanların çoğunda, özellikle olarak tanı, tarama ve laboratuvar testlerinde kullanımı giderek yaygınlaşmaktadır.

Klinik çalışmalarda sürekli sayılar kullanıldığından dolayı ölçümlerde olguları hasta ve sağlam olarak ayırma, çözümlemeyi karmaşık hale getirebilir ve dolayısı ile hata olasılığı artabilir. Koordinat sisteminde Y eksenine doğru pozitif değeri, X ekseninde ise yanlış pozitif değeri yerleştirilerek ROC eğrisi elde edilir. Doğru pozitif ve yanlış negatife karşılık gelen noktalar birleştirildiğinde ROC eğrisi elde edilmiş olur.

ROC eğrileri oluşturdukları şekillere göre kötü, iyi ve mükemmel olarak değerlendirilirler. Bu değerlendirilmelere ilişkin grafik Şekil 8.10'da verilmiştir.



Şekil 8. 10. ROC eğrilerinin performansa göre gösterimi (Gim, 2015).

ROC eğrisinin altında kalan alana bakılarak, tanı testinin hasta bireyler ile hasta olmayan bireyleri ne kadar doğru olarak ayırıp ayıramadığının kontrolü yapılabilir.

ROC eğrisi altında kalan alanın büyüklüğü bize tanı testinin başarısını istatistiksel olarak gösterir. Tanı testinin başarısının hiç olmadığı durumda ROC eğrisinin altında kalan değeri 0.50'dir. Tanı testinin başarısının mükemmel olduğu

durumda ROC eğrisinin altında kalan değeri 1'dir. Genellikle tanı testlerinin ROC eğrisi altında kalan değerleri 0.50 ile 1 arasındadır. ROC eğrisi altındaki alanın yorumlanmasında aşağıdaki dereceler kullanılabilir:

.90-1.00 = mükemmel

.80-.90 = iyi

.70-.80 = orta

.60-.70 = zayıf

.50-.60 = başarısız

8.2.2 UCI makine öğrenmesi veritabanından alınan veriler ile ilgili sonuçlar

UCI'den alınan veriler ile ilgili bilgiler bölüm 3.1.2'de anlatılmıştır. Bu bölümde ise yapılan analizlerde elde edilen sonuçlardan bahsedilecektir. UCI makine öğrenmesi veritabanından alınan verilere öncelikle ikili bulanık c-ortalama tabanlı veri ağırlıklandırma uygulanmış ve ağırlıklandırılan bu veriler MLP, k-NN, naive bayes ve DVM sınıflayıcılar ile sınıflandırılmıştır.


UCI makine öğrenmesi veritabanından alınan bel bölgesi veri kümesi (vertebral column dataset) içinde altı adet özellik ve bu verilerin ayrıldığı üç sınıf bulundurmaktadır. Özellikler: Pelvik insidans, pelvik tilt, lomber lordoz açısı, sakral eğim, pelvik yarıçapı ve spondilolistezis derecesidir. Sınıflar ise bel fıtığı (disk hernia, DH), disk kayması (spondylolisthesis, SL) ve normal (NO) sınıflarıdır (UCI, 2015).

Bu özelliklerin ham hallerinin ve ikili bulanık c-ortalamlar yöntemi ile ağırlıklandırılan hallerinin istatistiki değerleri Çizelge 8.2'de verilmiştir.

Çizelge 8.2 UCI vertebral column veritabanındaki özellik vektörlerinin istatistiki değerleri


Özellik Durumu	Özellik Adı	Min. Değer	Mak. Değer	Ortalama Değer	Standart Sapma	Özellik ve çıkış sınıfı arasındaki korelasyon Katsayısı
Ham	Pelvic_incidence	26.148	129.834	60.497	17.237	-0.029
Ağırlıklandırılmış		18.58	195.32	69.27	40.75	-0.167
Ham	Pelvic_tilt	-6.555	49.432	17.543	10.008	-0.211
Ağırlıklandırılmış		-9.84	74.26	20.55	16.86	-0.372
Ham	Lumbar_lordosis_angle	14	125.742	51.931	18.554	0.036
Ağırlıklandırılmış		8.45	212.31	64.69	46.69	-0.131
Ham	Sacral_slope	13.367	121.43	42.954	13.423	0.12
Ağırlıklandırılmış		7.94	182.79	49.81	29.43	-0.026
Ham	Pelvic_radius	70.083	163.071	117.92	13.317	0.234
Ağırlıklandırılmış		65.86	153.27	116.63	15.08	0.202
Ham	Degree_spondylosisthesis	-11.058	418.543	26.297	37.559	-0.119
Ağırlıklandırılmış		-0.84	5859	351.58	533.107	-0.120

Bu üç sınıflı ham ve ağırlıklandırılmış verilerin sınıflara göre dağılım grafiği Şekil 8.11’de görülmektedir. Kırmızı ile bel fıtığı (disk hernia), yeşil ile disk kayması (spondylolisthesis) ve mavi ile normal sınıfına ait veriler gösterilmiştir. Üstteki grafikte ham verilerin farklı bölgelere yayıldığı görülmektedir. Alttaki grafikte ise ağırlıklandırılan verilerin belli bölgelerde kümелendikleri açıkça görülmektedir. Verilerin belli bölgelere kümelenmeleri onların birbirinden daha kolay ayırt edilebilmesini dolayısı ile daha kolay sınıflara ayrılabilmelerini sağlamıştır. Verilerin ağırlıklandırılmasındaki amaç lineer olarak ayrılamayan verilerin daha kolay sınıflanabilir hale getirilmesidir.




Şekil 8. 11. Ham ve İBCOTVA ile ağırlıklandırılmış veri dağılımlarının grafiksel gösterimi

İkili bulanık c-ortalama tabanlı veri ağırlıklandırma (İBCOTVA) yöntemi detaylı olarak Bölüm 7.2’de anlatılmıştır. Üç sınıflı olan veri kümesindeki sınıflar ikili olarak eşleştirilmiştir. Bel fıtığı ve bel kayması (DH-SL), bel fıtığı ve normal (DH-NO), disk kayması ve normal (SL-NO) sınıfları çiftli hale getirilmiştir. Çiftli hale getirilen sınıflar Şekil 8.12’de verilmiştir.




Şekil 8. 12. Bel bölgesi veri kümesine gruplamalı bulanık c-ortalama tabanlı veri ağırlıklandırma yönteminin uygulanması (DH: Disk Hernia, SL: spondylolisthesis, NO:Normal)

İkili olarak gruplanan veriler bulanık c-ortalamlar yöntemi ile ağırlıklandırılmıştır. Bu ağırlıklandırmadaki benzer verilerin bir araya kümelenmesinin sağlanarak amaç sınıflama doğruluğunun artırılmasıdır. Bu sebeplerden dolayı sınıflama aşamasından önce veri ağırlıklandırma işlemi fayda sağlamaktadır. İkili grupların ham ve ağırlıklandırılmış veri dağılım grafiği Şekil 8.13’de verilmiştir. Ağırlıklandırılmış ikili grupların ağırlıklandırılmamış ikili gruplara göre daha kolay sınıflanabilir duruma gelmiştir.



Şekil 8. 13. İkili olarak gruplandırılan ham ve İBCOTVA ile ağırlıklandırılmış verilerin dağılımlarının grafiksel gösterimi

İkili gruplar halinde ağırlıklandırılan veriler daha sonra MLP, K-NN, DVM ve naive bayes ile sınıflandırılmıştır. Daha sonra sınıflandırılan verilerin sınıflama doğruluk değerlendirme yapılmıştır (Şekil 8.14).



Şekil 8. 14. Önerilen metodun blok diyagramı

Çizelge 8.3’de ikili grupların K-NN, MLP, DVM ve naive bayes sınıflandırma sonuçları görülmektedir. Sınıflama işleminin doğruluğunu onaylayabilmek amacı ile 10 kat çapraz-geçerlilik testi uygulanmıştır. Bu teste göre tüm veri seti 10 eşit veri setine ayrılmakta ve ağırlıklandırma işlemi için bu 10 setten 9’u kullanılırken, geriye kalan 1 set ile ağ test edilmektedir. Test işlemi bittiğinde bu kez testte kullanılan set eğitim kümesine dâhil edilirken eğitim kümesinden bir set de test kümesine alınmaktadır. Bu işlem 10 kez tekrarlandığında veri setinde bulunan tüm veriler ile ağırlıklandırma hem de test edilmesi sağlanmaktadır.

Buna göre, ikili grupların k-en yakın komşu (K-NN) algoritması ile sınıflandırılmasına göre ortalama % 92.12 sınıflama doğruluğu elde edilmiştir. Bu algortmada k değeri deneme yanılma yolu ile belirlenmiş ve en iyi k değeri 1 olarak belirlenmiştir.

Yine ikili grupların çok katmanlı algılayıcı (MLP) algoritması ile sınıflandırılmasına göre ortalama % 95.68 sınıflama doğruluğu elde edilmiştir.

İkili grupların destek vektör makinaları (DVM) algoritması ile sınıflandırılmasına göre ortalama % 94.02 sınıflama doğruluğu elde edilmiştir.

Son olarak ikili grupların destek vektör makinaları Naive Bayes algoritması ile sınıflandırılmasına göre ortalama % 95.84 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama doğruluğu %95.84 ile Naive bayes sınıflayıcısı yardımı ile elde edilmiştir.

Bu sınıflayıcılarda kullanılan parametre değerleri aşağıda verilmiştir. Bu parametrik değerler deneme yanılma yolu ile bu belirlenmiştir.

MLP için parametre değerleri: Öğrenme katsayısı: 0.3, momentum: 0.2, maksimum iterasyon sayısı: 500, gizli katman nöron sayısı: 15, aktivasyon fonksiyonu: sigmoid, hata değeri: <0.001

K-en yakın komşu algoritması için k=1 alınmıştır, mesafe ölçme yöntemi olarak oklid uzaklığı kullanılmıştır.

DVM için çekirdek fonksiyonu: polykernel, karmaşıklık parametresi c=1.0, tolerans değeri 0.001 alınmıştır.

RTFA için alınan minimum standart sapma değeri 0.1 alınmıştır. Gaussian fonksiyon kullanılan yöntemde sınıf sayısı 2 ve 3 alınmıştır.

LVQ yöntemi için parametre değerleri: Öğrenme katsayısı 0.3 ve maksimum iterasyon sayısı 500 alınmıştır.

Çizelge 8.3. İkili gruplamaların 10 kat çapraz-geçerlilik testi sonuçları

İkili Gruplar	Performans Ölçütü			Kullanılan Sınıflayıcı Tipi
	Sınıflama Doğruluğu (%)	Hassasiyet (%)	Seçicilik (%)	
DH-NO	91.875	94	88.33	k-NN (k=1 için)
DH-SL	95.71	98	90	
SL-NO	88.8	88	89.33	
Ortalama Değer	92.12	93.34	89.22	
DH-NO	90.00	91	88.33	MLP
DH-SL	99.04	98.66	100	
SL-NO	98	99	97.33	
Ortalama Değer	95.68	96.22	95.22	
DH-NO	94.37	96	91.66	DVM
DH-SL	95.71	96	95	
SL-NO	92	89	94	
Ortalama Değer	94.02	93.67	93.55	
DH-NO	92.50	93	91.66	Naive Bayes
DH-SL	99.04	100	96.66	
SL-NO	96	91	99.30	
Ortalama Değer	95.84	94.67	95.87	

Çizelge 8.4’de ham ve ağırlıklandırılmış veri kümelerinin 10 kat çapraz-geçerlilik testi uygulanarak çeşitli sınıflandırıcılar yardımı ile elde edilen sınıflama sonuçları verilmiştir. Buna göre ham veri kümesinde en iyi sınıflama doğruluğu %85.48 ile MLP sınıflayıcısı ile elde edilmiştir. Ağırlıklandırılan veri kümesinde ise en iyi sınıflama doğruluğu %97.42 ile naive bayes sınıflayıcısı ile elde edilmiştir. Ağırlıklandırılan verilerin sınıflama doğruluğunun oldukça arttığı görülmüştür

Çizelge 8.4. Ham ve bulanık c-ortalamalar yöntemi ile ağırlıklandırılan verilerin 10 kat çapraz-geçerlilik testi ile sınıflama sonuçları

Performans Ölçütü	10 kat çapraz-geçerlilik testi							
	k-NN Sınıflayıcısı (k=1)		MLP Sınıflayıcısı		Naïve Bayes Sınıflayıcısı		DVM Sınıflayıcısı	
	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler
Sınıflama Doğruluğu (%)	78.39	95.48	85.48	96.77	83.23	97.42	81.61	96.45
Hassasiyet(%)	71.82	95	75.50	97	65.09	97	72.64	98
Seçicilik (%)	82	95	90.38	96.66	92.65	97.62	86.27	95.71
Duyarlılık	0.69	0.91	0.79	0.93	0.82	0.95	0.73	0.91
Anma Değeri	0.72	0.95	0.75	0.97	0.65	0.97	0.73	0.98
f-ölçütü	0.70	0.93	0.77	0.95	0.73	0.96	0.73	0.95
ROC eğrisi Altında Kalan Alan	0.835	0.969	0.958	0.996	0.954	0.998	0.886	0.958
Hesaplama süresi (san.)	0	0	0.71	0.9	0.01	0.01	0.14	0.12

Çizelge 8.5’de ham ve ağırlıklandırılmış veri kümelerinin %50 eğitim %50 test olarak ayrılıp çeşitli sınıflandırıcılar yardımı ile elde edilen sınıflama sonuçları verilmiştir. Buna göre en iyi sınıflama doğruluğu % 96.77 ile naive bayes sınıflayıcısı yardımı ile elde edilmiştir. 10 kat çapraz-geçerlilik testine göre sınıflama doğruluklarında azalmalar gözlenmiştir.

Çizelge 8.5. Ham ve bulanık c-ortalama yöntemleri ile ağırlıklandırılan verilerin %50 test %50 eğitim verisi olarak ayrılmış sınıflama sonuçları

Performans Ölçütü	%50 test %50 Eğitim							
	k-NN Sınıflayıcısı (k=1)		MLP Sınıflayıcısı		Naïve Bayes Sınıflayıcısı		DVM Sınıflayıcısı	
	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler	Ham veriler	Ağırlıklı Veriler
Sınıflama Doğruluğu (%)	75.48	92.26	83.23	94.19	80.65	96.77	78.71	94.19
Hassasiyet(%)	59.18	97.73	66.66	95.45	68.09	100	71.42	100
Seçicilik (%)	83	90.09	90	93.69	86.11	95.50	82.07	91.89
Duyarlılık	0.62	0.80	0.73	0.85	0.68	0.90	0.65	0.83
Anma Değeri	0.59	0.98	0.66	0.95	0.68	1	0.71	1
f-ölçütü	0.60	0.88	0.70	0.90	0.68	0.95	0.68	0.90
ROC eğrisi Altında Kalan Alan	0.812	0.946	0.956	0.989	0.951	0.999	0.871	0.953
Hesaplama süresi (san.)	0	0	0.76	0.73	0.01	0.01	0.17	0.03

UCI vertebral column veritabanı üzerinde literatürde yer alan sınıflama performanslarının karşılaştırılması Çizelge 8.6’de verilmiştir. Buna göre ikili bulanık c-ortalama tabanlı veri ağırlıklandırma yöntemi ile ağırlıklandırılan veriler k-NN ile sınıflandırıldığında %95.48, MLP ile sınıflandırıldığında %96.77, naïve bayes ile sınıflandırıldığında %96.45 sınıflama doğruluğu elde edilmiştir. Sınıflama algoritmaları içerisinde en yüksek sınıflama doğruluğuna %97.42 oranıyla naïve bayes sınıflayıcısı ile ulaşılmıştır. Yine bu veritabanı üzerinde literatürde yer alan en yüksek sınıflama doğruluğuna tez çalışmamız için yapılan bu yöntem ile ulaşılmıştır.

Çizelge 8.6. UCI vertebral column veri kümesinin literatürde yer alan sınıflama performans karşılaştırma sonuçları

No	Yazar	Method	Sınıflama Doğruluğu (%)
1	Neto ve Barreto (2009)	DVM	82
		MLP	83
		GRNN	75
2	Neto ve Barreto (2009)	C-DVM	94
		C-MLP	88
		C-GRNN	81
3	Mattos ve Barreto (2011)	FA	83
		SOM	83
4	Neto ve ark. (2011)	DVM(different kernel)	85
5	Abdrabou (2012)	Hibrit CBR ve YSA	85

No	Yazar	Method	Sınıflama Doğruluğu (%)
6	Ansari ve ark. (2013)	YSA	93.87
		DVM	87.29
7	Çalışmamız (Unal ve ark, 2014)	İkili bulanık c-ortalamlar yöntemi ile veri ağırlıklandırma ve k-NN sınıflayıcısı	95.48
		İkili bulanık c-ortalamlar yöntemi ile veri ağırlıklandırma ve MLP sınıflayıcısı	96.77
		İkili bulanık c-ortalamlar yöntemi ile veri ağırlıklandırma ve Naïve Bayes sınıflayıcısı	97.42
		İkili bulanık c-ortalamlar yöntemi ile veri ağırlıklandırma ve DVM sınıflayıcısı	96.45

8.2.2. Hastaneden alınan veriler ile ilgili sonuçlar

Bölüm 3.1.1’de tez çalışması kapsamında hastaneden alınan veriler hakkında kapsamlı bilgiler yer almaktadır. Bu bölümde ise ilgili veri kümesi üzerinde yapılan analizlerden elde edilen sonuçlar anlatılmıştır. Öncelikle her bir hastadan hem aksiyal hem de sagittal MR görüntüleri elde edilmiştir. Bu görüntülere ön işlem uygulanarak görüntü kalitesi arttırılmıştır. Görüntü kalitesi arttırılan MR’lardan gereksiz alanlar çıkartılmıştır. Aktif şekil modeli ve yöntemleri ile özellik vektörleri elde edilmiştir. Elde edilen hibrit özelliklerin hangi eksen ve hangi bölgelerden elde edildiği Çizelge 8.7’da verilmiştir.

Çizelge 8.7. Elde edilen hibrit özellik vektörlerinin eksenleri ve bölgeleri

Özellik Numarası	Ekseni	Kullanılan Özelliklerin Bölgesi
1	Aksiyal	Sağ Lateral Kanal Genişliği
2	Aksiyal	Sol Lateral Kanal Genişliği
3	Aksiyal	Kanal Sağ Yüksekliği
4	Aksiyal	Kanal Dikey Çap
5	Aksiyal	Kanal Sol Yüksekliği
6	Aksiyal	Kanal Üst Genişliği
7	Aksiyal	Kanal Yatay Çapı
8	Aksiyal	Kanal Alt Genişliği
9	Sagittal	Disk yüksekliği
10	Sagittal	Disk parlaklığı
11	Sagittal	Disk genişliği
12	Sagittal	AŞM1 (Aktif Şekil Model)
13	Sagittal	AŞM2
14	Sagittal	AŞM3
15	Sagittal	AŞM4
16	Sagittal	AŞM5

17	Sagital	AŞM6
18	Sagital	AŞM7
19	Sagital	AŞM8
20	Sagital	AŞM9
21	Sagital	AŞM10
22	Sagital	AŞM11
23	Sagital	AŞM12
24	Sagital	AŞM13
25	Sagital	AŞM14
26	Sagital	AŞM15
27	Sagital	AŞM16

Buradaki ilk 8 adet özellik aksiyal MR görüntülerinin şekilsel özelliklerden elde edilmiştir. Dokuz, on ve onbir no'lu özellikler sagital eksenli MR görüntülerinden elde edilmiştir. Bunlar sırası ile disk yüksekliği, disk parlaklığı ve disk genişliğidir. On iki ve yirmi arasındaki (16 özellik) özellikler yine sagital eksenli görüntülerden elde edilmiştir. Bu özellikler aktif şekil modeli yöntemi ile elde edilmiştir. Özelliklerin nasıl elde edildiği ve elde edilme yöntemleri tezin ilgili bölümlerinde açıklandığı için burada tekrardan üzerinde durulmamıştır.

Normal sınıflı verilerin istatistiki değerleri Çizelge 8.8'de, hasta (anormal) sınıflı verilerin istatistiki verileri ise Çizelge 8.9'de verilmiştir.

Çizelge 8.8. Normal sınıflı verilerin istatistiki değerleri

Özellik Numarası	Min. Değer	Mak. Değer	Ortalama Değer	Standart Sapma	Varyans
1	0.24	0.95	0.5323	0.1293	0.0167
2	0.16	1.06	0.5385	0.1369	0.0187
3	0.4	1.94	0.918	0.1667	0.0278
4	0.75	1.84	1.276	0.1966	0.0386
5	0.53	81	1.364	5.9375	35.254
6	0.63	2.34	1.5326	0.2965	0.0879
7	0.9	2.54	1.7032	0.2980	0.0888
8	0.74	1.97	1.1274	0.1855	0.0344
9	0.71	3.63	1.2121	0.3545	0.125
10	24.98	307.24	38.931	20.241	409.72
11	1.07	4.76	3.5037	0.4125	0.1702
12	16	68	42.241	10.596	112.29
13	55	125	97.153	12.491	156.031
14	102	181	150.84	12.877	165.83
15	148	200	181.23	9.4226	88.78
16	117	188	157.3	9.783	95.714
17	71	162	103.46	12.69	161.078

18	25	107	51.043	13.16	173.40
19	7	76	25.983	9.25	85.56
20	15	57	34.846	7.72	59.688
21	8	39	22.137	5.335	28.47
22	10	47	25.9010	5.914	34.98
23	17	75	46.538	8.3	68.890
24	41	87	68.609	7.710	59.454
25	50	90	75.131	6.744	45.48
26	51	92	73.390	7.017	49.244
27	25	85	53.769	8.117	65.891


Çizelge 8.9. Hasta sınıflı verilerin istatistiki değerleri

Özellik Numarası	Min. Değer	Mak. Değer	Ortalama Değer	Standart Sapma	Varyans
1	0.05	0.9	0.2179	0.1117	0.0124
2	0.04	0.9	0.222	0.1230	0.0151
3	0.25	1.64	0.7805	0.2041	0.04167
4	0.47	1.65	1.055	0.2450	0.06003
5	0.2	1.53	0.8078	0.1854	0.03438
6	0.59	2.54	1.271	0.3335	0.11126
7	0.12	1.95	1.289	0.296	0.088008
8	0.31	1.92	0.921	0.192	0.03701
9	0.67	3.7	1.291	0.399	0.15945
10	6.366	46.364	27.64	5.332	28.43
11	0.67	4.8	3.834	0.553	0.30667
12	6	69	43.838	10.37	107.7
13	56	118	87.59	13.24	175.461
14	92	178	138.04	16.11	259.563
15	119	193	171.623	12.811	164.128
16	104	180	150.35	14.60	213.318
17	54	156	105.64	18.63	347.231
18	32	119	68.053	17.44	304.203
19	15	72	45.709	12.64	159.773
20	27	56	43.182	6.211	38.58
21	12	45	31.193	8.0071	64.114
22	15	50	32.20	7.061	49.859
23	23	68	43.623	8.863	78.563
24	27	80	57.430	9.456	89.42
25	40	86	60.82	9.005	81.10
26	45	90	60.032	9.346	87.357
27	39	71	53.569	5.97	35.660

Elde edilen toplam 27 adet özelliğin hangilerinin daha önemli hangi özelliklerin daha önemsiz olduğunun belirlenmesi amacı ile özellik seçme işlemine tabi tutulmuştur. Bunlar F-skor tabanlı veri seçme metodu ve korelasyon tabanlı veri seçme yöntemleridir. Yine bu yöntemler tezin ilgili bölümlerinde detaylı olarak anlatılmıştır.

F-skor tabanlı özellik seçme algoritmasının bel bölgesi MR görüntülerinden elde edilen hibrit özellik vektörlerine uygulanmasını gösteren akış diyagramı Şekil 8.15’de görülmektedir.

Veri kümesindeki her bir özellik için f-skor değeri hesaplanmıştır. Daha sonra ortalama f-skor değeri 0.724 olarak hesaplanmıştır. Eğer herhangi bir özelliğin f-skor değeri ortalama değerden büyük ise o özellik seçilmiştir. Eğer herhangi bir özelliğin f-skor değeri ortalama değerden küçük ise o özellik göz ardı edilmiştir. Her bir özelliğin numarası, ekseni, özelliğin adı, f-skor değeri Çizelge 8.10’da verilmiştir.



Şekil 8. 15. Bel bölgesi veritabanının f-skor ile özellik seçimi uygulamasını gösteren akış şeması

Aşağıdaki çizelgede (Çizelge 8.10) görüldüğü üzere birinci özelliğin f-skor değeri 3.534 olarak hesaplanmıştır. Birinci özelliğin f-skor değeri ortalama f-skor değeri olan 0.724'ten büyük olduğu için bu özellik sınıflama amacıyla seçilmiştir. Benzer şekilde 2, 9, 10, 22 no'lu özelliklerin F-skor değerleri ortalama f-skor değerinden büyük olduğu için bu özellikler sınıflama kümesine dâhil edilmiştir. Toplam 27 olan özellik sayısı F-skor tabanlı özellik seçme metodunun Bel bölgesi MR'larından elde edilen veri kümesine uygulanması ile 5'e düşmüştür.

Çizelge 8.10 27 özellik vektörünün f- skor değerleri


Veri kümesindeki özellik vektörlerinin numaraları	Eksen	Özelliklerin adı	F- skor değerleri
1 (seçilen özellik)	Aksiyal	Sağ Lateral Kanal Genişliği	3.534
2 (seçilen özellik)	Aksiyal	Sol Lateral Kanal Genişliği	4.185
3	Aksiyal	Kanal Sağ Yüksekliği	0.143
4	Aksiyal	Kanal Dikey Çap	0.068
5	Aksiyal	Kanal Sol Yüksekliği	0.372
6	Aksiyal	Kanal Üst Genişliği	0.018
7	Aksiyal	Kanal Yatay Çapı	0.121
8	Aksiyal	Kanal Alt Genişliği	0.031
9 (seçilen özellik)	Sagital	Disk yüksekliği	1.033
10 (seçilen özellik)	Sagital	Disk parlaklığı	5.341
11	Sagital	Disk genişliği	0.0367
12	Sagital	AŞM1 (Aktif Şekil Model)	0.003
13	Sagital	AŞM2	0.291
14	Sagital	AŞM3	0.630
15	Sagital	AŞM4	0.218
16	Sagital	AŞM5	0.048
17	Sagital	AŞM6	0.003
18	Sagital	AŞM7	0.136
19	Sagital	AŞM8	0.551
20	Sagital	AŞM9	0.346
21	Sagital	AŞM10	0.117
22 (seçilen özellik)	Sagital	AŞM11	1.495
23	Sagital	AŞM12	0.061
24	Sagital	AŞM13	0.281
25	Sagital	AŞM14	0.271
26	Sagital	AŞM15	0.217
27	Sagital	AŞM16	-1.45296029651327e-06
Ortalama F-skor değeri:			0.724

F-skor tabanlı özellik seçme yöntemi ile 27'den 5'e düşürülen özellikler çeşitli sınıflama algoritmaları ile 10 kat çapraz- geçerlilik testine tabi tutularak sınıflandırılmış ve sonuçlar Çizelge 8.11'da verilmiştir. Karar ağaçları ile yapılan sınıflamada %96 sınıflama doğruluğuna ulaşılmıştır. Sınıflama algoritmaları içinde en yüksek oran karar ağaçlarına ait olduğu görülmektedir.

Çizelge 8.11. 5 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP	DVM	Naïve Bayes	Karar Ağaçları
Özellik Sayısı	5	5	5	5
Sınıflama Doğruluğu (%)	94.1818	94.5454	94.18	96
Hassasiyet(%)	96.70	96.15	94.50	97.25
Seçicilik (%)	89.24	91.39	93.54	93.54
Duyarlılık	0.9462	0.9562	0.9662	0.9672
Anma Değeri	0.9670	0.9615	0.9450	0.9725
f-ölçütü	0.9565	0.9589	0.9555	0.9698
Kappa Değeri	0.9748	0.9751	0.9758	0.9747
ROC Eğrisi Altında Kalan Alan	0.9641	0.9378	0.9685	0.9513
Hesaplama Süresi (saniye)	0.62	0.04	0.01	0.04

Bel bölgesi MR görüntülerinden elde edilen 27 hibrit özellik vektörü korelasyon tabanlı özellik seçme yöntemi ile de özellik seçme işlemine de tabi tutulmuştur. Korelasyon tabanlı özellik seçme yöntemi Bölüm 6.2'de detaylıca anlatılmıştır. 27 özellikli veri kümesine korelasyon tabanlı özellik seçme algoritmasının akış diyagramı Şekil 8.16'de gösterilmiştir.



Şekil 8.16 Bel bölgesi veri kümesinin korelasyon tabanlı özellik seçimi uygulamasını gösterir akış şeması

Burada önce 27 özelliğin her birinin çıkışlar ile aralarındaki korelasyon katsayısı hesaplanmıştır. Daha sonra her bir özelliğin p değeri (olasılık faktörü) hesaplanmıştır. P değeri 0.05'ten küçük olan özellikler önemli özellik olarak belirlenmiş, p değeri 0.05'ten büyük olan özellikler ise veri kümesinden çıkartılmıştır. Çizelge 8.12'de özellik numaraları, bu özelliğin hangi eksenli MR görüntülerinden elde edildiği, özelliğin bölgesi, özelliklerin korelasyon değerleri ve p değerleri görülmektedir. 5, 9, 12, 17 ve 27 no'lu özelliklerin olasılık faktörü (p) 0.05'ten büyük olduğu için bu özellikler veri kümesinden çıkartılmıştır. Toplam 27 olan özellik sayısı 5 özelliğin çıkartılması ile 22'ye düşmüştür.

Çizelge 8.12. 22 özelliğin korelasyon ve p değerleri

Veri setindeki özelliklerin Numarası	Eksen	Kullanılan Özelliklerin Bölgesi	Özellikler ve Çıktılar arasındaki Korelasyon Katsayısı	p değeri (<0.05)
1	Aksiyal	Sağ Lateral Kanal Genişliği	-0.7700	3.30235389947732e-55
2	Aksiyal	Sol Lateral Kanal Genişliği	-0.7499	6.43803308492975e-51
3	Aksiyal	Kanal Sağ Yüksekliği	-0.3413	6.26406763133932e-09
4	Aksiyal	Kanal Dikey Çap	-0.4402	1.83877853716055e-14
5 (veri setinden çıkarıldı)	Aksiyal	Kanal Sol Yüksekliği	-0.0545	0.367611830527971
6	Aksiyal	Kanal Üst Genişliği	-0.3715	1.97805367914588e-10
7	Aksiyal	Kanal Yatay Çapı	-0.5507	3.28818505768879e-23
8	Aksiyal	Kanal Alt Genişliği	-0.4617	6.27312940781035e-16
9 (veri setinden çıkarıldı)	Sagital	Disk yüksekliği	0.1009	0.0948886317372052
10	Sagital	Disk parlaklığı	-0.3044	2.61507027076938e-07
11	Sagital	Disk genişliği	0.3198	5.87230274656312e-08
12 (veri setinden çıkarıldı)	Sagital	AŞM1	0.0718	0.234891941973340
13	Sagital	AŞM2	-0.3354	1.17181958147454e-08
14	Sagital	AŞM3	-0.3969	8.17277355801930e-12
15	Sagital	AŞM4	-0.3926	1.43337357798301e-11
16	Sagital	AŞM5	-0.2727	4.42155472178697e-06
17 (veri setinden çıkarıldı)	Sagital	AŞM6	0.06913	0.253166361714272
18	Sagital	AŞM7	0.4803	2.79387927996235e-17
19	Sagital	AŞM8	0.6651	1.70295172311148e-36
20	Sagital	AŞM9	0.4791	3.42753055699060e-17
21	Sagital	AŞM10	0.5599	4.26887644378205e-24
22	Sagital	AŞM11	0.4277	1.16364372785538e-13
23	Sagital	AŞM12	-0.1608	0.00753775796008991
24	Sagital	AŞM13	-0.5369	6.10812649984648e-22
25	Sagital	AŞM14	-0.6672	8.57610732760090e-37
26	Sagital	AŞM15	-0.6270	1.87094962447309e-31
27 (veri setinden çıkarıldı)	Sagital	AŞM16	-0.0126	0.834185741065315

27'den 22'ye korelasyon tabanlı özellik seçme metodu ile indirilen özellikler çeşitli sınıflama algoritmaları ile sınıflandırılmış ve sonuçlar Çizelge 8.13'de verilmiştir. 10 kat çapraz-geçerlilik testi uygulanarak MLP ile %93.98, DVM ile %94.73, naïve bayes ile %91.72 ve karar ağaçları ile %94.36'lık sınıflama doğruluğu elde edilmiştir. En iyi sınıflama doğruluğunu destek vektör makinaları algoritmasının verdiği görülmüştür.

Çizelge 8.13. 22 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP	DVM	Naïve Bayes	Karar Ağaçları
Özellik Sayısı	22	22	22	22
Sınıflama Doğruluğu (%)	93.98	94.73	91.72	94.36
Hassasiyet(%)	95.37	97.10	92.48	97.10
Seçicilik (%)	91.39	90.32	90.32	89.24
Duyarlılık	0.9537	0.9491	0.9467	0.948
Anma Değeri	0.9537	0.9710	0.9248	0.9710
f-ölçütü	0.9537	0.96	0.9356	0.9572
Kappa değeri	0.9745	0.9738	0.9756	0.9737
Roc Eğrisi Altında Kalan Alan	0.9886	0.9372	0.9753	0.9141
Hesaplama Süresi (saniye)	1.61	0.09	0.03	0.008

Özellik seçimi yapılmış verilerin sınıflama performansı yukarıda anlatılmış. Özellik sayısı azaltılmamış ham verilerin sınıflama performansı ise Çizelge 8.14’de verilmiştir. 27 özellikli verilerin 10 kat çapraz-geçerlilik testi uygulanarak çeşitli sınıflama algoritmaları ile sınıflandırma performansları şu şekildedir: MLP ile %93.45, destek vektör makineleri ile %94.54, naïve bayes ile %92.36, karar ağaçları ile %93.45’dir. En iyi sınıflama doğruluğunu destek vektör makinaları algoritmasının verdiği görülmüştür.

Çizelge 8.14. 27 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP (ANN model)	DVM	Naïve Bayes	Karar Ağaçları
Özellik Sayısı	27	27	27	27
Sınıflama Doğruluğu (%)	93.45	94.54	92.36	93.45
Hassasiyet(%)	95.60	97.25	92.30	96.15
Seçicilik (%)	89.24	89.24	92.47	88.17
Duyarlılık	0.9456	0.9465	0.96	0.9408
Anma Değeri	0.9560	0.9725	0.9230	0.9615
f-ölçütü	0.9508	0.9593	0.9411	0.9510
Kappa değeri	0.9753	0.9745	0.9766	0.9750
ROC Eğrisi Altında Kalan Alan	0.9827	0.9325	0.9726	0.9035
Hesaplama Süresi (saniye)	2.59	0.13	0.05	0.16

Özellik sayısının indirgenmeden önceki yani 27 özellikli veri kümesinde en yüksek sınıflama doğruluğu destek vektör makineleri ile %94.54 olarak bulunmuştur. 22 özellikli veri kümesinde en yüksek sınıflama doğruluğu %94.73 ile yine destek vektör makinaları ile elde edilmiştir. 5 özellikli veri kümesinde ise %96 gibi yüksek bir sınıflama doğruluğu karar ağaçları ile elde edilmiştir. Özellik sayısının indirgenmesi sınıflama doğruluğunu önemli ölçüde arttırdığı görülmüştür.

27, 22 ve 5 özellikli veri kümeleri yapay sinir ağları algoritmalarından radyal tabanlı fonksiyon (RTFA) ağları ve öğrenmeli vektör kuantalama (LVQ) ile sınıflandırılmış ve sonuçlar Çizelge 8.15’de gösterilmektedir. 5 özellik için RTFA ağları ve LVQ ile %95.27 sınıflama doğruluğu elde edilmiştir. 22 özellik için radyal tabanlı fonksiyon ağları %95.48 ve LVQ ile 89.09 sınıflama doğruluğu elde edilmiştir. 27 özellik için RTFA ağları %94.90 ve öğrenmeli vektör kuantalama %88 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama doğruluğu çok küçük bir farkla 22 özellikli veri kümesi için RTFA ile elde edilmiştir. Fakat 5 özellikli radyal tabanlı fonksiyon ağları ve LVQ algoritmaları da %95.27 ile oldukça yüksek bir sınıflama doğruluğu elde edilmiştir.

Çizelge 8.15. 5, 22 ve 27 özellikli veri kümelerinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi					
	RTFA	LVQ	RTFA	LVQ	RTFA	LVQ
Özellik sayısı	5 özellik	5 özellik	22 özellik	22 özellik	27 özellik	27 özellik
Sınıflama Doğruluğu (%)	95.2727	95.2727	95.4872	89.0977	94.9091	88
Hassasiyet (%)	95.6044	97.8022	95.9537	94.7976	94.5054	93.9560
Seçicilik (%)	94.6236	90.3225	94.6236	78.49	95.6989	76.3440
Duyarlılık	0.9720	0.9518	0.9707	0.8913	0.9772	0.8860
Anma Değeri	0.9560	0.9780	0.9595	0.9479	0.9450	0.9395
f-ölçütü	0.9639	0.9647	0.9651	0.9187	0.9608	0.912
Kappa Değeri	0.8952	0.8930	0.9013	0.7535	0.888	0.7239
ROC Eğrisi altında kalan alan	0.977	0.941	0.9777	0.889	0.974	0.852
Hesaplama Zamanı (san.)	0.27	0.01	0.05	0.01	0.06	0.02

Ayrıca 27, 22 ve 5 özellikli veri kümeleri k en yakın komşu algoritması ile sınıflandırılmıştır. Sonuçlar Çizelge 8.16’de verilmiştir. Burada k değeri sırası ile 1, 3, 5, 7 ve 10 olarak her üç veri kümesi içinde denenmiştir. Özellik seçme işlemi yapılmamış veri kümesinde k=1 değeri için en yüksek %94.18’lik sınıflama doğruluğuna ulaşılmıştır. F- skor tabanlı özellik seçim metodu ile özellik sayısı 27’den 5’e indirilen veri kümesinde k=7 değer için %95.27 sınıflama doğruluğu elde edilmiştir. Korelasyon tabanlı özellik seçimi ile özellik sayısı 27’den 22’ye indirilen veri kümesinde k=1 değeri için %94.54 ile en yüksek sınıflama doğruluğu elde edilmiştir.


Tez çalışması için geliştirilen bir diğer veri ağırlıklandırma yöntemi ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemidir. Bu yöntemin çalışma prensibi Bölüm 7.1’de ayrıntılı olarak anlatılmıştır.

Bel bölgesi aksiyal ve sagittal MR görüntülerinden elde edilen 27 hibrit özellik vektörü, ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemine tabi tutulmuştur.

Şekil 8.17’de (a) lineer olarak ayrılamayan iki özellik vektörü görülmektedir. Bu iki özellik vektörüne ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi uygulandığında bu özellik vektörünün lineer olarak ayrılabilir hale geldiği görülmektedir.

Çizelge 8.16. 27 özellikli veri kümesinin 10 kat çapraz-geçerlilik testi ve çeşitli sınıflayıcılar ile sınıflandırma sonuçları

k-NN sınıflayıcısı için k değeri	Sınıflama Doğruluğu	Özellik Sayısı	Kullanılan Metot
k=1	94.18*	27	Özellik seçimi metodu Kullanılmamış.
k=3	92.36	27	
k=5	92.36	27	
k=7	91.63	27	
k=10	92	27	
k=1	93.81	5	F-skor tabanlı özellik seçimi metodu uygulanmış ve özellik sayısı 27’den 5’e indirilmiş.
k=3	94.54	5	
k=5	93.45	5	
k=7	95.27*	5	
k=10	95.27	5	
k=1	94.54*	22	Korelasyon tabanlı özellik seçimi metodu uygulanmış ve özellik sayısı 27’den 22’ye indirilmiş
k=3	93.45	22	
k=5	93.09	22	
k=7	93.09	22	
k=10	92.36	22	
k=3	93.45	22	
k=5	93.09	22	
k=7	93.09	22	
k=10	92.36	22	



Şekil 8.17. İki özellik için (a) doğrusal olarak ayrılamayan ve (b) doğrusal olarak ayrılabilen veriler

Bel bölgesi MR görüntülerinden elde edilen 27 adet hibrit özellik vektörünün k-en yakın komşu algoritması ile ham ve ortalama kayma kümeleme tabanlı ağırlıklandırılmış veri kümeleri sınıflandırıldığında sonuçlar Çizelge 8.17’de verilmiştir. Buna göre 10 kat çapraz-geçerlilik testi uygulanarak ağırlıklandırılmamış ham veri kümesi için %94.18 sınıflama doğruluğu elde edilirken ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi uygulandığında %98.63 sınıflama doğruluğuna ulaşılmıştır. Veri kümeleri %50 test ve %50 eğitim kümesi olarak ayrıldığında ham verilerin k-en yakın komşu algoritması uygulandığında %91.97, ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi uygulandığında %100 sınıflama doğruluğu elde edilmiştir.

Çizelge 8.17. Ham ve OKKTVA ile ağırlıklandırılmış verilerin k-NN ile sınıflama sonuçları

Veri Bölme Yöntemi	10 kat çapraz-geçerlilik testi		50-50% Eğitim ve Test Olarak Ayrılmış	
Performans Ölçütleri	Ham Veri Kümesi	Ağırlıklı veri kümesi	Ham Veri Kümesi	Ağırlıklı veri kümesi
Sınıflama Doğruluğu (%)	94.18	99.6350	91.97	100
Hassasiyet(%)	96.70	99.4475	93.18	100
Seçicilik (%)	90.32	100	89.79	100
Duyarlılık	0.9513	1	0.9425	1
Anma Değeri	0.9670	0.9944	0.9318	1
f-ölçütü	0.9591	0.9972	0.9371	1
ROC Eğrisi Altında Kalan Alan	0.937	0.996	0.915	1
Kappa değeri	0.8772	0.9919	0.826	1

Bel bölgesi MR görüntülerinden elde edilen 27 adet hibrit özellik vektörünün radyal tabanlı fonksiyon sinir ağırları algoritması ile ham ve ortalama kayma kümeleme tabanlı ağırlıklandırılmış veri kümeleri sınıflandırıldığında sonuçlar Çizelge 8.18’de verilmiştir. Buna göre 10 kat çapraz-geçerlilik testi uygulanarak ağırlıklandırılmamış ham veri kümesi için %93.45 sınıflama doğruluğu elde edilirken Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma yöntemi uygulandığında %99.63 sınıflama doğruluğuna ulaşılmıştır. Veri kümeleri %50 test ve %50 eğitim kümesi olarak ayrıldığında ham verilerin radyal tabanlı fonksiyon sinir ağırları algoritması yakın komşu algoritması uygulandığında %92.70, Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma yöntemi uygulanmış ağırlıklandırılmış veri kümelerine uygulandığında %100 sınıflama doğruluğu elde edilmiştir.

Çizelge 8.18. Ham ve OKKTVA ile ağırlıklandırılmış verilerin RTFA ile sınıflama sonuçları

Veri Bölme Yöntemi	10 kat çapraz-geçerlilik testi		50-50% Eğitim ve Test Olarak Ayrılmış	
	Ham Veri Kümesi	Ağırlıklı veri kümesi	Ham Veri Kümesi	Ağırlıklı veri kümesi
Performans Ölçütleri				
Sınıflama Doğruluğu (%)	93.45	99.63	92.70	100
Hassasiyet(%)	93.40	99.44	89.77	100
Seçicilik (%)	93.54	100	97.95	100
Duyarlılık	0.9659	1	0.9875	1
Anma Değeri	0.9340	0.994	0.8977	1
f-ölçütü	0.9497	0.997	0.9404	1
ROC Eğrisi Altında Kalan Alan	0.967	0.996	0.948	1
Kappa değeri	0.856	0.991	0.8467	1

Son olarak tez çalışmasında kullanılmak üzere Selçuk Üniversitesi Tıp Fakültesi Radyoloji Bölümünden elde edilen veriler 3 sınıflı (spinal stenoz, dejeneratif disk ve normal) olarak MLP, DVM, naive bayes ve karar ağaçları algoritmaları ile analiz edilmiştir. 10 kat çapraz-geçerlilik testine tabi tutulan verilerden elde edilen sonuçlar Çizelge 8.19’da verilmiştir. Buna göre: çok katmanlı algılayıcı ile yapılan sınıflandırmada %81.45, destek vektör makinesi ile yapılan sınıflandırmada %81.45, naive bayes sınıflayıcısı ile yapılan sınıflandırmada %78.90, Karar ağaçları (ID3 algoritması) ile yapılan sınıflandırmada %89.09 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama başarısı %89.09 ile karar ağaçları algoritmasında elde edilmiştir.

Çizelge 8.19. 3 sınıflı ham verilerin MLP, DVM, naive bayes ve karar ağaçları ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP	DVM	Naïve Bayes	Karar Ağaçları
Sınıf Sayısı	3	3	3	3
Sınıflama Doğruluğu (%)	81.45	81.45	78.90	89.09
Hassasiyet (%)	80.18	81.56	77.67	86.95
Seçicilik (%)	86.20	81.03	83.33	95.58
Duyarlılık	0.95	0.94	0.94	0.98
Anma Değeri	0.80	0.81	0.77	0.86
f-ölçütü	0.87	0.87	0.85	0.92
Kappa Değeri	0.63	0.61	0.58	0.78
ROC Eğrisi Altında Kalan Alan	0.94	0.877	0.911	0.933
Hesaplama Süresi (saniye)	2.7	0.18	0.05	0.15

Yukarıda bahsedilen 3 sınıflı ham veriler, tezin ilgili kısmında anlatılan bulanık c-ortalamlar yöntemi ile ağırlıklandırılmış ve yine MLP, DVM, naive bayes ve karar ağaçları algoritmaları ile analiz edilmiştir. Elde edilen analiz sonuçları Çizelge 8.20’de

verilmiştir. Buna göre: çok katmanlı algılayıcı ile yapılan sınıflandırmada %94.90, destek vektör makinesi ile yapılan sınıflandırmada %90.90, naive bayes sınıflayıcısı ile yapılan sınıflandırmada %92.72, karar ağaçları (C4.5 algoritması) ile yapılan sınıflandırmada %97.09 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama başarısı %97.09 ile yine karar ağaçları algoritmasında elde edilmiştir. Ayrıca ağırlıklandırılan verilerin sınıflama başarısının bariz bir şekilde arttığı görülmüştür.

Çizelge 8.20. 3 sınıflı ikili bulanık c-ortalama ile ağırlıklandırılan verilerin MLP, DVM, naive bayes ve karar ağaçları ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP	DVM	Naïve Bayes	Karar Ağaçları
Sınıf Sayısı	3	3	3	3
Sınıflama Doğruluğu (%)	94.90	90.90	92.72	97.09
Hassasiyet (%)	92.85	87.92	90.09	96.29
Seçicilik (%)	100	100	100	98.83
Duyarlılık	1	1	1	0.99
Anma Değeri	0.92	0.87	0.90	0.96
f-ölçütü	0.96	0.93	0.94	0.97
Kappa Değeri	0.89	0.81	0.85	0.94
ROC Eğrisi Altında Kalan Alan	0.991	0.95	0.989	0.98
Hesaplama Süresi (saniye)	1.08	0.06	0.02	0.02

Son olarak 3 sınıflı ham veriler, tezin ilgili kısmında anlatılan ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi ile ağırlıklandırılmış ve yine MLP, DVM, naive bayes ve karar ağaçları algoritmaları ile analiz edilmiştir. Elde edilen analiz sonuçları Çizelge 8.21’de verilmiştir. Buna göre: Çok katmanlı algılayıcı ile yapılan sınıflandırmada %100, destek vektör makinesi ile yapılan sınıflandırmada %100, naive bayes sınıflayıcısı ile yapılan sınıflandırmada %99.27, karar ağaçları (ID3 algoritması) ile yapılan sınıflandırmada %99.27 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama başarısı %100 ile MLP ve DVM algoritmalarında elde edilmiştir. Ayrıca ağırlıklandırılan verilerin sınıflama başarısının çok fazla bir şekilde arttığı görülmüştür. Ortalama kayma kümeleme tabanlı veri ağırlıklandırma yöntemi ile ağırlıklandırılmış verilerin bulanık c-ortalama ile ağırlıklandırılan verilerden daha iyi sınıflama sonucu verdiği açık bir şekilde görülmüştür.

Çizelge 8.21. 3 sınıflı OKKTVA ile ağırlıklandırılan verilerin MLP, DVM, naïve bayes ve Karar ağaçları ile sınıflandırma sonuçları

Performans Ölçütleri	10 kat çapraz-geçerlilik testi			
	MLP	DVM	Naïve Bayes	Karar Ağaçları
Sınıf Sayısı	3	3	3	3
Sınıflama Doğruluğu (%)	100	100	99.27	99.27
Hassasiyet (%)	100	100	98.91	99.45
Seçicilik (%)	100	100	100	98.91
Duyarlılık	1	1	1	0.99
Anma Değeri	1	1	0.98	0.99
f-ölçütü	1	1	0.99	0.99
Kappa Değeri	1	1	0.98	0.98
ROC Eğrisi Altında Kalan Alan	1	1	0.993	0.992
Hesaplama Süresi (saniye)	2.36	0.14	0.05	0.06

9. SONUÇLAR VE ÖNERİLER

Bel bölgesi rahatsızlıklarının en belirgin ortak belirtisi bel ağrısıdır. Baş ağrısından sonra tüm dünyada en sık görülen ağrı çeşidi bel ağrısıdır. Bel rahatsızlıklarının doğru ve hızlı teşhisi hastaların yaşam kalitesinin artırılması, iş gücü kayıplarının azaltılması gibi faydalı sonuçlar doğuracağı açıktır. Bu rahatsızlıkların teşhisinde radyologlar çoğunlukla hem aksiyal hem de sagittal görüntüleri inceleyerek karar vermektedirler. Ancak hastanelerimizde az sayıda radyoloğun çok sayıda hastaya ait MR görüntülerine bakarak rapor hazırlaması sürecinde yanlış teşhis konulması gibi problemler ortaya çıkmaktadır. Bu tür durumları en aza indirmek için günümüz tıp dünyasında uzmanlara veya radyologlara yardımcı bilgisayar destekli teşhis (BDT) sistemleri kullanılmaktadır.

Bu tez çalışmasında, aksiyal ve sagittal MR görüntüleri üzerinden bel bölgesi rahatsızlıklarının teşhisinde doktor, radyolog ve uzmanlara yardımcı olabilecek bir bilgisayar destekli teşhis sistemi sunulmuştur. Çalışmada hem aksiyal hem de sagittal görüntülerin aynı anda kullanılması ile daha yüksek başarı oranı ile bir teşhis konulmasına yardımcı bir BDT ortaya çıkması sağlanmıştır.

Selçuk Üniversitesi Tıp Fakültesi Hastanesi Radyoloji Bölümü'nden alınan 55 hastaya ait aksiyal ve sagittal MR görüntüsü bu çalışmada kullanılmıştır. Bununla birlikte Uluslararası UCI veritabanından alınan Vertebral Column veri seti (310 hastadan alınan özellikler) de çalışmamızda kullanılan bir diğer veri kümesidir.

Çalışmanın ilk aşamasında 55 hastaya ait aksiyal ve sagittal MR görüntülerine ön işlem uygulanmıştır. Bu aşamada görüntülerin iyileştirilmesi anlamında histogram eşitleme ve medyan filtreleme kullanılmıştır. Ardından, görüntülerdeki gereksiz bölgelerin atılması amacıyla; aksiyal görüntülerde spinal kanal bölgesini içeren kısım ile sagittal görüntülerde her bir disk aralığını içeren kısımlar manuel olarak kesilmiştir. Bu aşamada otomatik olarak segmentasyon yapılması için gerekli teknikler uygulanmış, ancak gerek hastaların fizyolojik yapı farklılıkları gerekse radyolojide görüntülerin alınması sırasında bir standart çekim uygulanmaması sebebiyle başarılı sonuç elde edilememiştir.

Ön işlem aşamasında kesilerek elde edilen spinal kanal ve disk bölgesi görüntüler üzerinde özellik çıkarımı işlemi gerçekleştirilmiştir. Bu aşamada aksiyal görüntülerden elde edilen spinal kanal bölgesi üzerinde 8 adet (6 adet spinal kanal

içerisinde yatay ve dikey genişlik ile 2 adet sağ ve sol lateral kanal genişlik ölçümleri) ölçüm yapılmıştır. Sagittal MR görüntülerinden elde edilen disk bölgesine aktif şekil model tekniği yardımıyla 16 adet veri içeren küme elde edilmiştir. Bu veri kümesine ayrıca ilgili diskin genişliği, yüksekliği ve parlaklık değeri de eklenerek toplamda 19 adet veri içeren küme elde edilmiştir.

Sagittal ve aksiyal MR görüntülerinden elde edilen 27 (8 aksiyal + 19 sagittal) özellik içeren hibrit özellik vektörü bir sonraki aşamaya aktarılmıştır. Bu aşamada, hibrit özellik vektörüne özellik seçimi algoritmalarından f-skor tabanlı özellik seçimi (FSTÖS) ve korelasyon tabanlı özellik seçimi (KTÖS) yöntemleri uygulanmıştır. Bunun sonucunda FSTÖS uygulanarak 5 adet veri içeren küme, KTÖS uygulanarak 22 adet veri içeren veri kümesi elde edilmiştir. Özellik sayısı indirilen bu veri kümelerinin bu tez çalışmasında geliştirilen ortalama kayma kümeleme tabanlı veri ağırlıklandırma (OKKTVA) yöntemi ile veri ağırlıklandırma işlemi uygulanmıştır. Ağırlıklandırılan bu veri kümeleri bir sonraki aşamada sınıflandırma işlemine tabi tutulmuşlardır.

Sınıflandırma (teşhis) aşamasında hem indirgenmemiş (27 adet özellik içeren) hem de özellik sayısı azaltılan veri kümelerine (5 adet ve 22 adet özellik içeren) çok katmanlı algılayıcı (MLP), destek vektör makinesi (DVM), Naive Bayes ve karar ağaçları yöntemleri uygulanmıştır. Bununla birlikte yine aynı özellik vektörlerine radyal tabanlı fonksiyon ağları (RTFA) ve öğrenmeli vektör kuantalama (LVQ) sınıflayıcılar ile sınıflandırılmıştır.

Uluslararası UCI Makine Öğrenmesi veritabanından alınan veri kümesine ise önce ikili bulanık c-ortalamları yöntemi ile veri ağırlıklandırma gerçekleştirilmiştir. Bu işlemin sonucunda elde edilen ağırlıklandırılmış veri kümesi k-en yakın komşuluk (K-NN), MLP, Naive Bayes ve DVM yöntemleri kullanılarak sınıflandırılmıştır.

55 hastadan alınan aksiyal ve sagittal MR görüntülerinden elde edilen özellik vektörlerinin 2 sınıf için (Normal / Anormal) sınıflama doğruluğuna göre alınan sonuçlara göre indirgenmemiş veri (27 adet özellik) için en başarılı sonuç (% 94.90) RTFA ile elde edilmiştir. 22 adet özellik vektörüne indirgenmiş veri kümesi için en başarılı sonuç (% 95.48) RTFA ile elde edilmiştir. 5 adet özellik vektörüne indirgenmiş veri kümesi için en başarılı sonuç (% 96.00) karar ağaçları yöntemi ile elde edilmiştir.

55 hastadan alınan aksiyal ve sagittal MR görüntülerinden elde edilen indirgenmemiş özellik vektörünün (27 adet özellik) 3 sınıf için (Normal / Spinal Stenoz / Dejeneratif Disk) sınıflandırılmıştır. Elde edilen analiz sonuçlarına göre; çok katmanlı algılayıcı ile yapılan sınıflandırmada %94.90, destek vektör makinesi ile yapılan

sınıflandırmada %90.90, naive bayes sınıflayıcısı ile yapılan sınıflandırmada %92.72, karar ağaçları (C4.5 algoritması) ile yapılan sınıflandırmada %97.09 sınıflama doğruluğu elde edilmiştir. En yüksek sınıflama başarısı %97.09 ile yine karar ağaçları algoritmasında elde edilmiştir.

Hem 2 sınıf hem de 3 sınıflı indirgenmemiş veri kümesine (27 adet özellik) uygulanan ortalama kayma kümeleme tabanlı veri ağırlıklandırma (OKKTVA) sonucu elde edilen özellik vektörünü sınıflandırdığımızda sınıflandırma başarısı 2 sınıfa göre RTFA ve LVQ için %99.63, 3 sınıfa göre MLP ve DVM için %100 bulunmuştur. Dolayısıyla veri ağırlıklandırma yönteminin diğerlerine göre çok başarılı sonuç verdiği gözlemlenmiştir. OKKTVA yöntemi bu tez çalışmasında geliştirilen yeni bir yöntem olarak bilime katkı sağlamıştır. Literatüre yeni katkı anlamında geliştirilen bu yöntemin başka veri kümelerine de başarı ile uygulanabileceği öngörülmektedir.

Tez çalışması için geliştirilen bu sistem çevrimdışı (offline) çalışmaktadır. İlerleyen zamanlarda yapılacak çalışmalarda hastalardan elde edilecek ölçüm sonuçları çevrimiçi (online) olarak analiz edilmek suretiyle daha hızlı karar verme süreci yaşanabilecektir. Ayrıca daha farklı özellik seçim ve veri ağırlıklandırma teknikleri kullanılarak sınıflama başarısı arttırılabilir.

Sonuç olarak, insanların bel rahatsızlıklarına yakalanma sıklığı, bu rahatsızlığa yakalanan kişilerdeki yaşam kalitesinin düşmesi, iş gücü kayıpları, erken emeklilik ve tedavi maliyetlerinin büyüklüğü gibi parametreler düşünüldüğünde tez çalışmasında geliştirilen BDT sisteminin önemi ortaya çıkmaktadır.

KAYNAKLAR

- Abe, S., 2005, Support Vector Machine for Pattern Classification, *Springer*, London.
- Abdrabou, E., 2012, A hybrid intelligent classifier for the diagnosis of pathology on the vertebral colum, *Artif. Intell. Methods Tech Bus. Eng. Appl*, pp. 297–310.
- Afrinc, 2015, LVQ sinir ağı, <http://www.afrinc.com/products/fire-detection/>, [Ziyaret Tarihi: Mart 2015].
- Agrawal, R., Imielinski, T., and Swami, A. N., 1993, Mining association rules between sets of items in large databases, *In Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, (Editörler P. Buneman and S. Jajodia), Washington, D.C., 207216.
- Alapan, Y., 2012, Lomber omurgada ani dönme merkezi ve değişiminin biyomekanik etkileri, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2-3.
- Al-Helo, S., Alomari, R.S., Chaudhary, V. and Al-Zoubi, M.B., 2011, Segmentation of lumbar vertebrae from clinical CT using active shape models and GVF-snake, *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, DOI: 10.1109/IEMBS.2011.6091981 Publication Year: 2011 , Page(s): 8033 – 8036
- Allahverdi, N. 2002. Uzman Sistemler Bir Yapay Zeka Uygulaması, *Atlas Yayın Dağıtım*, İstanbul.
- Alpaydin, E., Introduction to Machine Learning, *MIT Press*, 2004.
- Alomari, R.J., Corso, J. J., Chaudhary, V., Dhillon G., 2010, Automatic diagnosis of lumbar disc herniation with shape and appearance features from MRI, *SPIE Medical Imaging*, San Diego, California, USA.
- Akbulut, S., 2006, Veri madenciliği teknikleri ile bir kozmetik markanın ayrılan müşterianalizi ve müşteri segmentasyonu, Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- Akdemir, B., Polat, K., Güneş, S., 2007, Prediction of e.coli promoter gene sequences using a hybrid combination based on feature selection, fuzzy weighted pre-processing, and decision tree classifier, *KES* (1) 2007: 125-131.
- Anonim, 2012, Omurga stres kırığı, www.omurgasagligimerkezi.com/omurga-stres-kirigi [Ziyaret Tarihi: Aralık 2014].
- Anonim, 2013, Bel Rahatsızlıkları <http://www.isom.com.tr/bel-rahatsizliklari> [Ziyaret Tarihi: Aralık 2014].

- Anonim, 2014, Radyoloji, <http://biyomedikalmuhendislik.com/wp-content/uploads/2014/10/rontgen.pdf>, [Ziyaret Tarihi: Aralık 2014].
- Ansari, S., Sajjad, F., ul-Qayyum, Z., Naveed, N., 2013, Diagnosis of vertebral column disorders using machine learning classifiers, in: *International Conference on Information Science and Applications (ICISA)*, pp. 1–6.
- Apinetree, 2015, K-en yakın komşu algoritması, <http://apinetree.blog.51cto.com/714152/1600872>, [Ziyaret Tarihi: Mart, 2015].
- Asyalı F. Z., 2006, Manyetik Rezonans Görüntüleme, Yüksek Lisans Tezi, *Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir.
- Aşık, İ., 2014, Faset Eklem Sendromu, <http://www.ibrahimasik.com.tr/tr/tag/agri-merkezi/page/2/> [Ziyaret Tarihi: Aralık 2014].
- Atılğan, E., 2011, Karayollarında meydana gelen trafik kazalarının karar ağaçları ve birliktelik analizi ile incelenmesi, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- Aydın, F., 2011, Kalp ritim bozukluğu olan hastaların tedavi süreçlerini desteklemek amaçlı makine öğrenmesine dayalı bir sistemin geliştirilmesi, Yüksek Lisans, *Trakya Üniversitesi Fen Bilimleri Enstitüsü*, Edirne.
- Aydın, Ü., 2014, Lomber bölge, <http://umitaydin.net/?q=node/81> [Ziyaret Tarihi: Aralık 2014].
- Bekci H. B., 2010, Lomber spinal stenoz tanısı olan bireylerde dengenin değerlendirilmesi, Tıpta Uzmanlık Tezi, *Gaziosmanpaşa Üniversitesi Tıp Fakültesi Fiziksel Tıp ve Rehabilitasyon Anabilim Dalı*, Tokat.
- Bezdek J. C., 1981, Pattern recognition with fuzzy objective function algorithms, *Plenum Press*, New York.
- Birtane, S., 2013, Omurilik şekil bozukluklarının sınıflandırılmasına yönelik yazılım geliştirme, Yüksek Lisans, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 28-38.
- Bishop, C. M., 1995, Neural networks for pattern recognition, *Oxford University Press*.
- Borenstein, D.G., 2000, Rheumatology, *Mosby*, Vol.1, Section 4, 3.1-26 p.
- Boztok Özgermen, 2014, Köpeklerde akciğer hastalıklarının tanısında bilgisayarlı tomografi ve torasik radyografibulgularının karşılaştırılması, Doktora Tezi, *Ankara Üniversitesi Sağlık Bilimleri Enstitüsü*, Ankara.
- Boztoprak H. ve Özbay Y., 2012, Görüntü işlemede aktif kontur ve ysa kullanarak atık sularda protozcentikoa belirlenmesi, *ELECO 2012*, s.567-571.

- Busuttil, S., 2003, Support vector machines, *In Proceedings of the Computer Science Annual Research Workshop*, Villa Bighi, Kalkara, University of Malta.
- Bülbül, Ö., 2012, Lomber spinal stenoz hastalarında posterior Dekompresyon ve posterior enstrümantasyonun klinik, oswestry maluliyet skalası, elektrofizyolojik ve radyolojik sonuçlarının değerlendirilmesi, Tıpta Uzmanlık Tezi, *Ufuk Üniversitesi Tıp Fakültesi Ortopedi ve Travmatoloji Anabilim Dalı*, Ankara, 3-4.
- Büyükışıklar, A., 2014, Karar ağaçları sınıflandırma algoritması ile toprak özgül direnci tespitinde jeolojik veri kullanımı, Yüksek Lisans Tezi, *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü*, Bilecik.
- Cenaero, 2015, RBF yapay sinir ağları, <http://www.cenaero.be/Page.asp?docid=27097>, [Ziyaret Tarihi: 2014].
- Chen Y. W., and Lin C. J., 2003, Combining SVMs with Various Feature Selection Strategies, *NIPS 2003 Feature Selection Challenge*, 1-10.
- Civalek, Ö., 1997, The design of structures under earthquake effects by using neuro-fuzzy method, *Fourth National Earthquake Engineering Conferences*, 17-19 September, Ankara, s.431-438.
- Comaniciu D., Ramesh V., Meer P., 2003, Kernel-based object tracking, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 25, pp. 564–577.
- Comaniciu, D. ve Meer P., 2002, Mean shift: a robust approach towards feature space analysis, *IEEE Transaction on Pattern Analysis and Machine Intelligence* Vol.24,No:5, p.603-608.
- Cortes, C., Vapnik, V., 1995, Support vector networks, *Machine Learning*, 20,1-25.
- Çalışkan, S. K., 2008, K'KNN: Kümeleme ve K en yakın komşu yöntemi ile ağlarda nüfuz tespiti, Yüksek Lisans Tezi, *Gebze İleri teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü*, Gebze.
- Çakır, H., 2009, Bel fıtığı olan hastalarda prolidaz aktivitesinin belirlenmesi ve oksidatif stres indeksi ile karşılaştırılması, Tıpta Uzmanlık Tezi, *Harran Üniversitesi Tıp Fakültesi Tıbbi Biyokimya Anabilim Dalı*, Şanlıurfa.
- Çayıroğlu, İ., 2010, <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf> [Ziyaret Tarihi: Kasım 2014].
- Çelik E., 2011, Görüntü işlemeye dayalı avuç içi izinin yapay sinir ağı ile tanınması, Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Çentik, G., 2013, Makine öğrenmesi yöntemleri ile polisomnografik verilere uygulanması, Doktora Tezi, *Trakya Üniversitesi Fen Bilimleri Enstitüsü*, Edirne.

- Çetinkaya C., 2011, Retina görüntülerinde radyal tabanlı fonksiyon sinir ağları ile damar tipik noktalarının tespit edilmesi, Yüksek Lisans Tezi, *Ege Üniversitesi Fen Bilimleri Enstitüsü*, İzmir.
- Çetinkaya, F. B., 2005, Lomber disk hernili hastalarda egzersiz ve elektrik stimülasyonunun etkinliği, Uzmanlık Tezi, *70. Yıl İstanbul Fizik Tedavi ve Rehabilitasyon Eğitim ve Araştırma Hastanesi*, İstanbul.
- Çevikcan, B., 2007, Bel fıtığı hastalığı bulunan bireylerin bel ve karın kası fonksiyonlarının elektromyografik analizi, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri.
- Çomak E., 2004, Destek vektör makineleri çoklu sınıf problemleri için çözüm önerileri, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Çöl, H. A., 2011, Lomber spinal stenozda lomber stabilizasyon egzersizlerinin etkinliği, Tıpta Uzmanlık Tezi, *Trakya Üniversitesi Tıp Fakültesi Fizik Tedavi ve Rehabilitasyon Anabilim Dalı*, Edirne.
- Çölkesen, İ., ve Kavzoğlu, T., 2011, Örnek tabanlı k-star algoritması ile uzaktan algılanmış görüntülerin sınıflandırılması, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VI. Sempozyumu (TUFUAB2011)*, Antalya.
- Däschlein, R., Waschulzik, T., Brauer, W., et al., 1994, Segmentation of computertomographies with neural networks based on local features. in ifeachor, e., & rosen, k. (eds.), *International Conference on Neural Networks and Expert Systems in Medicine and Healthcare*, pp. 240-247.
- Demetgül, M., 2008, Pnömatik sistemde gerçek zamanlı LVQ yapay sinir ağı algoritması ile arıza tespiti, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, cilt:14, sayı:1, ss. 83-90.
- Derpanis, K.G.,2005, Mean shift clustering, http://www.cse.yorku.ca/kosta/CompVis_Notes/mean_shift.pdf
- Doğan, Ö., 2013, Lomber stenozlu hastalarda faset eklem enjeksiyonun lomber aks ve klinik bulgular üzerine etkisi, Tıpta Uzmanlık Tezi, *Akdeniz Üniversitesi Tıp Fakültesi Beyin ve Sinir Cerrahisi Anabilim Dalı*, Antalya.
- Domingos P., Pazzani M., 1997, On the optimality of the simple bayesian classifier under zero-one loss, *Machine Learning*, 29, pp.103-130.
- Dönmez, G. M., 2011, Bel ağrısı sorunlarında lomber bölge egzersizlerinin eklem hareket açıklığı ve ağrı durumuna etkisi, Yüksek Lisans Tezi, *Marmara Üniversitesi Sağlık Bilimleri Enstitüsü*, İstanbul.
- Dunn J.C., 1973, A fuzzy relative of the ISODATA process and Its use in detecting compact well-separated lusters, *Journal of Cybernetics* , vol.3: pp.32-57.

- Durduran, S.S., 2010, A decision making system to automatic recognize of traffic accidents on the basis of a GIS platform, *Expert Systems with Applications*, 37(12), 2010, 7729-7736.
- Ekşi, Z., 2012, Yapay sinir ağları ile kemik kırıklarının görüntü işleme tabanlı tespiti, Yüksek Lisans Tezi, *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü*, Sakarya
- Elbistanlı, G., 2007, HVAC sisteminin mlp tipi yapay sinir ağları (ysa) kullanarak denetlenmesi, Yüksek Lisans Tezi, *Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü*, Kahramanmaraş.
- Elmas, Ç., 2007, Yapay Zeka Uygulamaları, *Seçkin Yayıncılık*, Ankara.
- Emir Ş., 2013, Yapay sinir ağları ve destek vektör makineleri yöntemlerinin sınıflandırma performanslarının karşılaştırılması: borsa endeks yönünün tahmini üzerine bir uygulama, Doktora Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul.
- Er, O., ve Temurtas F., 2005, İnsan yüzü tanıma, *Electronic Letters on Science & Engineering*, 1(2).
- Erastö, P., 2001, Support vector machines-backgrounds and practice, Academic Dissertation for The Degree of Licentiate of Philosophy. *Rolf Nevanlinna Institute*, Helsinki.
- Ercan, S., 2011, Destek vektör makineleri kullanılarak patent değerlendirme, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Erdem L. O., Erdem C. Z., Gündoğdu S., Çağavi F., Kalaycı M., Açıkgöz B., 2004, Lomber disk hastalığında üç boyutlu MR myelografinin yeri, *Tanısal ve Girişimsel Radyoloji Dergisi*, 10:189-195.
- Erdoğan E., 2009, Yapay sinir ağları kullanılarak beyin hastalıklarının görüntülerinden tespiti, Yüksek Lisans Tezi, *Fatih Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul,
- Ertan, A. F., 2002, BT rehberliğinde elektronik navigasyon sistemi ile yapılan diskografi sonrası olguların düşük doz izotropik, yüksek rezolüsyonlu multi-slice BT ile değerlendirilmesi, Tıpta Uzmanlık Tezi, *Gazi Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim dalı*, Ankara.
- Fanntool, 2015, Yapay sinir ağının yapısı, <http://fanntool.blogspot.com.tr/p/ysa-nedir.html>, [Ziyaret Tarihi: Eylül 2014].
- Felsefe, 2015, Biyolojik sinir hücresi, http://www.felsefe.gen.tr/psikoloji/psikolojik_ve_biyolojik_surecler.asp, [Ziyaret Tarihi: Aralık 2014].
- Fukunaga K., Hostetler L. D., 1975, The estimation of the gradient of a density function with applications in pattern recognition, *IEEE Trans. Inf. Theory* 21, pp.32-40.

- Gim, 2015, ROC eğrisi, <http://gim.unmc.edu/dxtests/roc3.htm>, [Ziyaret Tarihi: Mart 2015].
- Gonzales, C. ve Woods, R. E., 2002, Digital Image Processing, *Prentice Hall*, New Jersey.
- Gsmmedicalcenter, 2014, Diskogram örneği, <http://gsmedicalcenter.org/services/pain-management/minimally-invasive-procedures/discography/>, [Ziyaret Tarihi: Eylül 2014].
- Gözel, A., 2001, Bulanık K-en yakın komşuluk tabanlı bulanık ilişki matrisi ile EMG işaretlerinin sınıflanması, Yüksek Lisans, *Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü*, Gebze.
- Gülce A. C., 2010, Veri madenciliğinde apriori algoritması ve apriori algorıtmmasının farklı veri kümelerinde uygulanması, Yüksek Lisans Tezi, *Trakya Üniversitesi Fen Bilimleri Enstitüsü*, Edirne.
- Hacıbeyoğlu, M., 2012, Bilgi sistemlerinde fark fonksiyonu tabanlı özellik seçme yönteminin geliştirilmesi, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Hacıfendioğlu, Ş., 2012, Makine öğrenmesi yöntemleri ile glokom hastalığının teşhisi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 35-50.
- Hall, L., Bensaid, A., Clarke, L., Velthuizen, R., Silbiger, M., & Bezdek J., 1992, A comparison of neural network and fuzzy clustering techniques in segmenting magnetic resonance images of the brain, *IEEE Transactions on Neural Networks*, Vol. 3(5), pp. 672—682.
- Haykin, S., 1994, Neural networks, *A comprehensive foundation*. Macmillan, New York, NY.
- Homepages, 2014, Histogram eşitleme, http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/OWENS/LECT5/node3.html, [Ziyaret Tarihi: Ekim 2014].
- Houston, A., Kemp, P., Macleod, M., Norsworthy, J., et al., 1994, Analysis of a nuclear medicine database for colorectal cancer using expert system rule induction and neural networks. in ifeachor, e., & rosen, k. (eds.), *International Conference on Neural Networks and Expert Systems in Medicine and Healthcare*, pp. 303-309.
- Höppner, F., Klawonn, F., Kruse, R., and Runkler, T., 2000, Fuzzy cluster analysis, *John Wiley&Sons, Chichester*.
- Işık M., ve Çamurcu A. Y., 2007, K-means, k-medoids ve bulanık c-means algoritmalarının uygulamalı olarak performanslarının tespiti, *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, Yıl: 6 Sayı:11, s.31-45.

- İstanbul, M., 2013, Yapay sinir ağları ve destek vektör makineleri ile kemik erimesinin teşhisi, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul,
- Kabalıcı, A., 2013, Çok katmanlı algılayıcı, Jeoloji mühendisliği i a.b.d. esnek hesaplama yöntemleri-I dersi ders notları, Nevşehir.
- Kakıcı, A., 2009, <http://ahmetkakici.github.io/yazilim/yapay-sinir-aglarina-giris/> [Ziyaret Tarihi: Kasım 2014].
- Karaboğa, D., 2011, Yapay Zeka Optimizasyon Algoritmaları, *Nobel Yayın Dağıtım*, Ankara.
- Karakas, M., Duru, H., Tipi, V., et al., 1994, A system for an automated classification of blood cells from microscope images: cell v. 1.0. in ifeachor, e., & rosen, k. (eds.), *International Conference on Neural Networks and Expert Systems in Medicine and Healthcare*, pp. 248-256.
- Kavzaoğlu, T., ve Çölkesen, İ., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, Sayı:144, s.73-82.
- Kayar, F. A., 2011, Posterior reversibl ensefalopati sendromu radyolojik görüntüleme bulguları, Tıpta Uzmanlık Tezi, *Dicle Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı*, Diyarbakır.
- Kazdal, S., 2013, Beyin tümörlerinin ileri görüntü işleme ve örüntü tanıma teknikleri kullanılarak bilgisayar Destekli tespiti, Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Kızılkaya, O., 2013, LDL kolesterolün yapay sinir ağları ile tahmini, Yüksek Lisans Tezi, *İnönü Üniversitesi Sosyal Bilimler Enstitüsü*, Malatya.
- Kimyonok, 2003, An Application of decision trees constructed with simulated annealing variants to prostate cancer detection, (Tavlama benzetimi yöntemi varyantlarıyla oluşturulmuş karar ağaçlarının prostat kanser tanısına uygulanması), *Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Koçer H. E., 2007, İris deseninin yapay zeka yöntemleri ile tanınması, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- Korkmaz N., 2008, Omurga şekil bozukluğu analiz ve teşhisine yönelik yazılım geliştirme, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Kul, S., 2008, Diagnosis of lumbar disc hernia from images using artificial neural network, Yüksek Lisans Tezi, *Fatih Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 24-27.
- Mattos, C.L.C., Barreto, G.A., 2011, ARTIE and MUSCLE models: building ensemble classifiers from fuzzy ART and SOM networks, *Neural Comput. Appl.* pp.1–13.

- Medicastore, 2014, Myelografi uygulanmış hasta görüntüsü, <http://medicastore.com/penyakit/3359/Myelography.html>, [Ziyaret Tarihi: Eylül 2014].
- Megep, 2012, Hareket sistemi modülü, *Milli Eğitim Bakanlığı*, modül no: 720S00027 Ankara.
- Mehmetcuka, 2014, Omurga yapısı, <http://mehmetcuka.com/haber/omurga-sistemi-nasil-calisir-omurgayi-olusturan-kisimler-nelerdir/> [Ziyaret Tarihi: Eylül 2014].
- Michopoulou, S., 2011, Image Analysis for the diagnosis of MR images of the lumbar spine, PhD Thesis, *University College London Department of Medical Physics and Bioengineering*, London.
- Miller, A., 1993, the application of neural networks to imaging and signal processing in astronomy and medicine, Ph.D. Thesis, University of Southampton.
- Moertini, V. S., 2002, Introduction to five clustering algorithms, *Integral*, 7, 2.
- National Institute of Neurological Disorders and Stroke (NINDS), 2014, Low back pain fact, NINDS Publication, (<http://www.ninds.nih.gov/disorders/backpain/>).
- Neto A. R.R., Barreto, G.A., 2009, On the application of ensembles of classifiers to the diagnosis of pathologies of the vertebral column: a comparative analysis, *IEEE Trans. Latin Am.*, 7 (4), 487–496.
- Neto A.R.R., Sousa, R., Barreto, G.A, Cardoso, J.S., 2011, Diagnostic of pathology on the vertebral column with embedded reject option, in: Jordi Vitrià, João Miguel Sanches, and Mario Hernández (Eds.), *Proceedings of the Fifth Iberian Conference on Pattern Recognition and Image Analysis (IbPRIA011)*, Springer Verlag, Berlin, Heidelberg, pp. 588–595.
- Neurologyindia, 2014, T1 ve T2 ağırlıklı bel bölgesi MR görüntüleri, <http://www.neurologyindia.com/article.asp?issn=0028-3886;year=2010;volume=58;issue=5;spage=738;epage=739;aulast=Duan>, [Ziyaret Tarihi: 2014].
- Nml, 2014, intervertebral disk, <http://www.nlm.nih.gov/medlineplus/ency/imagepages/19469.htm>, [Ziyaret Tarihi: Eylül 2014].
- Oktay, A. B., 2011, Önsel bilgi kullanarak tıbbi görüntülerde makine öğrenmesi tabanlı kontur bulma ve nesne konumlandırma, Doktora Tezi, *Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü*, Gebze.
- Omurgaomurilik, 2014, Omur kayması, <http://www.omurgaomurilik.com/page/belkaymasi.html>, [Ziyaret Tarihi: Eylül 2014].

- Orman, O., 2009, Pelvik insidens açısı ve diğer sakropelevik parametrelerin iki Yıl takipli kifoz hastalarında korreksiyon kaybı üzerine etkisi, *Uzmanlık Tezi, Okmeydanı Eğitim ve Araştırma Hastanesi Ortopedi ve Travmatoloji Kliniği*, İstanbul.
- Oyar, O., 2008, Magnetik rezonans görüntüleme (mrg)'nin klinik uygulamaları ve endikasyonları, *Harran Üniversitesi Tıp Fakültesi Dergisi*, 2008;5(2):31-40.
- Öner A., 2013, Yüz öznitelik çıkarımı için geliştirilmiş aktif şekil modeli, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- Özdemir H., 2013, Yapay sinir ağları ve dokuma teknolojisinde kullanımı, *Tekstil Teknolojileri Elektronik Dergisi*, Cilt: 7, No: 1, pp. 51-68.
- Özkan, M., Sprenkels, H., and Dawant, B., 1990, Multispectral magnetic resonance image segmentation using neural networks, *In International Joint Conference on Neural Networks*, Vol. 1, pp. 429-434.
- Özkan, Y., 2008, Veri madenciliği yöntemleri, *Papatya Yayıncılık*, İstanbul, 136,137.
- Özkaya, A. U., 2006, Intelligent arrhythmia classification based on support machines, Yüksek Lisans Tezi, *Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul,
- Özlü, M. H., 2012, Spondilolis nedeniyle opere edilen olguların uzun dönem takip ile klinik ve radyolojik olarak değerlendirilmesi, Tıpta Uzmanlık Tezi, *Bakırköy Prof.Dr. Mazhar Osman Ruh Sağlığı Ve Sinir Hastalıkları Eğitim Ve Araştırma Hastanesi Nöroşirürji Kliniği*, İstanbul.
- Özsen O., 2004, Mamogramlar üzerinde kullanılan görüntü işleme tekniklerinin incelenmesi, *ELECO*, Cilt:1, s. 319-323.
- Öztemel, E., 2006, Yapay sinir ağları, *Papatya Yayıncılık*, İstanbul,
- Pitas, I., 2000, Digital image processing algorithms and applications, *John Wiley& Sons Inc.*
- Physioworks, 2014, sağlam ve fıtıklı disk, http://physioworks.com.au/injuries-conditions-1/bulging_disc, [Ziyaret Tarihi: Eylül, 2014].
- Polat, K., Güneş, S., Tosun, S., 2006, Diagnosis of heart disease using artificial immune recognition system and fuzzy weighted pre-processing, *Pattern Recognition*, 39(11):2186-2193.
- Polat, K., Güneş, S., 2007, A hybrid approach to medical decision support systems: Combining feature selection, fuzzy weighted pre-processing and AIRS, *Computer Methods and Programs in Biomedicine*, 88(2): 164-174.
- Polat, K., Şahan, S., Güneş, S., 2007a, Automatic detection of heart disease using an artificial immune recognition system (AIRS) with fuzzy resource allocation mechanism and k-nn (nearest neighbour) based weighting preprocessing, *Expert Systems with Applications*, 32(2): 625-631.

- Polat, K., Güneş, S., 2007b, A novel approach to estimation of E. coli promoter gene sequences: Combining feature selection and least squares support vector machine (FS_LSSVM), *Applied Mathematics and Computation*, 190(2):1574-1582.
- Polat, K., Güneş, S., 2007c, A new method to forecast of Escherichia coli promoter gene sequences: Integrating feature selection and Fuzzy-AIRS classifier system, *Expert Systems with Applications*, In Pres
- Polat, K., Güneş, S., 2009, A new feature selection method on classification of medical datasets: Kernel F-score feature selection, *Expert Systems with Applications*, 36 (7), 10367-10373.
- Polat, K., Kırmacı, V., 2011, Determining of gas type in counter flow vortex tube using pairwise fisher score attribute reduction method, *International Journal of Refrigeration*, 34(6), 1372-1386.
- Rajapakse, J., and Acharya, R., 1990, Medical image segmentation with mara, *In International Joint Conference on Neural Networks*, Vol.2, pp. 965-972.
- Sağıroğlu Ş., Beşdok E., ve Erler M., 2003, Mühendislikte yapay zeka uygulamaları-1 / yapay sinir ağları, *Ufuk Kitap Kirtasiye*, Kayseri.
- Sarıkaya, B., 2009, Lung mass classification using wavelets and support vector machines, Yüksek Lisans Tezi, *Başakşehir Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul,
- Sarıkaya, S., 2002, Kömür madeni çalışanlarında bel ağrısı, *Türkiye 13 Kömür Kongresi*, s.3-11, Zonguldak, Türkiye.
- Sebastianraschka, 2015, Özellik uzayında (a) lineer olarak ayrılabilen ve (b) lineer olarak ayrılamayan veri kümeleri, http://sebastianraschka.com/Articles/2014_kernel_pca.html, [Ziyaret Tarihi: Mart 2015].
- Sezer, Ü., 2008, Karar ağaçlarının birliktelik kuralları ile iyileştirilmesi, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, Kocaeli.
- Scholkopf, B., ve Smola, A., J., 2002, Learning with kernels., *The MIT Press*, Cambridge, MA.
- Silahtaroglu, G., 2008, Kavram ve algoritmalarıyla temel veri madenciliği, *Papatya Yayıncılık*, İstanbul.
- Sozlukanlaminedir, 2014, Bel bölgesi omuru, <http://www.sozlukanlaminedir.com/omur-nedir-omur-ne-demek/> [Ziyaret Tarihi: Eylül 2014]
- Spinalstenosis, 2014, Bel fıtığının dört aşaması, <http://spinalstenosis.org/blog/herniated-disc-spinal-stenosis/> [Ziyaret Tarihi: Eylül 2014].

- Statsoft, 2015, Doğrusal olarak ayrılamayan veri kümesi, <http://www.statsoft.com/textbook/support-vector-machines>, [Ziyaret Tarihi: Mart2015].
- Suyabatmaz, Ö. 2008, Kronik bel ağrılı hastalarda bel okulunun etkinliğinin araştırılması, Tıpta Uzmanlık Tezi, *İstanbul Eğitim ve Araştırma Hastanesi Fiziksel Tıp ve Rehabilitasyon Kliniği*, İstanbul.
- Şenköylü A., 2013, Omurganın fonksiyonel anatomisine ortopedik yaklaşım, *Türk Ortopedi ve Travmatoloji Eğitim Konseyi*, Hizmetiçi eğitim ders notları, Malatya.
- Talu, M. F., Türkoğlu İ., Cebeci M., Ortalama kayma algoritması kullanılarak gerçek zamanlı çekirdek tabanlı nesne takibi, *SIU 2010, IEEE 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Diyarbakır, 328-331.
- Tayyar, N., ve Tekin, S., 2013, İMKB-100 endeksinin destek vektör makineleri ile günlük, haftalık ve aylık veriler kullanarak tahmin edilmesi, *AİBÜ Sosyal Bilimler Enstitüsü Dergisi*, Cilt:13, Yıl:13, Sayı:1, 13:189-217.
- Tekin A., 2010, Lumbal disk hernisi ve spinal stenoz olgularında ilgilianatomik bölgenin radyolojik ve klinik bulgular ile değerlendirilmesi, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Sağlık Bilimleri Enstitüsü*, Kocaeli.
- Tekin S., 2013, Destek vektör makineleri yöntemi ile İMKB 100 endeksi hareket yönü tahmini, Yüksek Lisans Tezi, *Uşak Üniversitesi Sosyal Bilimler Enstitüsü*, Uşak.
- Tronlyimage, 2014, Bel bölgesi röntgen görüntüsü, <http://tr.onlyimage.com/photo/schmorl-s-nodes-and-limbus-vertebrae-1056703>, [Ziyaret Tarihi: Eylül 2014].
- Tumorlibrary, 2014, Bel bölgesi bilgisayarlı tomografi görüntüsü, http://www.tumorlibrary.com/case/detail.jsp?image_id=4028 [Ziyaret Tarihi: Eylül 2014].
- Turanuslu, 2014, Bel bölgesi omurları, <http://www.turanuslu.net/omurga-anatomisi/> [Ziyaret Tarihi: Eylül 2014].
- Turkoğlu, İ., Şengür A., Toraman S., 2003, Tıbbi görüntülerden istenen bir örüntünün ayrıştırılması, *Doğu Anadolu Bölgesi Araştırmaları Dergisi*, vol. 3., 97- 101.
- Uslu, M. F., 2011, Yapay sinir ağları ile tıbbi verilerin değişik eğitim metodları ve aktivasyon fonksiyonları kullanılarak analizi (Analysis of medical data via artificial neural networks with comparing different training methods and activation functions), Yüksek Lisans, *Fatih Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
- UCI, 2015, Makine öğrenmesi veritabanları, Vertebral Column Dataset. UCI Repository of Machine Learning Databases. <http://archive.ics.uci.edu/ml/machine-learning-databases/00212/> [Ziyaret Tarihi: Ocak 2015]

- Ünal, Y., Polat, K., Kocer H. E., 2014, Pairwise FCM based feature weighting for improved classification of vertebral column disorders, *Computers in Biology and Medicine*, Vol:46, pp.61-70.
- Üstün, Z., 2014, Bir üniversite hastanesi hemşirelerinde bel ağrısı sıklığı fonksiyonel yetersizlik düzeyi ve ilişkili etmenler, Yüksek Lisans Tezi, *Ankara Üniversitesi Sağlık Bilimleri Enstitüsü*, Ankara.
- Vapnik, V. N., 1995, The nature of statistical learning theory, *Springer-Verlag*, NewYork.
- Vapnik, V. N., 1998, Statistical learning theory. *John Wiley & Sons*, New York.
- Vapnik, Vladimir N., 1997, Support vector regression machines, in *Advances in Neural Information Processing Systems*, NIPS 1996, 155–161, MIT Press.
- Varyemez, M. T., 2010, Lomber instabilite ve lomber spondilolistezis olgularında posterior stabilizasyon ile füzyon uygulamalarının ağrı, disabilite ve yaşam kalitesi üzerine etkisi, *Mersin Üniversitesi Tıp Fakültesi Beyin Ve Sinir Cerrahisi Anabilim Dalı*, Mersin.
- Vertebral Column Dataset. UCI Repository of Machine Learning Databases. <http://archive.ics.uci.edu/ml/machine-learning-databases/00212/> [Ziyaret Tarihi Mart 2015].
- Wu K. L., Yang M. S., 2007, Mean shift-based clustering, *Pattern Recognition Society*, 40(2007), pp. 3035-3052.
- Wu K. L., Yang M. S., 2007, Mean shift-based clustering, *Pattern Recognition*, 40(11), pp. 3035–3052.
- Xie Q. Y., Cheng Y., 2014, K-centers mean-shift reverse mean-shift clustering algorithm over heterogeneous wireless sensor networks, *Wireless Telecommunications Symposium (WTS)*, s.1- 6.
- Xing, G., and Feltham, R., 1994, *Pyramidal neural networking for mammogram tumour pattern recognition* , In *IEEE International Conference on Neural Networks*, Vol. VI, pp. 3546-3551.
- Yalçın, N., 2012, Sezgisel algoritma öğrenmeli yapay sinir ağları ile epilepsi hastalığının teşhisi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 8-14.
- Yavuz, F., 2010, Lomber dejeneratif disk hastalığında intradiskal steroid enjeksiyonun etkinliğinin araştırılması, Tıpta Uzmanlık Tezi, *Gülhane Askeri Tıp Akademisi Askeri Tıp Fakültesi Fiziksel Tıp ve Rehabilitasyon Anabilim Dalı*, Ankara.

Yumak B., 2011, Elektronik postaların ayrıştırılmasında naive bayesian ve bulanık mantık yöntemlerinin karşılaştırılması,Yüksek Lisans Tezi, *Gazi Üniversitesi Bilişim Enstitüsü*, Ankara.

EKLER

EK-1 Etik Kurul Kararı

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Sayısı: 2014/18

Toplantı Tarihi : 04.11.2014


Karar Sayısı 2014/301 S.Ü. Teknoloji Fakültesi Öğretim Üyesi Yrd.Doç.Dr. H.Erdinç KOÇER'in, "Makine Öğrenmesi Yöntemleriyle Bel Bölgesi Rahatsızlıklarının Tanısı" adlı çalışmanın görüşülmesi, başlıklı araştırmasının değerlendirilme talebi ile ilgili 28.10.2014 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Yrd.Doç.Dr. H.Erdinç KOÇER'in, "Makine Öğrenmesi Yöntemleriyle Bel Bölgesi Rahatsızlıklarının Tanısı" adlı araştırmanın kabulüne oy birliği ile karar verildi.


ASLI GİBİDİR
04/11/2014
Mehmet Kılıç
Sekreterya
S. Ü. D. E. K.

EK-2 Tezde Kullanılan Yazılımların Ekran Görüntüleri


Tez çalışmasının ön işlem aşamasında MR görüntülerinin iyileştirilmesi (histogram eşitleme ve medyan filtreleme) ve kesme işlemleri için MATLAB GUI ortamında geliştirilen yazılımın ekran görüntüleri (Şekil 1, Şekil 2, Şekil 3) aşağıda verilmiştir.



Şekil 1. Ön işlem aşaması ana ekranı




Şekil 2. İlgili bölgenin kesilmesi ekran görüntüsü




Şekil 3. İlgili bölge üzerinde ölçüm işlemi


Tez çalışmasının sınıflandırma aşamasında özellik çıkarımından elde edilen özellik vektörleri, Waikato Üniversitesinde geliştirilmiş açık kaynak kodlu WEKA makine öğrenmesi yazılımında sınıflandırılmıştır. Sınıflandırma işleminin adımlarını gösteren ekran görüntüleri (Şekil 4, Şekil 5, Şekil 6, Şekil 7) aşağıda verilmiştir.




Şekil 4. Weka yazılımı ana ekran görüntüsü



Şekil 5. Açılan dosyanın istatistiki bilgiler ekran görüntüsü



Şekil 6. Weka yazılımı kütüphanesinde yer alan sınıflama algoritmaları



Şekil 7. Naive bayes algoritması ile sınıflama sonuçları

EK-3 Tezde Geliştirilen Ortalama Kayma Kümeleme Tabanlı Veri Ağırlıklandırma Yönteminin Matlab Kodları

```

clc;

clear all;

load yavuz_3_class_full;

dataPts=yavuz_3_class_full(:,1:11);

dataPts=dataPts';

bandWidth=5.75;

[clustCent,data2cluster,cluster2dataCell] = MeanShiftCluster(dataPts,bandWidth);

function [clustCent,data2cluster,cluster2dataCell] =
MeanShiftCluster(dataPts,bandWidth,plotFlag);
%perform MeanShift Clustering of data using a flat kernel
%
% ---INPUT---
% dataPts      - input data, (numDim x numPts)
% bandWidth    - is bandwidth parameter (scalar)
% plotFlag     - display output if 2 or 3 D   (logical)
% ---OUTPUT---
% clustCent    - is locations of cluster centers (numDim x numClust)
% data2cluster - for every data point which cluster it belongs to (numPts)
% cluster2dataCell - for every cluster which points are in it (numClust)
%
% Bryan Feldman 02/24/06
% MeanShift first appears in
% K. Funkunaga and L.D. Hosteler, "The Estimation of the Gradient of a
% Density Function, with Applications in Pattern Recognition"

%*** Check input ****
if nargin < 2
    error('no bandwidth specified')
end

if nargin < 3
    plotFlag = true;
    plotFlag = false;
end

```



```

%**** Initialize stuff ***
[numDim,numPts] = size(dataPts);
numClust      = 0;
bandSq        = bandWidth^2;
initPtInds    = 1:numPts;
maxPos        = max(dataPts,[],2);           %biggest size in each dimension
minPos        = min(dataPts,[],2);           %smallest size in each dimension
boundBox      = maxPos-minPos;               %bounding box size
sizeSpace     = norm(boundBox);              %indicator of size of data space
stopThresh    = 1e-3*bandWidth;             %when mean has converged
clustCent     = [];                         %center of clust
beenVisitedFlag = zeros(1,numPts,'uint8');   %track if a points been seen already
numInitPts    = numPts;                     %number of points to posibaly use as
initialization points
clusterVotes  = zeros(1,numPts,'uint16');    %used to resolve conflicts on cluster
membership

while numInitPts

    tempInd     = ceil( (numInitPts-1e-6)*rand); %pick a random seed point
    stInd       = initPtInds(tempInd);          %use this point as start of mean
    myMean      = dataPts(:,stInd);             % intilize mean to this points
location
    myMembers   = [];                          % points that will get added to this cluster

    thisClusterVotes = zeros(1,numPts,'uint16'); %used to resolve conflicts on
cluster membership

    while 1 %loop untill convergence

        sqDistToAll = sum((repmat(myMean,1,numPts) - dataPts).^2); %dist squared
from mean to all points still active
        inInds      = find(sqDistToAll < bandSq); %points within bandWidth
        thisClusterVotes(inInds) = thisClusterVotes(inInds)+1; %add a vote for all the in
points belonging to this cluster

        myOldMean   = myMean; %save the old mean
        myMean      = mean(dataPts(:,inInds),2); %compute the new mean
        myMembers   = [myMembers inInds]; %add any point within
bandWidth to the cluster
        beenVisitedFlag(myMembers) = 1; %mark that these points have
been visited

    %*** plot stuff ****
    if plotFlag
        figure(12345),clf,hold on
        if numDim == 2
            plot(dataPts(1,:),dataPts(2:),'')

```

```

        plot(dataPts(1,myMembers),dataPts(2,myMembers),'ys')
        plot(myMean(1),myMean(2),'go')
        plot(myOldMean(1),myOldMean(2),'rd')
        pause
    end
end

%**** if mean doesn't move much stop this cluster ***
if norm(myMean-myOldMean) < stopThresh

    %check for merge possibilities
    mergeWith = 0;
    for cN = 1:numClust
        distToOther = norm(myMean-clustCent(:,cN));    %distance from posible
new clust max to old clust max
        if distToOther < bandWidth/2                    %if its within bandwidth/2 merge
new and old
            mergeWith = cN;
            break;
        end
    end

    if mergeWith > 0    % something to merge
        clustCent(:,mergeWith)    = 0.5*(myMean+clustCent(:,mergeWith));
%record the max as the mean of the two merged (I know biased towards new ones)
        %clustMembsCell{mergeWith}    = unique([clustMembsCell{mergeWith}
myMembers]); %record which points inside
        clusterVotes(mergeWith,:)    = clusterVotes(mergeWith,:) + thisClusterVotes;
%add these votes to the merged cluster
    else    %its a new cluster
        numClust    = numClust+1;                    %increment clusters
        clustCent(:,numClust)    = myMean;                %record the mean
        %clustMembsCell{numClust}    = myMembers;                %store my
members
        clusterVotes(numClust,:)    = thisClusterVotes;
    end

    break;
end

end

initPtInds    = find(beingVisitedFlag == 0);    %we can initialize with any of the
points not yet visited
numInitPts    = length(initPtInds);                %number of active points in set

end

```

```
[val,data2cluster] = max(clusterVotes,[],1);      %a point belongs to the cluster
with the most votes
```

```
%*** If they want the cluster2data cell find it for them
```

```
if nargout > 2
```

```
    cluster2dataCell = cell(numClust,1);
```

```
    for cN = 1:numClust
```

```
        myMembers = find(data2cluster == cN);
```

```
        cluster2dataCell{cN} = myMembers;
```

```
    end
```

```
end
```

KİŞİSEL BİLGİLER

Adı Soyadı : Yavuz ÜNAL
Uyruğu : T.C
Doğum Yeri ve Tarihi : Tokat/Erbaa 05.02.1980
Telefon : 03582123341
Faks : 03582180104
e-mail : yavuz.unal@amasya.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Coşkun Önder Lisesi , Erbaa, Tokat	1997
Üniversite	: Selçuk Üniversitesi Teknik Eğitim Fakültesi	2002
Yüksek Lisans	: Selçuk Üniversitesi Elektronik ve Bilgisayar Eğt.	2006
Doktora	: Selçuk Üniversitesi Bilgisayar Müh.	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2002-2012	Selçuk Üniversitesi Teknik Eğitim Fak.	Araştırma Gör.
2012-...	Amasya Üniversitesi Eğitim Fakültesi	Öğretim Gör.

UZMANLIK ALANI

Görüntü İşleme, Sınıflama, Veri Ağırlıklandırma

YABANCI DİLLER

İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR

Yavuz ÜNAL, Kemal POLAT, H. Erdinç KOÇER , "Pairwise FCM based feature weighting for improved classification of vertebral column disorders", [Computers in Biology and Medicine](#), Vol:46, pp.61-70, 2014. (Doktora tezinden yapılmıştır)

Yavuz ÜNAL, Kemal POLAT, H. Erdinç KOÇER “Detection of Abnormalities in Lumbar Discs from Clinical Lumbar MRI with Hybrid Models”, *Applied Soft Computing*, 2015. (Doktora tezinden yapılmıştır)

Hakan IŞIK, Mustafa Cihat AVUNDUK, Yavuz ÜNAL.,(2010) “Design and Realization of an Improved Patalogy Equipment by Giving a Frozen Ability”, *E-Journal of New World Sciences Academy*, Volume: 5, Number: 2, Article Number: 1A0078, pp.215-225 (Yüksek lisans tezinden yapılmıştır)

Yavuz ÜNAL, Erdiñ KOÇER, H.E. AKKURT “A comparison of feature extraction techniques for diagnosis of lumbar intervertebral degenerative disc disease” Innovations in Intelligent Systems and Applications (INISTA), 2011 International Symposium on INnovations in Intelligent SysTems and Applications (Doktora tezinden yapılmıştır)

Y. Unal, H. E. Kocer and H. E. Akkurt, Automatic diagnosis of intervertebral degenerative disk disease using Artificial Neural Networks, 6th International Advanced Technologies Symposium (IATS'11), 16-18 May 2011, Elazığ, Turkey (Doktora tezinden yapılmıştır)

Y. Unal, E. Kocer, "Diagnosis of pathology on the vertebral column with backpropagation and Naive Bayes classifier", The International Conference on Technological Advances in Electrical, Electronics and Computer Engineering (TAEECE2013), 9-13 may. Konya/TURKEY. (Doktora tezinden yapılmıştır)