



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

3B ALZHEİMER MR GÖRÜNTÜLERİNİN SINIFLANDIRILMASINDA YENİ YAKLAŞIMLAR

Muhammet Üsame ÖZİÇ

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Ağustos-2018
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Muhammet Üsame ÖZİÇ tarafından hazırlanan "3B Alzheimer MR Görüntülerinin Sınıflandırılmasında Yeni Yaklaşımlar" adlı tez çalışması 13/08/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri	**İmza**
Başkan Dr. Öğr. Üyesi H. Oktay ALTUN	H. Oktay Altun
Danışman Doç. Dr. Seral ÖZŞEN	
Üye Dr. Öğr. Üyesi Ömer Kaan BAYKAN	Ö. Kaan
Üye Dr. Öğr. Üyesi Bayram AKDEMİR	
Üye Dr. Öğr. Üyesi Burak YILMAZ	

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mustafa YILMAZ
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.



İmza

Muhammet Üsame ÖZİÇ

Tarih: 13.08.2018

ÖZET

DOKTORA TEZİ

3B ALZHEİMER MR GÖRÜNTÜLERİNİN SINIFLANDIRILMASINDA YENİ YAKLAŞIMLAR

Muhammet Üsame ÖZİÇ

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Seral ÖZŞEN

2018, 185 Sayfa

Jüri
Dr. Öğr. Üyesi Hüseyin Oktay ALTUN
Doç. Dr. Seral ÖZŞEN
Dr. Öğr. Üyesi Ömer Kaan BAYKAN
Dr. Öğr. Üyesi Bayram AKDEMİR
Dr. Öğr. Üyesi Burak YILMAZ

Alzheimer Hastalığı yaşlılıkla beraber başlayan ve geri dönüşü olmayan nörolojik bir beyin hastalığıdır. Hastalığın nedeni bilinmemektedir ve hastalığı durduran bir tedavi yoktur. Ancak erken evre teşhis edilebilirse hastalığın bulunduğu evreyi uzatacak bir takım tedaviler mevcuttur. Dünyada yaşlı nüfusun artması ile beraber hastalığın ülkelere tedavi maliyetleri, bakım masrafları ve sosyolojik çıktıları bakımından ağır yükler getireceği tahmin edilmektedir. Güncel rakamlarla Türkiye'de yaklaşık 600 bin aile Alzheimer ile mücadele etmektedir. Ülkemizde de yaşlı nüfusun artması ile beraber hastalığa yakalanma riski de gittikçe artmaktadır. Dolayısıyla Alzheimer hastalığının tespiti, maliyeti, risk faktörleri, ilaç tedavileri, sosyolojik çıkıtları, bakım metotları gibi çalışmalar hem ülkemizde hem de dünyada güncelliğini koruyan konulardır.

Manyetik rezonans görüntüleme nörolojik hastalıkların beyinde oluşturduğu hasarların invazif olmayan bir şekilde izlenebilmesi için geliştirilmiş olan üç boyutlu bir görüntüleme tekniğidir. Bu teknik ile Alzheimer hastalığının beyinde meydana getirdiği katı değişiklikler net bir şekilde izlenebilmektedir. Tez çalışmasında üç boyutlu manyetik rezonans görüntüler kullanılarak Alzheimer hastalığının beyinde meydana getirdiği hacim, simetri ve doku farklılıklarını temsil eden çok değişkenli özellikler ile hastalığı sınıflandıran yeni yaklaşımlar geliştirilmiştir. Üç boyutlu Manyetik Rezonans görüntülerde önişlemelerin nasıl yapıldığı, literatürde hangi sayısal metotların ve paket programların kullanıldığı detaylı bir şekilde incelenmiştir. Global ve lokal hacimler için hesaplamaları kısa bir sürede yapan etkili modeller önerilmiştir. Simetri analizi için görüntü kalite analizinde kullanılan iki metrik ve istatistikte kullanılan dokuz metrik ile yeni bir simetri hesabı modeli türetilmiştir. Doku analizi için üç boyutlu görüntülerde hangi bölgelerin dejenerasyona uğradığı öncelikle belirlenmiştir. Bunun için literatürde grup analizlerinde sıklıkla kullanılan Voksel Tabanlı Morfometri ile kayıp bölge haritalamaları yapılmış, ilgili bölgelerin üç boyutlu hacim kayıp maskeleri elde edilmiştir. Böylece tüm bir görüntü ile analiz yerine sadece ilgili bölge analizi yapılarak hem süre hem de sınıflandırma performansı açısından etkili modeller geliştirilmiştir. İlgili bölgeler manyetik rezonans görüntülerde maskelendikten sonra histogram tabanlı birinci dereceden istatistikler, ham voksel değerleri, üç boyutlu ayrık dalgacık dönüşümü ve üç boyutlu gri seviye eş oluşum matrisleri kullanılarak doku özellik kümeleri oluşturulmuştur. Tüm özellikler, boyutlarının çok fazla olmasından dolayı Bhattacharya, entropi, roc, t-test, Wilcoxon özellik derecelendirme yöntemi ile en anlamlı özellikten en anlamsız özelliğe doğru derecelendirilmiştir. Sıralanan özellikler sırayla birleştirilmiş ve sonra on kat çapraz geçerleme ve iki farklı kernel kullanarak destek vektör makinaları ile sınıflandırılmıştır.

Tez çalışmasında, önerilen yaklaşımların öncelikle The Open Access Series of Imaging (OASIS) veri tabanından elde edilen Alzheimer ve Normal üç boyutlu MR görüntüleri ile sınıflandırma doğrulukları değerlendirilmiştir. OASIS veri tabanında en yüksek sınıflandırma doğruluğunu veren modeller belirlenerek, Selçuk Üniversitesi Tıp Fakültesi Nöroloji ve Radyoloji Anabilim Dallarının ortak aldıkları verilerde validasyon işlemi gerçekleştirilmiştir. Tüm analizler sonucunda üç boyutlu manyetik rezonans görüntülerinde normal kontrolden Alzheimer hastalığını ayıran en iyi özellik kümeleri ve sınıflandırma modelleri belirlenmiştir.

Anahtar Kelimeler: Alzheimer, Manyetik Rezonans, Sınıflandırma, Hacim Analizi, Doku Analizi, Simetri Analizi

ABSTRACT

Ph.D THESIS

NEW APPROACHES TO THE CLASSIFICATION OF 3D ALZHEIMER MR IMAGES

Muhammet Üsame ÖZİÇ

The Graduate School of Natural and Applied Science of Selçuk University
The Degree of Doctor of Philosophy in Electrical & Electronics Engineering

Advisor: Assoc. Prof. Seral ÖZŞEN

2018, 185 Pages

Jury
Asst. Prof. Dr. Hüseyin Oktay ALTUN
Assoc. Prof. Dr. Seral ÖZŞEN
Asst. Prof. Dr. Ömer Kaan BAYKAN
Asst. Prof. Dr. Bayram AKDEMİR
Asst. Prof. Dr. Üyesi Burak YILMAZ

Alzheimer's Disease is a neurological brain disease that begins with aging and is irreversible. The cause of the disease is unknown and there is no cure to stop the disease. However, if it can be diagnosed at early stage, there are a number of treatments that will extend the stage of the disease. Along with the increase in the elderly population in the world, it is estimated that the disease will bring a heavy burden to the countries in terms of treatment costs, care costs and sociological outcomes. With current figures, approximately 600 thousand families are struggling with Alzheimer's in Turkey. With the increase in the elderly population in our country, the risk of getting caught the disease is also increasing. Therefore, studies such as detection, cost, risk factors, drug treatments, sociological outcomes, and care methods of Alzheimer's Disease are the subjects that keep up-to-date both in our country and in the world.

Magnetic resonance imaging is a three-dimensional imaging technique developed for non-invasive monitoring of brain damage caused by neurological diseases. With this technique, rigid changes in the brain caused by Alzheimer's disease can be clearly monitored. In the thesis study, new approaches that classify the disease have been developed with multivariate features representing the volume, symmetry and tissue differences caused by Alzheimer's disease in the brain by using three-dimensional magnetic resonance images. In the three-dimensional magnetic resonance images, how preprocessing methods are made, which numerical methods and package programs are used in the literature are examined in detail. Effective models have been proposed that make calculations for global and local volumes in a short time. For symmetry analysis, a new model of symmetry calculation has been derived with two metrics used in image quality analysis and nine metrics used in the statistic. In order to perform the texture analysis, it has been determined primarily which regions undergo degeneration in three-dimensional images. For this purpose, lossy region maps have been obtained with Voxel-Based Morphometry which is often used in group analyzes in the literature, and three-dimensional volume loss masks of the corresponding regions have been obtained. Thus, instead of analyzing an entire image, only the relevant region analysis is performed and effective models are developed in terms of both time and classification performance. Relevant regions after being masked in magnetic resonance images, histogram-based first order statistics, raw voxel values, three-dimensional discrete wavelet transform, and three-dimensional gray level co-occurrence matrices have been used to generate texture feature sets. All features have been ranked from the most meaningful feature to the most meaningless feature with Bhattacharya, entropy, roc, t-test, Wilcoxon feature ranking methods because of their large size. Ranked features have been combined in order and then have been classified by support vector machines using ten-fold cross-validation and two different kernels.

In the thesis study, the proposed approaches have been firstly evaluated with the classification accuracies of Alzheimer's and Normal three-dimensional MR images obtained from the Open Access Series of Imaging (OASIS) database. In the OASIS database, the models that given the highest classification accuracy have been identified and validation has been performed in the data obtained from the Department of Neurology and Radiology, Faculty of Medicine, Selçuk University. As a result of all analyzes, the best feature clusters and classification models that distinguish Alzheimer's disease from normal control in three-dimensional magnetic resonance images have been determined.

Keywords: Alzheimer, Magnetic Resonance, Classification, Volume Analysis, Tissue Analysis, Symmetry Analysis

ÖNSÖZ

Bu tez çalışmasında akademik katkılarıyla benden yardımlarını esirgemeyen danışmanın Doç. Dr. Seral ÖZŞEN'e, verilerin toplanmasında yardımcı olan Selçuk Üniversitesi Tıp Fakültesi Nöroloji Anabilim Dalı Dr. Öğretim Üyesi Ahmet Hakan EKMEKCİ ve Arş. Gör. Aydın Talip YILDOĞAN'a, Radyoloji Anabilim Dalı öğretim üyesi Prof. Dr. Mustafa KOPLAY'a, mesai arkadaşlarıma, bölüm hocalarıma ve aileme teşekkürü bir borç bilirim.

Muhammet Üsame ÖZİÇ
KONYA-2018

İÇİNDEKİLER

ÖZET ..... **iv**

ABSTRACT ..... **vi**

ÖNSÖZ ..... **viii**

İÇİNDEKİLER ..... **ix**

SİMGELER VE KISALTMALAR ..... **xi**

1. GİRİŞ **1**

1.1. Tez Konusunun Amacı ve Önemi 2
1.2. Tezin Organizasyonu 6

2. KAYNAK ARAŞTIRMASI **7**

3. ALZHEİMER HASTALIĞI **18**

4. MANYETİK REZONANS GÖRÜNTÜLEME **22**

4.1. Veri Tabanları 24
4.2. Paket Programlar 25
4.3. MR Görüntülerinde Önişleme Yöntemleri 27
4.3.1. Eksen Dönüştürme 28
4.3.2. Görüntü Reoryantasyonu 29
4.3.3. Gürültü ve Bias Giderme 31
4.3.4. Normalizasyon 33
4.3.5. Beyin Dışı Yapıların Atılması 34
4.3.6. Segmentasyon 35
4.3.7. Modülasyonlu ve Modülasyonsuz Görüntüler 37
4.3.8. Yumuşatma 38
4.3.9. Birlikte Çakıştırma 39

5. MATERYAL VE YÖNTEM **40**

5.1. Veri Kümesi 41
5.1.1. OASIS Veri Tabanı 41
5.1.2. Tıp Fakültesi Verileri 44
5.2. VBM8 Kütüphanesi ile Segmentasyon İşlemi 46
5.3. Hacim Analizi 47
5.3.1. Global Hacimler 48
5.3.2. Lokal Hacimler 49
5.4. Simetri Analizi 52
5.5. Doku Analizi 59
5.5.1. Voksel Tabanlı Morfometri 59
5.5.2. Hacim Kayıp Maskesi ile 3B Maskeleme İşlemi 67

5.5.3. Histogram Tabanlı Birinci Dereceden İstatistikler 70
5.5.4. Voksel Değerlerinin Özellik Olarak Kullanımı 72
5.5.5. 3B Ayrık Dalgacık Dönüşümü 74
5.5.6. 3B Gri Seviye Eş Oluşum Matrisleri 81
5.6. Özellik Seçme 86
5.7. Sınıflandırma 89
5.8. Performans Değerlendirme Kriterleri 91
5.9. Sınıflandırma Mimarisi 93

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA 96

6.1. Global Beyin Özellikleri Sınıflandırma Sonuçları 96
6.2. Lokal Hacimler Sınıflandırma Sonuçları 98
6.3. Simetri Sınıflandırma Sonuçları 101
6.4. HTBDİ Sınıflandırma Sonuçları 103
6.5. Voksel Değerleri Sınıflandırma Sonuçları 106
6.6. 3B GSEOM Sınıflandırma Sonuçları 110
6.7. 3B Ayrık Dalgacık Dönüşümü Sınıflandırma Sonuçları 113
6.8. OASIS ve Tıp Fakültesi Verileri Sınıflandırma Genel Sonuçları 115

7. SONUÇLAR VE ÖNERİLER 134

7.1. Sonuçlar 134
7.2. Öneriler 139

KAYNAKLAR 142

EKLER 152

ÖZGEÇMİŞ 184

SİMGELER VE KISALTMALAR

Simgeler

μ	: Ortalama
σ	: Standart Sapma
σ_{xy}	: Ortak Kovaryans
S	: Ölçek Parametresi
T	: Kaydırma Parametresi
$\psi_{s,\tau}(t)$	: Ana Dalgacık Fonksiyonu
$\varphi(x)$	: Bir Boyutlu Ölçekleme Fonksiyonu
$\varphi(x,y)$	: İki Boyutlu Ölçekleme Fonksiyonu
$\varphi(x,y,z)$	: Üç Boyutlu Ölçekleme Fonksiyonu
$\psi(x)$	: Bir Boyutlu Dalgacık Fonksiyonu
$\psi(x,y)$	: İki boyutlu Dalgacık Fonksiyonu
$\omega^i(x,y,z)$	: Üç Boyutlu Dalgacık Fonksiyonu
x_{ik}	: *i.* gözlemin *k.* değişkeni
x_{jk}	: *j.* gözlemin *k.* değişkeni
f(x)	: Bir Boyutlu Fonksiyon
f(x,y)	: İki Boyutlu Fonksiyon
f(x,y,z)	: Üç Boyutlu Fonksiyon
h(i)	: Histogram
p(i)	: Piksel Yoğunluk Fonksiyonu
$\delta(j,i)$	: Kronecker Delta Fonksiyonu
σ^2	: Varyans
μ_3	: Basıklık
μ_4	: Çarpıklık
c_{jk}	: Ayrışım Katsayıları
d_{jk}	: Detay Katsayıları
J	: Ayrıştırma Seviyesi
L(x,y,z)	: Alçak Geçiren Filtre
H(x,y,z)	: Yüksek Geçiren Filtre
P[i,j]	: Piksel Çiftleri
d_{ij}	: Uzaklık
D	: Deplasman Vektörü
θ	: z düzleminde aşağı yukarı hareket açısı
Φ	: xy düzlemindeki hareket
ϑ	: Açısal Yönler
W_{φ}	: Üç Boyutta Yaklaşım Katsayıları
W_{ω}^{i}	: Üç Boyutta Detay Katsayıları
w	: Ağırlık Vektörü
b	: Eğilim Değeri
ml	: Mililitre
mm	: Milimetre
p	: Önemlilik Değeri

Kısaltmalar

1B : Bir Boyutlu
2B : İki Boyutlu
3B : Üç Boyutlu
AAL : *Automated Anatomical Labeling*
AC : *Anterior Commissure*
ADD : Ayrık Dalgacık Dönüşümü
ADNI : *Alzheimer's Disease Neuroimaging Initiative*
AH : Alzheimer Hastalığı
B : *Bhattacharya*
BET : *Brain Extraction Tool*
BM : Beyaz Madde
BOS : Beyin Omurilik Sıvısı
BSE : *Brain Surface Extractor*
DARTEL : *Diffeomorphic Anatomical Registration Through Exponentiated Lie Algebra*
D : Dikey
DICOM : *Digital Imaging and Communication in Medicine*
DO : Doğruluk
DL : DVM-Lineer
DN : Doğru Negatif
DP : Doğru Pozitif
DR : DVM-rbf
DVM : Destek Vektör Makinaları
E : Entropi
ESLR : *Ensemble Feature Selection Based Sparse Logistic Regression*
FA : *Flip Angle*
FD : Fourier Dönüşümü
FWE : *Family Wise Error*
FWHM : *Full Width at Half Maximum*
GM : Gri Madde
GSEOM : Gri Seviye Eş Oluşum Matrisleri
HA : Hassasiyet
HTBDİ : Histogram Tabanlı Birinci Dereceden İstatistikler
K : Köşegen
KDR : Klinik Demans Derecelendirme
kNN : *k-Nearest Neighbors*
KZFD : Kısa Zamanlı Fourier Dönüşümü
LV : Lateral Ventrikül
McRBFN : *Meta-Cognitive Radial Basis Function Network*
MIPAV : *Medical Image Processing, Analysis and Visualization*
MIRIAD : *Minimal Interval Resonance in Alzheimer's Disease*
MNI : *Montreal Neurological Institue*
MP-RAGE : *Magnetization Prepared Rapid Gradient Echo*
MR : Manyetik Rezonans
MRG : Manyetik Rezonans Görüntüleme
MSE : *Mean Square Error*
NIfTI : *Neuroimaging Informatics Technology Initiative*
NK : Normal Kontrol

OASIS : *The Open Access Series of Imaging Studies*
OPLS : *Orthogonal Partial Squares to Latent Structures*
ÖS : Özellik Sayısı
ÖZ : Özgüllük
PC : *Posterior Commissure*
PET : Pozitron Emisyon Tomografi
PRNKM : Parankim
PSNR : *Peak Signal to Noise Ratio*
R : *Roc*
RBF : *Radyal Based Function*
RF : Radyo Frekans
ROC : *Receiver Operating Characteristic*
ROI : *Region of Interest*
VOI : *Volume of Interest*
SDD : Sürekli Dalgacık Dönüşümü
SLR : *Sparse Logistic Regression*
SPM8 : *Statistical Parametric Mapping 8*
SS : Standart Sapma
SSIM : *Structural Similarity Index Measure*
T : *T-test*
TBH : Tüm Beyin Hacmi
TD : *Delay Time*
TE : *Echo Time*
TI : *Inversion Time*
TPM : *Tissue Probability Map*
TR : *Repetition Time*
VBM8 : *Voxel Based Morphometry 8*
VOI : *Volume of Interest*
VTM : Voksel Tabanlı Morfometri
Y : Yatay
YN : Yanlış Negatif
YP : Yanlış Pozitif
W : *Wilcoxon*
WFU : *Wake Forest University*

1. GİRİŞ

Alzheimer Hastalığı (AH) yaşlılıkla ve basit unutkanlıklarla başlayan nörolojik bir hastalıktır. Dünyada yaşlı nüfusun artması ile beraber AH'ye yakalanma riski de gittikçe artmaktadır. Gelişmiş ve gelişmekte olan ülkeler için AH'nin teşhisi, tedavisi ve hasta bakım hizmetleri gibi masraflar, ciddi anlamda maddi bir yük getirmektedir. AH unutkanlıklar ile başladığı için öncelikle beyindeki hafıza bölgelerinde dejenerasyon başlamaktadır. Erken evrede başlayan bu dejenerasyon ileri evrede diğer beyin bölgelerine de yayılarak fonksiyonel merkezleri işlevsiz duruma getirmektedir. Son evrede hasta kendi günlük işlerini dahi yapamaz hale gelerek bir bakıcı refakatinde hayatını idame ettirmektedir. Hastalığın nedeni bilinmediği gibi durduran bir tedavisi de yoktur. Ancak erken evrede tespit edilebilirse evre süresini uzatabilecek bir takım tedaviler uygulanmaktadır. Böylece hastaya belli bir süre daha refah bir hayat sürdürme imkânı sağlanmaktadır. AH, başlangıç olarak birçok demans nedeni ile benzer klinik bulgular göstermektedir. Beyindeki bozulmalar yıllar önce başlasa da klinik olarak sinsi ilerlemektedir. Dolayısıyla erken safha teşhis ve diğer demans nedenlerinden ayırma, belli bir süre aldığı gibi hastalıklar karıştırılabilmektedir. Bu nedenle beyindeki bozulmaların net bir şekilde ortaya konması gerekmektedir. AH'de beyindeki temel bozulmalar tüm beyinde küçülme, gri madde hacim azalması, beyin omurilik sıvısı artışı, sulkus ve giruslarda değişim, lateral ventriküllerin genişlemesi, özellikle hafıza ve dil bölgelerinde atrofi, beyindeki nörofibril yumak ve senil plakların değişimi, iki yarım küre arasındaki simetrinin gittikçe bozulması olarak sayılabilir. Bu değişimler nörofibril yumak ve senil plak hariç dokuları yüksek çözünürlükte gösteren yapısal beyin Manyetik Rezonans (MR) görüntüleme tekniği ile invazif olmayan bir şekilde incelenebilmektedir. Nörofibril yumak ve senil plaklardaki artış-azalma Pozitron Emisyon Tomografisi (PET) görüntüleme yöntemi ile izlenebilmektedir. AH'ye teşhis ve tanı koyabilmek için görüntüleme teknikleri, klinik, laboratuvar, nöropsikolojik test sonuçları ile beraber bu sonuçları yorumlayan doktor tecrübesi birbirini tamamlayan gerekli unsurlardır. Son zamanlarda 3B yapısal beyin MR görüntüleri kullanılarak elde edilen özellikler ile hastalığın sınıflandırılması ve karar destek sistemi tasarımı çalışmaları popüler bir şekilde artış göstermektedir. Gerçeklenen karar destek sistemleri ile sınıflandırma başarımları ölçülmektedir. Bu sistemler ile hastalığın erken safha teşhisi ve üç boyutlu MR görüntülerinin hangi sınıfa ait olduğu belirlenmeye çalışılmaktadır. Bu karar destek sistemlerinin geliştirilmesi, yeni yaklaşım ve

modellerin tasarlanması hem doktorların teşhisine yardımcı olabilmesi hem de hastalığa daha hızlı müdahalelerin yapılması açısından önemlidir. Klinikte görülen Parkinson, Alzheimer, Frontotemporal Demans, Huntington Demans, Lewy Cisimcikli Demans gibi nörolojik hastalıkların kendi içinde ve birbirleri arasındaki farkları belirleyebilecek karar destek sistemlerin tasarlanması ve MR cihazlarının içine gömülmesi gelecekte tıp alanında beklenen bir çalışmadır.

1.1. Tez Konusunun Amacı ve Önemi

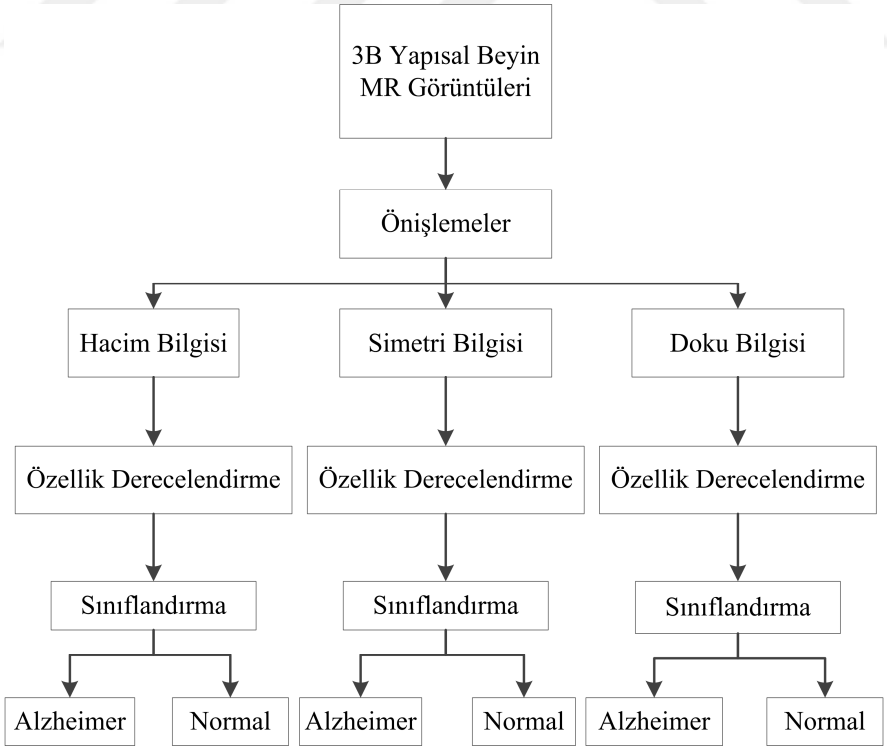
Demansa neden olan nörolojik hastalıkların 3B yapısal MR görüntüleri ile incelenmesi ve sınıflandırılması literatürde çalışılan güncel bir konudur. AH klinikte karşılaşılan demans vakalarının büyük çoğunluğunu oluşturduğundan dolayı 3B MR görüntüleme tekniği sıklıkla kullanılmaktadır. Son zamanlarda sayısal analiz tekniklerinin artması ile beraber AH ve diğer demansları, beyin MR görüntüleri kullanarak, birbirinden ve normal gruplardan yapay zeka teknikleri ile sınıflandıran çalışmalar artmıştır. Tez çalışmasında literatür yoğun bir şekilde taranmış, beyin MR görüntülerinde önişleme, özellik çıkarma, özellik seçme ve sınıflandırma yöntemleri detaylı bir şekilde incelenmiş olup, AH beyin MR görüntülerini sınıflandıran yeni yaklaşımlar önerilmiştir.

MR görüntülerinin üç boyutlu ve birbirini takip eden görüntülerden oluşması sayısal analizi son derece zorlaştırmaktadır. Çünkü bir kesit ele alınıyorsa o kesitin bir önceki ve bir sonraki kesit komşularına da bakmak gerekmektedir. Hastalıklar ile ilgili anlamlı ve değerli bilgiler birbirini takip eden görüntülerde saklanmaktadır. Dolayısıyla kümülatif bir yaklaşımla üç boyutta analiz gerçekleştirilmelidir. Üç boyutta analiz sırasında ise önişleme ve standardizasyon problemi ortaya çıkmaktadır. Her insanda kafa büyüklüğünün farklı olması, beyin dışı yapılar, görüntüye eklenen gürültüler, segmentasyon problemleri, hacim problemleri, normalizasyon problemleri, grup analizleri yüksek düzeyde modeller ve işlemler gerektiren konulardır. Bu işlemlerin manuel bir şekilde yapılması mümkün değildir. Bu nedenle her bir aşama için sayısal yöntemler ve paket programlar geliştirilmiştir. Üç boyutlu yapısal MR görüntülerinde her bir önişleme aşaması literatürde defalarca çalışılmış, en iyi yöntemler ortaya konulmuştur. Tez çalışmasında önişleme yöntemlerinin neler olduğu, hangi amaçla kullanıldığı, hangi önişlemenin hangi paket programda nasıl kullanıldığı detaylı bir şekilde araştırılmıştır. Önişleme yöntemleri, tez çalışması için bir amaç değil araç olarak

kullanılmıştır. Önişleme ve standardizasyon işleminden sonra AH'ye ait beyin özelliklerinin üç boyutlu MR görüntüsünden nasıl elde edilebileceği araştırılmıştır. AH'de beyinde meydana gelen temel bozulmalar hacimsel, dokusal ve simetri bozulması olarak görülmektedir. Hacim değişimleri global ve lokal bölgeler olmak üzere ikiye ayrılır. İnsan beynindeki global hacim değişkenleri Gri Madde (GM), Beyaz Madde (BM), Beyin Omurilik Sıvısı (BOS), Parankim Dokusu (PRNKM), Tüm Beyin Hacmi (TBH) ve Lateral Ventrikül (LV) olarak sıralanabilir. Bu bölgeler MR görüntülerinde net bir şekilde izlenebilse de sınır voksel değerlerinin hangi sınıfa ait olacağına karar vermek büyük bir problemdir. Bu bölgelerin segmentasyonu için *London College* Üniversitesi tarafından geliştirilen MATLAB tabanlı *Statistical Parametric Mapping 8* (SPM8) paket programı ve bu program altında çalışan *Voxel Based Morphometry 8* (VBM8) kütüphanesi kullanılmıştır. Segmente edilmiş bölgelerin hacim hesabı için bir MATLAB kod parçası kullanılmıştır. Hipokampus, amigdala, talamus, entorhinal korteks, pallidum gibi subkortikal hacim hesabı ise daha büyük bir problemdir. Bu bölgelerin gri madde üzerinde sınırları net bir şekilde görülmemekte, sınırları çizilse bile göreceli olmaktadır. Dolayısıyla bu bölgelerin manuel bir şekilde hacim hesabının yapılması kişiden kişiye değişebilmekte, tüm bölgelerin manuel çizim ve hacim hesabı uzun süreler alabilmektedir. Bu işlemin sayısal olarak yapılabilmesi için uluslararası standartlarda geliştirilen elektronik beyin atlasları kullanılmıştır. Elektronik beyin atlasları MATLAB içinde *Wake Forest* Üniversitesi (WFU) tarafından geliştirilen WFU PickAtlas isimli bir kütüphanede sayısal olarak elde edilebilmektedir. Ancak GM ile atlaslar arasında hem görüntü boyutu hem de voksel boyutları uyumsuzdur. Bu iki görüntü yine SPM8 programının araçları ile aynı boyutlara getirilerek bir MATLAB kod parçası ile hacim hesabı işlemi gerçekleştirilmiştir. WFU PickAtlas altındaki *Automated Anatomical Labeling* (AAL) ve Talairach atlasları ile 127 bölgenin hacim hesabı yapılmıştır. Ancak bu bölgelerin ham olarak hesaplanması ve analizi bazı sorunları beraberinde getirmektedir. Her insanda kafa büyüklüğünün farklı olması ölçülen değerlerin göreceli olmasına neden olmaktadır. Kafa büyüklüğünden dolayı sağlıklı insanlarda beyin bölgeleri farklı hacimlerde görülse de global bir hacim büyüklüğüne oranı yaklaşık eşit çıkacaktır. Dolayısıyla sayısal analizde bir normalizasyon problemi ortaya çıkmaktadır. Bunun için ham hacim değerleri GM, PRNKM ve TBH hacmine bölünerek sonuçlar istatistiksel olarak karşılaştırılmış, sınıflandırma performans analizleri yapılmıştır. Beyindeki simetri değişimleri genel olarak sağ ve sol yarımküre hacimlerinin hesaplanması ve birbirine oranlanması ile

yapılmaktadır. Bu hesaplamalar ile beynin sağa mı yoksa sola mı asimetrik olduğu bulunmaktadır. Ancak genel olarak simetri çalışmalarının problemli olduğu belirtilmektedir. Simetri değişiminin modellenmesi için istatistiksel yaklaşımlar kullanılarak tez çalışmasında yeni bir yaklaşım geliştirilmiştir. Bu yaklaşım sonuçları kullanılarak sınıflandırma performans analizleri yapılmıştır. Doku analizi MR görüntülerindeki bölgesel değişimlerden ve voksel komşuluklarındaki değişimlerden kaynaklı örüntü bozulmalarının modellenmesi işlemidir. AH'de genel olarak gri madde kayıpları olduğu için hacimsel azalmanın olduğu yerlerde renk örüntüsü gri tondan siyah tona doğru dönecektir. Hangi bölgelerin ne kadar kayıpla değiştiği manuel olarak yorumlansa da nicel bir yaklaşım manuel olarak mümkün değildir. Dolayısıyla üç boyutlu yapısal MR görüntülerinin kümülatif bir yaklaşımla grup analizlerinin yapılması, kümeler arasında hangi beyin bölgelerinin değiştiği net bir şekilde ortaya konulmalıdır. Voksel Tabanlı Morfometri (VTM) MR görüntülerinde grup analizlerinin yapılması için literatürde sıklıkla kullanılan bir tekniktir. Bu teknik ile beynin aynı koordinatlarına denk gelen voksel intensiteleri karşılaştırılarak istatistiksel olarak anlamlı hacim değişiklikleri haritalanmaktadır. Bu yöntem genel olarak grup içi, iki grup, ikiden fazla gruplar ve boylamsal veriler arasındaki hacimsel değişimlerin nerelerde olduğunu lokalize eder. Tıbbi çalışmalarda VTM ile lokalize edilen bölgeler hastalık için sadece yorumlanır ve çıkarımlarda bulunulur. Ancak bu teknik kullanılarak oluşturulan *Volume of Interest* (VOI) maskeleri ile yapılan karar destek sistemi çalışma sayısı çok azdır. Tez çalışmasında hastalık ayrımı için daha fazla anlamlı bilginin bu bölgelerde olduğu belirlenerek VTM yöntemi ile binary maskeler üretilmiş, sadece ilgili bölgelerden dokusal özellikler elde edilmiştir. VTM ile analizlerin nasıl yapıldığı, hangi paket programın nasıl kullanıldığı, parametrelerin ne olacağı, binary maskenin nasıl üretileceği, görüntülerdeki maskelemenin nasıl yapılacağı detaylı bir şekilde incelenmiştir. Bu bölgelerdeki üç boyutlu komşuluklar dikkate alınarak işlem yapılması için dört farklı doku analizi tekniği kullanılmış ve performansları karşılaştırılmıştır. VOI bölgelerden Histogram Tabanlı Birinci Dereceden İstatistikler (HTBDİ), ilgili bölgelerdeki ham voksel değerlerinin direkt olarak özellik olarak kullanılması, 3B Ayrık Dalgacık Dönüşümü (ADD) ve 3B Gri Seviye Eş Oluşum Matrisleri (GSEOM) ile özellikler çıkarılmıştır. Özellik sayısının fazla olması boyutun laneti (*The Curse of Dimensionality*) problemini ortaya çıkarmıştır. Bu nedenle özellik seçme işlemlerinden özellik derecelendirme yöntemine göre veriler en değerliden en değersize doğru derecelendirme yapılmıştır. Özellik derecelendirme yöntemine göre en iyi veriler sırası

ile birleştirilerek iki farklı kernel kullanan Destek Vektör Makinaları (DVM) ve 10 çapraz doğrulama ile verilerin sınıflandırma performansları analiz edilmiştir. AH MR görüntülerini sınıflandırma çalışmaları literatürde farklı veri sayısı ve demografik dağılımlarda yapılmaktadır. Yeni yapılan çalışmalarda farklı veri kümeleri olsa bile sınıflandırma karşılaştırmaları yapılmaktadır. Veri kümelerinin bütün popülasyonu temsil edip etmediğine dair kontroller genel olarak yapılmamaktadır. Tez çalışmasında *The Open Access Series of Imaging Studies* (OASIS) veri tabanından alınan MR görüntülerinin hem segmentasyon aşamasındaki veri bozulmalarının incelenmesi ile hem de veri kümesinin istatistiksel analizleri ile optimum veri kümesi belirlenmiştir. Eğitim ve test işlemleri veri tabanı üzerinden yapılarak en yüksek doğruluk oranlarını veren sınıflandırma sonuçları elde edilmiştir. En yüksek sınıflandırma doğruluğunu veren modeller ile Selçuk Üniversitesi Tıp Fakültesi Nöroloji ve Radyoloji Anabilim Dalları ile ortak alınan verilerde validasyon işlemi yapılmıştır. Son olarak 3B AH ve Normal Kontrol (NK) MR görüntüleri arasındaki tüm sınıflandırma değerlendirmeleri tablolar ve grafikler ile raporlanarak en iyi yöntemler ortaya konulmuştur. Şekil 1.1'de tez çalışmasında gerçeklenen aşamalar blok diyagram halinde verilmektedir.



Şekil 1.1. Tez çalışmasında gerçeklenen aşamaların blok diyagramı

Tez çalışması 3B beyin MR görüntülerinin sınıflandırılmasında yeni özellik kümelerinin ortaya konulması açısından önemlidir. Bu çalışma süresinde literatür yoğun bir şekilde incelenmiş ve literatürdeki eksiklikler üzerine yoğunlaşılmıştır. 3B beyin MR görüntülerinde farklı ve yeni özellik çıkarma yöntemleri ile etkin karar destek sistemleri geliştirilmiştir. Geliştirilen yöntem ve yaklaşımların daha büyük popülasyonlar ve diğer nörolojik hastalıklarla eğitilmesi erken safha teşhisler için önemlidir. Ülkemizde üç boyutlu MR görüntülerinin sayısal yöntemler kullanılarak analizi ile ilgili çok fazla çalışma olmadığından, tez çalışması ülkemizde yapılacak gelecek çalışmalar için iyi bir kaynak olacaktır.

1.2. Tezin Organizasyonu

Tezin birinci bölümü, tezin önemi ve amacını detaylı bir şekilde belirten giriş kısmından oluşmaktadır.

İkinci kısım kaynak araştırmasından oluşmaktadır.

Üçüncü bölümde Alzheimer hastalığı ve beyinde meydana getirdiği değişimler anlatılmıştır.

Dördüncü bölümde üç boyutlu yapısal beyin MR görüntüleme yöntemi, veri tabanları, MR görüntülerinde önişleme yöntemleri ve paket programlar anlatılmıştır.

Beşinci kısımda veri kümeleri, hacim hesaplama yöntemleri, simetri ve doku analizi yöntemleri, voksel tabanlı morfometri, özellik seçme ve sınıflandırma mimarileri anlatılmıştır.

Altıncı kısımda analiz ve sınıflandırma sonuçları tablo ve grafikler halinde verilmiş ve yorumlanmıştır.

Yedinci kısımda genel itibarıyla sonuçlar ve gelecek çalışmalar için öneriler verilmiştir.

2. KAYNAK ARAŞTIRMASI

3B yapısal MR görüntülerinden özellik çıkararak AH sınıflandırma çalışmaları ve karar destek sitemlerinin tasarlanması son zamanlarda çalışılan güncel konulardır. Tez çalışmasında MR görüntülerinde özellikle hacim, simetri ve doku analizi yöntemleri incelenmiştir. Bu üç özellik AH'nin beyinde meydana getirdiği temel değişimleri oluşturmaktadır. Bu kısımda literatürde sadece MR görüntülerinde üç boyutlu özellik çıkarma ve sınıflandırma işlemlerinin kullanıldığı çalışmalar derlenmiştir. 2B MR görüntüleri ile ilgili çalışmalar bulunmasına rağmen bu tezde 3B MR görüntüleri ele alındığı için bu çalışmalar kaynak araştırması kapsamına alınmamıştır.

Zhou ve ark. (2014), özel olarak elde ettikleri 129 AH ve 60 NK MR görüntüsünden *Freesurfer* programı ile çıkardığı 45 subkortikal hacim ve 10 morfometrik istatistik, 68 kortikal kalınlık ve 70 yüzey alan özelliklerine farklı normalizasyon tekniklerini uygulayarak, nöropsikolojik değerlerle beraber sınıflandırma performanslarını incelemiştir. İstatistiksel özellik seçme yöntemi ile beraber DVM ve beş kat çapraz geçerleme ile 50 kez koşturulmuş, doğruluk ortalamaları alınmıştır. Mini Mental Durum Testinin beraber kullanılması ile sınıflandırma performansının arttığı, subkortikal bölgelerin TBH ile normalize edilmesine gerek olmadığı, ancak kortikal kalınlıkların ortalama kortikal kalınlık veya TBH ile normalize edilmesi gerektiğini, yüzey alanlarının ise diğer iki özniteliğe göre çok az ayırıcı bilgiye sahip olduğu belirtilmiştir. Subkortikal hacim verileri ile Mini Mental Durum Testi skorlarının beraber kullanımının %92.3 doğruluk oranı ile en iyi sonucu verdiği belirlenmiştir (Zhou ve ark., 2014).

Zhang ve ark. (2011), *Alzheimer's Disease Neuroimaging Initiative* (ADNI) veri tabanından aldıkları 51 AH ve 52 NK deneklerde atlas tabanlı yöntem ile MR görüntülerinden 93, PET görüntülerinden 93 özellik ve BOS ile üç özellik olmak üzere toplam 189 özellik elde etmişlerdir. Lineer DVM ve on kat çapraz geçerleme ile 10 kez koşturularak sınıflandırma çalışması yapılmıştır. T-test ile özellik seçme yapılarak en ayırıcı özelliklerin belirlenmesi ile sınıflandırma doğruluğunun arttığı belirtilmiştir. Yapılan denemelerde MR, PET ve BOS özelliklerinin beraber kullanılmasının %93.2 gibi bir doğruluk oranı ürettiği saptanmıştır. Yapısal MR görüntüsünden tek başına kullanılan özellikler ile %86.2'lik bir doğruluk oranı elde edilmektedir. Tek bir modalitedeki özellik yerine farklı modalitedeki verilerin beraber kullanımının

sınıflandırma doğruluğunu arttıracağı bu çalışmanın ortaya koyduğu sonuçtur (Zhang ve ark., 2011).

Magnin ve ark. (2009), özel bir çalışma ile oluşturdukları 22 NK ve 16 AH MR görüntülerinden Tzourio-Mazoyer tarafından önerilen AAL atlas ile *Region of Interest* (ROI) bölgelerini bularak DVM ile sınıflandırma çalışması yapmışlardır. 116 ROI bölgesinin 26 bölgesini çalışmadan çıkararak 90 bölge ile sınıflandırma yapılmıştır. ROI bölgelerin t-test ile grupları en iyi ayıran bölgeler belirlenmiştir. Veriler %75 eğitim %25 test olarak ayırılarak 5000 defa sınıflandırıcı çalıştırılmış ve doğruluk oranının ortalaması alınmıştır. Önerilen model sonucunda %94.5 ortalama doğruluk oranı bulunmuştur (Magnin ve ark., 2009).

Klöppel ve ark. (2008), özel bir çalışma ile oluşturdukları 10 NK ve 10 AH, 14 NK ve 14 AH, 57 NK ve 33 AH olmak üzere üç farklı grup oluşturarak DVM ile sınıflandırma çalışması yapmıştır. MR görüntülerinde SPM5 programı ile GM, BM, BOS segmentasyonu yapılmıştır. GM özellikleri kullanılarak birini dışarda bırak (*leave –one-out*) yöntemi ile veriler lineer DVM ile sınıflandırılmıştır. İşlem sonucunda birinci grupta %95, ikinci grupta %92.9, üçüncü grupta %81.1 sınıflandırma doğruluğu elde edilmiştir (Klöppel ve ark., 2008).

Walhovd ve ark. (2010), ADNI veri tabanından oluşturdukları 42 AH ve 38 NK MR görüntü gruplarından hipokampus*, entorhinal, parahipokampal, retrosplenial, precuneus, inferior parietal, supramarginal, middle temporal, lateral, medial orbitofrontal cortices* bölgelerini VOI olarak kullanmış, bu bölgelerden hacim ve kalınlık değerleri elde etmişlerdir. Lojistik regresyon analizi ile yapılan sınıflandırma çalışmasında %82.5 sınıflandırma doğruluk değeri bulunmuştur (Walhovd ve ark., 2010).

Cuingnet ve ark. (2011), ADNI veri tabanından oluşturdukları 162 AH ve 137 NK MR görüntü gruplarından beş voksel tabanlı, üç kortikal kalınlık tabanlı metot ve iki hipokampus tabanlı metot olmak üzere on metot ile sınıflandırma karşılaştırmaları yapmıştır. Çalışmada gauss kernel DVM, lineer DVM ve lojistik regresyon sınıflandırıcıları kullanılmıştır. İki kat çapraz geçerlemenin kullanıldığı çalışmada, AH ve NK sınıflandırma karşılaştırmaları için voksel tabanlı ve kortikal tabanlı metotların %85 duyarlılık %95 seçicilik olmak üzere hassasiyeti arttırdığı belirtilmiş, direkt olarak sınıflandırma doğruluk oranları verilmemiştir (Cuingnet ve ark., 2011).

Fan ve ark. (2008), ADNI veri tabanından oluşturdukları 66 AH ve 56 NK MR görüntü gruplarından iki farklı yaklaşımla özellik çıkarmışlardır. Hipokampus ve

entorhinal korteks tabanlı ROI ve voksel tabanlı yöntemler ile elde edilen özellikler çapraz geçerleme ile DVM sınıflandırıcısına verilmiştir. Özyinelemeli özellik eliminasyon yöntemi (*Recursive Feature Elimination*) ile özellik seçme işlemi yapılmıştır. Sınıflandırma işlemi sonucunda ROI tabanlı yöntemlerle %82.0, voksel tabanlı yöntemlerle %94.3 doğruluk oranı elde edilmiştir (Fan ve ark., 2008).

Westman ve ark. (2011), ADNI veri tabanından oluşturdukları 100 NK ve 100 AH MR görüntü gruplarından Montreal Nöroloji Enstitüsü'nün oluşturduğu modeller ile segmentasyon ve bölgesel parselasyon işlemi yapmışlardır. OPLS (*Orthogonal Partial Squares to Latent Structures*) ile çoklu değişken ve çoklu ölçekler kullanılarak yapılan sınıflandırma işleminde %92 oranında sınıflandırma doğruluğu elde edilmiştir (Westman ve ark., 2011b).

Beheshti ve ark. (2016), ADNI veri tabanından oluşturdukları 130 NK ve 130 AH MR görüntü gruplarından GM kayıp hacim bölgelerini voksel tabanlı morfometri yöntemi ile bulmuşlardır. Kayıp maskeler ile GM görüntüler çarpılarak sadece ilgilenen bölgelerdeki hacimsel kısmı kesmişlerdir. Bu bölgelerdeki voksel değerlerini DVM sınıflayıcısına ham olarak vermeden önce yedi farklı özellik derecelendirme yöntemi ile verileri derecelendirerek özellik seçme işlemi yapılmıştır. Optimum büyüklükteki veri boyutunu bulmak için sınıflandırma hata oranı kullanılmış, on kat çapraz geçerleme ile sınıflandırma denemeleri yapılmıştır. Önerilen otomatik sınıflandırma sistemi ile %92.48 sınıflandırma oranı bulunmuştur (Beheshti ve ark., 2016a).

Aguilar ve ark. (2013), ADNI veri tabanından oluşturdukları 116 AH ve 110 HK MR görüntü gruplarında *Freesurfer* programı ile özellik çıkarma işlemi yapmışlardır. 10 çapraz geçerleme yöntemi ile OPLS, karar ağaçları, yapay sinir ağları, DVM olmak üzere dört faklı sınıflandırıcı ile denemeler yapılmıştır. DVM ve OPLS'nin diğer iki sınıflandırıcıya göre biraz daha üstün değerler verdiği belirtilmiştir. Gerçeklenen denemeler sonucunda %84.9 sınıflandırma doğruluğu elde edilmiştir (Aguilar ve ark., 2013).

Querbes ve ark. (2009), ADNI veri tabanından oluşturdukları 130 NK ve 130 AH MR görüntü gruplarında kortikal kalınlık ve normalize kalınlık indeksini hesaplamışlardır. Bu verilerin normal hasta ayrımındaki güçleri ROC (*Receiver Operating Characteristic*) yöntemi ile belirlenmiştir. On kat çapraz geçerleme ve karar ağacının kullanıldığı sınıflandırma denemelerinde %85 sınıflandırma doğruluğu bulunmuştur (Querbes ve ark., 2009).

Khedher ve ark. (2015), ADNI veri tabanından oluşturdukları 188 AH ve 229 NK MR görüntü gruplarından gri madde, beyaz madde segmentasyon işlemini yaptıktan sonra bu görüntüler üzerinden iki farklı metot ile özellik seçme işlemi yapmışlardır. Temel bileşen analizi ve parçalı en az kareler metodu ile yapılan özellik çıkarma işleminden sonra lineer ve radyal tabanlı fonksiyon kernellerini kullanarak DVM ile sınıflandırma işlemi yapmışlardır. On kat çapraz geçerleme ile yapılan sınıflandırma denemelerinde %88.49 sınıflandırma doğruluk oranı bulunduğu belirtilmiştir. Parçalı en az kareler metodu ile yapılan özellik çıkarma işleminin daha ayırıcı özellikler verdiği belirtilmiştir (Khedher ve ark., 2015b).

Westman ve ark. (2012), ADNI veri tabanından oluşturdukları 96 AH ve 111 NK MR görüntü gruplarından *Freesurfer* ile subkortikal bölge hacimleri ve kortikal kalınlık değerlerini elde etmişlerdir. Bu değerlerden 57 MR özelliğini ve veri tabanından Aβ42, t-tau ve p-tau olmak üzere üç adet beyin omurilik sıvısı özelliğini sınıflandırıcı için kullanmışlardır. Özellik seçme işleminin kullanılmadığı çalışmada on çapraz geçerleme ile OLPS sınıflandırma metodu kullanılmıştır. Denemeler sonucunda %87.0 sınıflandırma doğruluğu bulunmuştur. Subkortikal bölge hacimleri, kortikal kalınlıklar ve beyin omurilik sıvısı özelliklerinin sınıflandırma işleminde beraber kullanılmasının ayırıcı tanıda etkili bir çözüm olduğu önerilmiştir (Westman ve ark., 2012).

Beheshti ve ark. (2015), ADNI veri tabanından oluşturdukları 130 NK ve 130 AH MR görüntü grupları arasındaki hacimsel farklılıkları voksel tabanlı morfometri yöntemi ile belirlemişlerdir. Hacimsel farklılık maskesi kullanılarak gri madde görüntülerde ilgili bölgelerin segmentasyonu yapılmıştır. Bu işlemden sonra özellik seçme ve azaltma için olasılık dağılım fonksiyonu kullanarak yeni bir özellik seçme işlemi önermişlerdir. Diğer özellik seçme yöntemleri ile karşılaştırılarak on kat çapraz geçerleme ile DVM sınıflandırıcısı kullanılmıştır. Yapılan sınıflandırma denemelerinden sonra %89.65 doğruluk oranı bulunarak yeni önerilen olasılık dağılım fonksiyonu tabanlı özellik seçme yönteminin literatürdeki diğer yöntemlerle yarışabilecek seviyede olduğu önerilmektedir (Beheshti ve ark., 2015).

Papakostas ve ark. (2015), OASIS veri tabanından oluşturdukları 49 AH ve 49 NK MR görüntü gruplarından voksel tabanlı morfometri ve deformasyon tabanlı morfometri olmak üzere iki farklı yöntem ile özellik çıkarma işlemi yapmışlardır. *Lattice Computing* tabanlı kNN (*k-Nearest Neighbors*) sınıflayıcısı ile özellik seçme tabanlı bir yöntem önererek on kat çapraz geçerleme ile sınıflandırma çalışması

yapmışlardır. Farklı DVM sınıflandırıcıları ile önerilen yöntemler karşılaştırılmış, önerilen hibrid sınıflandırma yönteminin literatürdeki diğer sınıflandırma yöntemlere göre yarışabilir sonuçlar verdiği belirtilmiştir. Gerçeklenen denemeler sonucunda %85 doğruluk oranı bulunmuştur (Papakostas ve ark., 2015).

Khedher ve ark. (2015), ADNI veri tabanından oluşturdukları 229 NK ve 188 AH MR görüntülerini SPM8 programı altında çalışan VBM8 programı ile gri madde, beyaz madde ve beyin omurilik sıvısı olarak segmente etmişlerdir. Gri madde, beyaz madde ve gri madde+beyaz madde görüntülerden bağımsız bileşen analizi ile özellik çıkarma işlemi yapmışlardır. DVM ile yapılan sınıflandırma işleminde lineer kernel ile GM+BM görüntüler %86.7 sınıflandırma doğruluğu vermiştir (Khedher ve ark., 2015a).

Yang ve ark. (2010), ADNI veri tabanından oluşturdukları MR görüntü gruplarında SPM programı ile GM, BM, BOS görüntülerin segmentasyonunu yapmışlardır. Bu görüntülerden GM görüntülere bağımsız bileşen analizi uygulamışlardır. Yapılan sınıflandırma denemelerinde %88.9 sınıflandırma doğruluğu elde edilmiştir (Yang ve ark., 2010).

Oliveria ve ark. (2011), özel bir çalışma ile elde ettikleri 16 AH ve 16 NK MR görüntülerinde korpus kollosum ve thalamus bölgelerini segmente ederek bu bölgelerin doku analizi farklılıklarına bakmışlardır. *Corpus collosum* ve *thalamus* bölgeleri uzman bir doktor tarafından bölütlenmiştir. Gri seviye eş oluşum matrislerinin kullanıldığı çalışmada MAZDA isimli bir doku analizi programı ile her iki bölgeden 44 doku parametresi çıkarılmıştır. SYSTAT istatistiksel analiz programı ile ilgili bölgelerden elde edilen doku parametreleri Mann-Whitney U testi ile analiz edilerek, gruplar arası anlamlı bir fark olup olmadığı araştırılmıştır. Herhangi bir sınıflandırma sonucunun olmadığı çalışmada doku analizi yönteminin doku farklılıklarını ayırmada anlamlı sonuçlar verdiği belirtilmiştir (De Oliveira ve ark., 2011).

Rajeesh ve ark. (2012), ADNI veri tabanından oluşturdukları 146 NK ve 133 AH MR görüntü gruplarında yazar tarafından önerilen yarı otomatik bir sistemle hipokampus bölgelerinin segmentasyon işlemi yapılmıştır. Bu bölgelerden gri seviye eş oluşum matrisleri ile 56 özellik çıkarılmıştır. Temel bileşen analizi ile yapılan özellik seçme işleminden sonra özellikler DVM ile sınıflandırılmıştır. Çalışma sonucunda %93.6 sınıflandırma sonucu elde edildiği belirtilmektedir. Hipokampus bölgesi AH'de en çok etkilenen bölge olduğu için bu bölgenin dokusal özelliklerinin AH ve NK ayırımında ayırıcı özellik olduğu önerilmektedir (Rajeesh ve ark., 2012).

Mahanand ve ark. (2012), OASIS veri tabanından oluşturdukları 30 AH ve 30 NK MR görüntü gruplarından voksel tabanlı morfometri yöntemi ile 5788 özellik çıkarmışlardır. Çıkarılan özelliklere integer kodlu genetik algoritma ile özellik azaltma işlemi uygulamışlardır. Bu veriler makalede yeni bir sınıflandırıcı olarak sunulan *Self-Adaptive Resource Allocation Network* sınıflandırıcı ile sınıflandırılarak sonuçlar DVM ve aşırı öğrenme makinaları ile karşılaştırılmıştır. Önerilen sınıflandırıcının DVM ve aşırı öğrenme makinalarından daha iyi sonuçlar verdiği belirtilmiştir. On özellik ile %92.13 ortalama sonuç veren sınıflandırıcı özelliklerinden parahipokampal girus ve amigdala bölgelerinin erken başlangıçlı AH için iyi bir ayırıcı olduğu belirtilmiştir (Mahanand ve ark., 2012).

Mesrob ve ark. (2008), özel olarak elde ettikleri 33 AH ve 28 NK MR görüntülerini AAL kullanarak beyin bölgelerini MR görüntüleri üzerinde parsellemişlerdir. Uzaysal normalizasyon ve segmentasyon işlemleri SPM2 programı ile yapılmıştır. 16 AH ve 15 NK MR görüntüsü eğitim, 17 AH ve 13 NK MR görüntüsü test için kullanılmıştır. DVM ile beraber kullanılan özyinelemeli özellik eliminasyon yöntemi ile özellik seçme işlemi yapılmıştır. Radyal tabanlı fonksiyon kullanılarak yapılan sınıflandırma çalışmasında %90 oranında sınıflandırma doğruluğu bulunduğu belirtilmiştir (Mesrob ve ark., 2008).

Savio ve ark. (2009), OASIS veri tabanından oluşturdukları 49 AH ve 49 NK MR görüntü gruplarından voksel tabanlı morfometri ile hacimsel kayıp olan bölgeleri bulmuşlardır. Gri madde üzerindeki bu bölgelerin voksel kümeleri belirlenerek üç farklı özellik çıkarma işlemi yapılmıştır. Görüntüler üzerindeki gerekli önişlemeler ve segmentasyon SPM5 programı ile yapılmıştır. On kat çapraz geçerleme ile kullanılan DVM ve adaboost-DVM sınıflandırıcı performansları karşılaştırılmıştır. Adaboost tabanlı yöntemle %85 doğruluk oranı belirtilmiştir (Savio ve ark., 2009).

Savio ve ark. (2013), OASIS veri tabanından aldıkları 416 MR görüntülerinden deformasyon tabanlı morfometri ile özellik çıkarma işlemi yapmışlardır. Pearson korelasyon, Bhattacharry test ve Welch t-test olmak üzere üç farklı özellik seçme işlemi kullanılmıştır. DVM ve on çapraz geçerleme ile yapılan sınıflandırma sonucunda Welch t-test ile yapılan özellik seçme tabanlı model %92.83 sınıflandırma doğruluğu vermiştir (Savio ve GrañA, 2013a).

Wolz ve ark. (2011), ADNI veri tabanından oluşturdukları 231 NK ve 198 AH MR görüntü gruplarından hipokampal hacim, tensör tabanlı morfometri, kortikal kalınlıklar ve manifold öğrenme tabanlı yöntemlerle özellik çıkarma işlemi

yapmışlardır. Sınıflandırma karşılaştırmaları lineer diskriminant analiz ve DVM ile yapılmıştır. Özellik birleştirerek yapılan sınıflandırma denemelerinin daha yüksek sonuçlar verdiği belirtilmiştir. Sınıflandırma işlemi sonucunda en yüksek değerler %90 hassasiyet ve %85 seçicilik olarak belirtilmiş, sınıflandırma doğruluk oranı yerine farklı metrikler kullanılmıştır (Wolz ve ark., 2011).

Koikkalainen ve ark. (2012), ADNI veri tabanından oluşturdukları 217 NK ve 191 AH MR görüntü grupları üzerinden analiz gerçekleştirmişlerdir. ADNI veri tabanında üç binden fazla özellik olduğu bunlardan sadece dokuzunun çalışmada kullanıldığı belirtilmiştir. Çalışmadaki temel amaç yaş ve cinsiyet gibi AH'de test sonuçlarını ve biyoişaretçilerin teşhis gücünü etkileyen problemli değerlerin (*nuisance variable*) sınıflandırmaya nasıl bir etkisinin olduğunun araştırılmasıdır. Sınıflandırma verileri ve problemli veriler arasında dört farklı etkileşim tanımlanmış, üç metot bu etkileşimi kaldırmak için denenmiştir. Bu yöntemlerle problemli verilerin veri setinden eliminasyonunun sınıflandırma doğruluğunu arttırdığı belirtilmiştir (Koikkalainen ve ark., 2012).

Cheng ve ark. (2013), ADNI veri tabanından oluşturdukları 198 AH ve 229 NK MR görüntü grupları üzerinde özellikler çıkarıldıktan sonra çantalama yöntemine dayanan yeni bir topluluk tabanlı özellik seçme yöntemi uygulamışlardır. Görüntüler üzerinde normalizasyon, inhomojenite giderme, BSE (*Brain Surface Extractor*) ve BET (*Brain Extraction Tool*) yöntemleri ile beyin dışı yapıların atılması olarak önişlemeler yapılmıştır. FSL programının FAST özelliği ile görüntüler GM, BM, BOS olarak ayrılmıştır. HAMMER ile bölütlenen görüntüler üzerinde 93 bölge etiketlenmiştir. Özellikler üzerinde DVM, DVM+SLR (*Sparse Logistic Regression*), DVM +ESLR (*Ensemble feature selection based Sparse Logistic Regression*) yöntemleri uygulanarak karşılaştırmalar yapılmıştır. DVM +SLR %1.7 sınıflandırma doğruluğunu arttırırken, DVM +ESLR %6.7 doğruluk arttırılmıştır. On kat çapraz geçerlemenin kullanıldığı çalışmada LIBSVM aracı kullanılmıştır. Özellik seçme yöntemlerinin MR gibi yüksek boyutlu verilerin sınıflandırılmasında etkili olduğu belirtilmiştir (Cheng ve Jie, 2013).

Mahmood ve ark. (2013), OASIS veri tabanından aldıkları tüm MR görüntülerinden talairach eksenine çakıştırılmış yeni görüntülerin en ortadaki kesitlerini alarak *N*1* vektörler haline getirmişlerdir. Tüm görüntülerin *N*1*'lik dönüşmüş durumları ile bir matris oluşturulmuştur. Temel bileşen analizi yöntemi ile 150 veriye dönüştürülen yüksek boyuttaki veri seti yapay sinir ağları ile dört farklı evre için

sınıflandırılmıştır. Yapılan denemeler sonucunda %89.22 sınıflandırma oranı bulunmuştur (Mahmood ve Ghimire, 2013).

Jha ve ark. (2017), OASIS veri tabanından oluşturdukları 28 AH ve 98 NK MR görüntü gruplarından çift ağaç kompleks ayrık dalgacık dönüşümü ile özellik çıkarma işlemi yapmışlardır. Üç boyutlu MR görüntülerinden merkezi 32 kesit alınarak işlemler yapılmıştır. Özellik azaltma işlemini temel bileşen analizi ile yaparak veriler ileri beslemeli yapay sinir ağları ile sınıflandırılmıştır. On kat çapraz geçerleme ile yapılan sınıflandırma denemelerinde %90.06 doğruluk oranı bulunmuştur (Jha ve ark., 2017).

Wang ve ark. (2015), OASIS veri tabanından oluşturdukları 97 NK, 57 Hafif Bilişsel Bozulma ve 24 AH MR görüntü gruplarından iki boyutlu ve üç boyutlu dalgacık dönüşümleri kullanarak alt bantlardan özellik çıkarma işlemi yapmıştır. Db2 dalgacığı ile yapılan dönüşümlerde alt bantların enerji ve entropi değerleri elde edilmiştir. DVM ile yapılan sınıflandırma çalışmalarında üç boyutlu dalgacık dönüşümünün iki boyutlu dalgacık dönüşümüne göre daha yüksek sonuçlar verdiği belirtilmiştir (WANG ve ark., 2015).

Aggarwal ve ark. (2015), OASIS veri tabanından oluşturdukları üç farklı grup ile (99AH-99NK, 49AH-49NK, 30AH-30NK) MR görüntülerden gri madde normalizas-yonu ve segmentasyonu gerçekleştirerek bu görüntüler üzerinde yumuşatma işlemi yapmışlardır. Yumuşatılan görüntülerde WFU PickAtlas kullanılarak AH'de en çok etkilendiği düşünülen hipokampus, amigdala, lateral ventrikül, anterior cingulate, posterior cingulate bölgeleri VOI olarak seçilmiş, bu bölgelerde 3B dalgacık dönüşümü ile detay katsayıları özellik olarak çıkarılmıştır. Çok fazla detay katsayısı olduğu için fisher diskriminant oranı ve *Minumum Redundancy Maxiumum Relevance* özellik seçme yöntemleri uygulamışlardır. Coif, db, bior ve sym dalgacık türlerinin kullanıldığı çalışmada özellik seçme uygulanmış veriler DVM, kNN ve C4.5. karar ağacı olmak üzere üç farklı sınıflandırıcı ile sınıflandırma performansları incelenmiştir. Üç boyutlu dalgacık dönüşümünün ve öncül bilginin kullanılmasının literatürde var olan yöntemlere göre verimli sonuçlar ürettiği belirtilmiştir (Aggarwal ve ark., 2015a).

Wang ve ark. (2016), OASIS veri tabanından aldıkları 28AH ve 98 HK MR görüntülerinden sınıflar arası varyans kuralına göre her bir üç boyutlu MR görüntüsünden bir tane kesit alarak özellik çıkarma işlemini bu kesit üzerinden yapmışlardır. Dalgacık dönüşümü ile elde edilen yedi alt bant katsayılarının entropi değerini bularak her bir görüntü için yedi adet özellik vektörü oluşturmuşlardır. Biyocoğrafya tabanlı bir optimizasyon algoritması ile beraber yapay sinir ağları

kullanarak verileri sınıflandırmışlardır. Yapılan denemeler sonucunda %92.40 sınıflandırma doğruluk oranı elde edilmiştir. Önerdikleri yöntemin diğer yöntemlerden daha etkili sonuçlar verdiği vurgulamıştır (Wang ve ark., 2016).

Aggarwal ve ark. (2015), OASIS veri tabanından oluşturdukları üç farklı veri seti ile daha önceki çalışmasında yapmış oldukları önişleme metodunu takip etmiştir. Segmente edilip yumuşatılan görüntülerden hipokampus, amigdala, lateral ventrikül, anterior cingulate, posterior cingulate bölgeleri VOI olarak seçilerek bu bölgelerden çift ağaç üç boyutlu wavelet ile özellik çıkarma işlemi yapmışlardır. Fisher discriminat oranı ve *Minumum Redundancy Maxiumum Relevance* ile özellik seçme işlemi uygulanarak sınıflandırıcılar için uygun veri seti elde edilmiştir. Sınıflandırıcı olarak lineer DVM, kNN, C4.5 karar ağacı ve *Levenberg-Marquard* yapay sinir ağı kullanmışlardır. Önerilen AH-NK sınıflandırmasında verimli sonuçlar elde edildiği belirtilmiştir (Aggarwal ve ark., 2015b).

Zhang ve ark. (2015), OASIS veri tabanından oluşturdukları 28 AH ve 98 NK MR görüntü gruplarından deplasman alanları kullanarak özellik çıkarma işlemi yapmışlardır. Temel bileşen analizi ile veri azaltma yapılarak üç farklı sınıflandırıcı ile sınıflandırma performansı ölçülmüştür. On çapraz geçerleme ve elli defa modelin koşturulması sonucu DVM, *Eigenvalue Proximal* DVM ve *Twin* DVM ile sınıflandırma performansları karşılaştırılmıştır. Yapılan denemeler sonucunda *Twin* DVM ile yapılan sınıflandırma %92.75 ile en yüksek doğruluk oranını vermiştir (Zhang ve Wang, 2015).

Chaddad ve ark. (2016), OASIS veri tabanından oluşturdukları 62 AH ve 62 NK MR görüntü grupları üzerinden üç boyutlu gri seviye eş oluşum matrisi, üç boyutlu dalgacık dönüşümü ve LoG filtreler ile özellik çıkarma işlemi yapmışlardır. Özellikler on kat çapraz geçerleme ile rastgele orman (*random forest*) yöntemi ile sınıflandırılmışlardır. Sınıflandırma sonuçlarının %70 üzeri çıkmasından dolayı kullanılan yöntemlerin verimli olduğunu belirtmişlerdir (Chaddad ve ark., 2016).

Svapriya (2011), yapmış olduğu çalışmada OASIS veri tabanından aldığı görüntülerde gabor filtre ve gri seviye eş oluşum matrisleri ile özellik çıkarma işlemi yapmışlardır. Temel bileşen analizi ve dalgacık yöntemi özellik azaltma için kullanılmıştır. DVM sınıflandırıcısının kullanıldığı çalışmada optimum DVM parametrelerinin bulunabilmesi için genetik algoritmalar ve parçacık sürü optimizasyonunu kullanılmıştır. Önerilen modelin sınıflandırma doğruluğunu arttırdığı ve hesaplama süresini azalttığı belirtilmiştir (Svapriya, 2011).

Arunadevi ve Deepa (2013), tümörlü MR görüntülerinde 3B Gri Seviye Eş Oluşum Matrisleri ve 3B Gabor Filtreler ile özellik çıkarma işlemi yapmışlardır. Genetik algoritma tabanlı özellik seçme yöntemi kullanılarak DVM ve Aşırı Öğrenme Makinaları ile doğruluk oranları karşılaştırılmıştır. Özellik seçme tabanlı 3B Gri Seviye Eş Oluşum Matrisi sınıflandırma sonuçlarının 3B doku sınıflandırmada etkili sonuçlar verdiği belirtilmiştir (Arunadevia ve Deepa, 2013).

Aggarwal ve ark. (2013), OASIS veri tabanından oluşturdukları 49 NK ve 49 AH MR görüntü gruplarını öncelikle BET aracından geçirerek beyin dışı yapıları atmışlardır. MR kesitlerinden birinci ve ikinci dereceden istatistikler çıkarılarak her MR görüntüsü için özelliklerin ortalamaları alınmıştır. Bu özellikler ile DVM, C4.5, lineer diskriminant sınıflandırıcı, *levenberg-marquard* yapay sinir ağı sınıflandırıcı kullanılarak doğruluk oranları karşılaştırılmıştır. On kat çapraz geçerleme yöntemi kullanılarak algoritmalar on kez çalıştırılmıştır. Bu yöntemlerin voksel tabanlı morfometri ile yapılan sınıflandırma sonuçlarına göre daha iyi sonuç verdiği belirtilmiştir (Aggarwal ve ark., 2013).

Saraswathi ve ark. (2013), OASIS veri tabanından oluşturdukları 98 NK, 70 Hafif Bilişsel Bozulma ve 30 AH MR görüntü gruplarından voksel tabanlı morfometri tabanlı özellik çıkarma yöntemi ile farklı sınıflandırma modelleri önermişlerdir. Voksel tabanlı morfometri ile üretilen yüksek boyutlu veri genetik algoritmalar ile özellik azaltma işlemine tabi tutulmuştur. Aşırı öğrenme makinalarının parametreleri parçacık sürü optimizasyonu ile optimize edilerek genetik algoritma özellik seçme tabanlı bir hibrid sınıflandırıcı modellenmiştir. Çoklu sınıf problemi için yapılan denemelerde %87.23 test ortalaması elde edilmiş, yöntemin hastalığı ayırmasında etkili bir model olduğu belirtilmiştir (Saraswathi ve ark., 2013).

Ding ve ark. (2015), ADNI veri tabanından oluşturdukları 54 AH ve 58 NK MR görüntü gruplarından voksel tabanlı morfometri ve doku analizi tabanlı sınıflandırılması için bir çerçeve model önermişlerdir. Denemeler özyinelemeli tabanlı DVM ile yapılmıştır. Denemeler sonucunda doku analizi ve voksel tabanlı morfometri ile elde edilen özelliklerin beraber kullanımının her özelliğin tek başına kullanılmasından daha iyi sonuç verdiği belirtilmiştir (Ding ve ark., 2015).

Mahanand ve ark. (2015), OASIS veri tabanından oluşturdukları 100 AH ve 98 NK MR görüntü gruplarından voksel tabanlı morfometri yöntemi kullanılarak özellik çıkarma işlemi gerçekleştirmişlerdir. Özelliklerin sınıflandırılması için *Meta-cognitive Radial Basis Function Network* (McRBFN) tabanlı hibrid bir sınıflandırma modeli

önerilmiştir. Özellik seçme yöntemi hibrid modele eklenerek Özyinelemeli özellik eliminasyonu tabanlı *Projection Based Learning* (McRBFN) isimli bir çerçeve model önerilmiştir. Önerilen modelin açık bir şekilde AH tanısında iyi sonuç verdiği belirtilmiştir. Sınıflandırma mekanizmasında insula bölgesinin AH erken tanıdan sorumlu bölge olabileceği iddia edilmektedir (Mahanand ve ark., 2015).

Derlenen çalışmalarda görüldüğü gibi 3B beyin MR görüntülerinde AH ve NK sınıflandırma çalışmaları farklı veri sayılarında olduğu gibi farklı veri tabanlarından da olmaktadır. Veri sayıları ve demografik yapılar belli standartlarda olmadığı için çalışma sonuçlarının birbiri ile karşılaştırılması göreceli olmaktadır. Bir diğer göze çarpan farklılık bazen üç boyutlu görüntünün tümünde, bazen VOI bölgelerde veya bazen belli kesitlerde yapılan özellik çıkarma çalışmalarıdır. Görüntüleri tek bir kesit üzerinden analiz etmeyerek üç boyutlu görüntünün tümüne ve sadece üç boyutlu VOI bölgesine bakmak daha güvenilir sonuçlar verecektir. Ancak belli kesitlerde yapılan çalışmalarda hastalığın etkilediği düşünülen kesitler yazar tarafından belirlenmekte, kesit belirleme için bir metot kullanılmamaktadır. Bu işlem de çalışmaları göreceli yapmaktadır. Tez çalışmasında bu problem voksel tabanlı morfometri ile giderilerek önerilen bir model ile ilgili kesit aralığı belirlenmektedir. Kesit aralıklarının belirlenmesi ile beraber kesitlerde VTM binary maskeleri ile maskelenmiş bölgelerden doku özellikleri elde edilmiştir. VTM ile gruplar arasındaki hacimsel kayıpların net bölge sınırları bulunduktan sonra 3B ayrık dalgacık dönüşümü ve 3B GSEOM doku analizi yöntemleri ile özellik çıkarma işlemi bu tez çalışması ile literatürde ilk defa tanımlanacaktır. Tez çalışmasında hacim analizleri için kümülatif ve VOI yaklaşımlar, simetri özellikleri için kümülatif yaklaşımlar, doku analizi için VTM tabanlı VOI yaklaşımlar kullanılarak literatüre yeni yaklaşımlar önerilmektedir. Aynı zamanda veri kümesi oluştururken veri yaş dağılımının normal dağılıma uyup uymadığı kontrol edilerek veri kümesinin popülasyonu temsil edip etmediği test edilmiştir.

3. ALZHEİMER HASTALIĞI

Alzheimer Hastalığı (AH) yaşlılıkla beraber başlayan, ilerledikçe beyinde hacimsel kayıplar meydana getiren ve son evrelerinde hastanın günlük sıradan işlerini dahi yapabilmesine izin vermeyen nörolojik bir hastalıktır. AH ilk defa 1906 yılında hastalığa ismini veren Alois Alzheimer isimli Alman bir nöropatolog tarafından ölen bir kadının beyin otopsisindeki doku değişikliklerini fark etmesi ile tanımlanmıştır. Hastalığın ilk belirtileri basit ve masum unutkanlıklar ile başlar. İleri evrelerde unutkanlığın şiddeti daha da artar. Hastalığın nedeni bilinmediği gibi hastalığı durduran bilinen bir tedavisi de yoktur. Ancak hastalık erken safhada teşhis edilebilirse hastalığı yavaşlatan ve hastalığın bulunduğu evreyi uzatabilen birtakım tedaviler mevcuttur. Klinikte görülen tüm demans vakalarının %50-80'inini AH'nin oluşturduğu belirtilmektedir. AH dünyada en sık ölüm nedenleri arasında sayılmaktadır (Selekler, 2010). 2000 ve 2010 yılları arasında kalp hastalıkları, göğüs kanseri, prostat kanseri, inme ve HIV ölüm oranları sırasıyla yüzde 16, 2, 8, 23 ve 42 oranında azalırken, AH şaşırtıcı bir şekilde %68 oranında artmıştır (Association, 2013b). Dünyada yaşlı nüfusun artması ile beraber, gelişen ve gelişmekte olan ülkelerde, hastalığın bakım ve tedavi masrafları, sosyolojik çıktıları ve ülkelere getirdiği ekonomik yükü büyük etkiler oluşturacağı belirtilmektedir (Ferri ve ark., 2006; Association, 2013a).

Türkiye'de AH ve diğer demanslar ile alakalı yapılan çalışmalar yeterli düzeyde değildir. Gürvit ve ark. (2008), İstanbul Kadıköy ilçesinde gerçekleştirdikleri prevelans çalışmasına göre 70 yaş üzeri prevelansın %11 olduğunu belirtmişlerdir. Bu sonuca göre 2008 yılında ülkemizde yaklaşık 250-300 bin AH olduğu tahmin edilmektedir (Bıyıklı ve Şanlıer; Gurvit ve ark., 2008). Türkiye Alzheimer Derneği'nin güncel değerlendirmesine göre ülkemizde yaklaşık 600 bin aile AH ile mücadele etmektedir (Anonim, 2017d). Bu değerlendirmelere göre AH 10 yılda yaklaşık iki kat artmıştır. Türkiye İstatistik Kurumu verilerine göre 2023 yılında Türkiye'de 65 yaş üstü yaşlı oranının toplam nüfusun %10'u olacağı belirtilmektedir (Anonim, 2017c). Yaşlı nüfusun artması ile beraber AH riski de artacaktır. Bundan dolayı AH ileri dönemlerde ülkemize tanı ve tedavi masraflarının artışı ile beraber, sosyolojik olarak ciddi problemler ortaya çıkaracaktır. Dünyada ve ülkemizde yaşlı nüfusun artması ile beraber hastalığın paralel bir şekilde artması yapılan çalışmaların güncelliğini korumaktadır. Hastalığın erken safha teşhisi, sosyolojik ve ekonomik çıktıları, hasta yakınlarına dönük eğitim metotları, hasta hayatını idame ettirebilecek eğitim metotları gibi çalışmalar halen güncelliğini

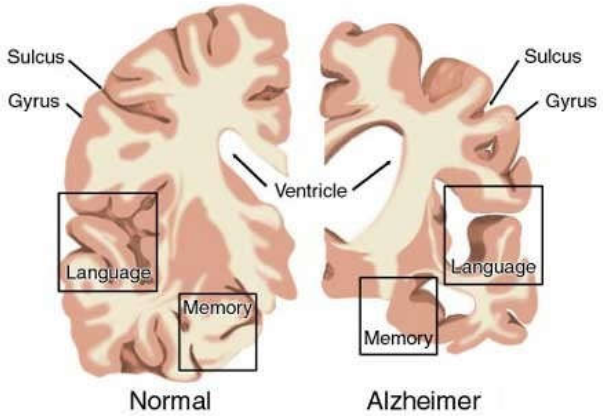
korumaktadır. AH ile ilgili ülkemizde farkındalık oluşturmak için Ulusal Alzheimer Kongresi yapılmakta ve Türkiye Alzheimer Derneği hasta ve hasta yakınları için çalışmalarını sürdürmektedir.

AH basit unutkanlıklarla başladığı için ilk dejenerasyonlar hafıza ile ilgili bölgelerde başlar. Basit unutkanlıklar, kelime bulamama, kişilik bozuklukları, uzak ve yakın hafızanın zayıflaması, yakınlarını tanıyamama, sezgisel bozukluklar ve günlük işlevlerde aksama belli başlı problemlerden bazılarıdır. Evreler ilerledikçe dejenerasyon diğer beyin bölgelerine doğru yayılır. En son evrede birçok fonksiyonel bölge dejenerasyona uğradığından hasta kendi günlük işlerini dahi yapamaz duruma gelerek bir bakıcının ilgilenmesine muhtaç hale gelmektedir (Celsis, 2000). AH'nin erken safha teşhisi kişinin ileri dönem hayat standartlarının iyileştirilmesi için önemli bir basamaktır. Hastalığın bilinen bir tedavisi yoktur. Ancak erken safha teşhiste evre aralıklarını uzatan birtakım tedaviler mevcuttur. Böylece hasta ve hasta yakınları bu tedavilerle belli bir süre ileri evrelerin problemlerinden kurtulabilirler. Ancak AH'de erken evre teşhisi başlıca bir problemdir. Kişi basit unutkanlık şikayeti ile hastaneye geldiği zaman hemen AH teşhisi konulamamaktadır. AH klinik olarak sinsi bir şekilde ilerlediğinden dolayı belirtileri bir süre diğer demans nedenleri ve psikolojik rahatsızlıklar ile benzerlik gösterir. Bundan dolayı basit unutkanlık nedenleri olan karaciğer fonksiyonel eksikliği, B12 eksikliği, tiroit bozuklukları gibi basit demans nedenleri dışlanmaya çalışılır. Bu eksiklik ve bozulmalar incelendikten sonra görüntüleme yöntemleri ile beraber diğer ileri düzey tetkikler yapılarak araştırmalar derinleştirilir. Parkinson, Huntington Demans, Frontotemporal Demans, Lewy Cisimcikli Demans gibi yine başlangıç belirteçleri belli bir süre paralel seyreden hastalıklarla karıştırılma ihtimali bulunmaktadır. Dolayısıyla erken evrede farklı bir teşhis konulursa ilgili tedaviler geciktiğinden dolayı AH daha hızlı ilerleyebilir, hasta ve hasta yakınlarına daha uzun süre problem yaşatabilir (Selekler, 2010).

Unutkanlık şikayeti ile gelen hastaya unutkanlığın şiddetini ölçmek için birtakım nöropsikolojik testler uygulanır. Ülkemizde en çok uygulanan nöropsikolojik test mini mental durum testidir. Hastaya hafıza ve diğer fonksiyonel merkezlerin test edilmesi için bir dizi sorular sorulur. Kişi 0-30 arası bir skor alarak unutkanlığın derecesi belirlenir. Diğer bir popüler nöropsikolojik test klinik demans derecelendirmedir (KDR). Bu test hasta ve hasta yakınlarına bir takım sorular sorularak skorlanır. Uzun bir test olduğu için çok pratik olmayabilir. Ancak ülkemizde çok yaygın olmasa da dünyada klinik çalışmalarda sıklıkla kullanılmaktadır. KDR skorlama yöntemi KDR0: Normal,

KDR 0.5: Hafif Bilişsel Bozulma, KDR1: Hafif Evre AH, KDR2: Orta Evre AH, KDR3: Ağır Evre AH olmak üzere 5 evreden oluşur. Yapılan nöropsikolojik testlerin skorlarına göre hastalığın tanı, teşhis ve tedavi süreçlerinde planlamalar yapılır (Gürvit ve Baran, 2007).

AH'de kesin tanı nöropatolojik inceleme ile konulabilmektedir. Ancak böyle bir durum hasta hayatta iken mümkün olmadığından görüntüleme yöntemleri ile oluşan patoloji yorumlanmaya çalışılmaktadır. AH'de beyin incelemeleri makroskobik ve mikroskobik olmak üzere ikiye ayrılmaktadır (Sezer ve Memiş, 2001; Öztürk ve Karan, 2006). Makroskobik değişiklikler beyin bölgelerinde meydana gelen atrofi, hacim artması veya azalmasıdır. Bu değişimler katı olduğundan üç boyutlu yapısal MR görüntüleri ile izlenebilir. Beyinde kortikal örtü incelir. Oksipital lob ve motor korteks genellikle sağlamdır. Tüm beyinde hacim azalması, gri madde hacim azalması, beyin omurilik sıvısında artış, lateral ventriküllerin genişlemesi, sulkuslarda genişleme, giruslarda küçülme ve düzleşme, özellikle hafıza ve dil bölgelerinde lokal hacimsel değişimler, sağ ve sol yarımküreler arasındaki simetri bozulması beyinde meydana gelen katı değişimlerdir (Sezer ve Memiş, 2001; Öztürk ve Karan, 2006; Selekler, 2010). Şekil 3.1'de verilen beyin modelinde beyinde meydana gelen katı değişimler görülmektedir.



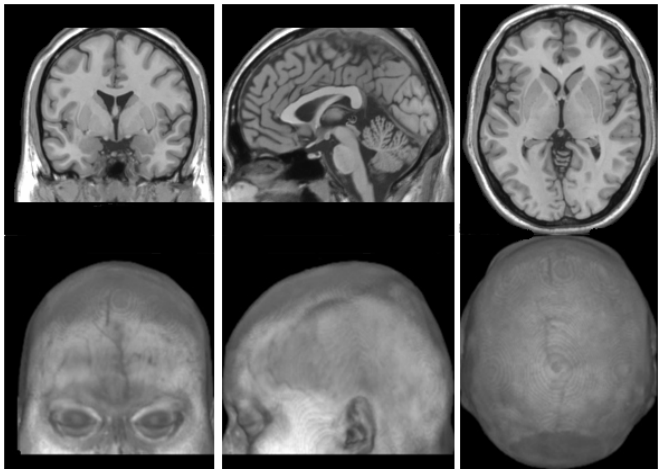
Şekil 3.1. AH'de beyindeki makroskobik katı değişimler (Anonim, 2017h)

AH'de miskroskobik özellikler hücre içi değişimler ve patolojik doku bozuklukları gibi mikroskop ile incelenebilecek detaylarla ortaya çıkan AH özellikleridir. Beyin dokularında meydana gelen nörofibril yumak, senil plak, nöron sinaps kayıpları mikroskobik olarak AH'nin histopatolojik özellikleridir. AH'li beyinlerde hücre dışında amiloid, hücre içinde ise nörofibril yumak birikimi ile beraber

oluşan hücresel kayıplar meydana gelmektedir. Senil Plaklar AH'deki en önemli histopatolojik özelliktir ve özellikle amigdala, hipokampus ve neokortekste görülmektedir (Öztürk ve Karan, 2006). Bu değişiklikler katı olmadığından ve çok küçük olduğundan yapısal MR ile görülmez. Miktarların değişimi PET görüntüleme yöntemi ile izlenebilmektedir.

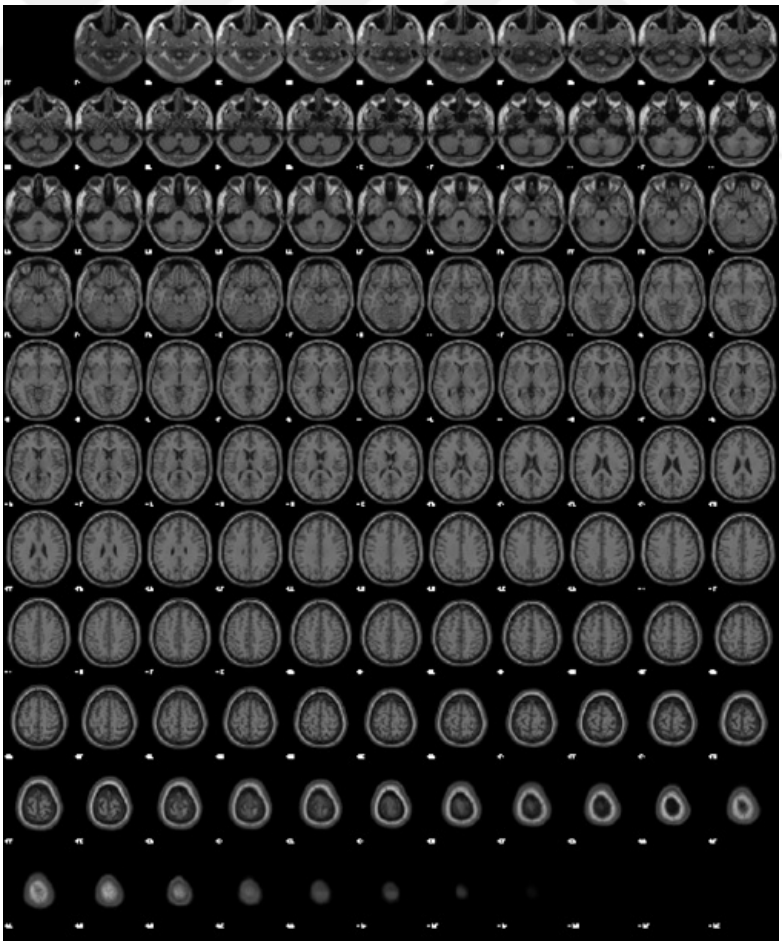
4. MANYETİK REZONANS GÖRÜNTÜLEME

Manyetik Rezonans Görüntüleme (MRG) nörolojik hastalıkların beyinde invazif olmayan bir şekilde izlenebilmesi için sıklıkla kullanılan bir görüntüleme tekniğidir. Bu görüntüleme tekniği ile beyin dokuları yüksek çözünürlükte izlenebilmektedir. Beyindeki dejenerasyon MR görüntüleri ile yorumlanarak hızlı ve etkin bir şekilde teşhisler ortaya konulabilmektedir. MR görüntülerinin fiziksel olarak oluşumunda vücut içerinde bulunan su ve yağ dokularındaki hidrojen atomları rol almaktadır. Normal şartlar altında bu atomlar yönelim olarak rastgele dağılımlıdır. Kişiler MR cihazı içerisinde üzerindeki metal eşyalar çıkarıldıktan sonra yüksek düzeyde bir manyetik alan içerisine yatırılır. Bu esnada hidrojen atomları rastgele dağılım yönünden manyetik alan yönünde dizilim durumuna geçer. Daha sonra görüntü alınmak istenen kesite bir Radyo Frekans (RF) sinyali gönderilerek hidrojen atomları manyetik dizilim alanından saparak yönlerini değiştirirler. RF sinyalinin çekilmesi ile beraber hidrojen atomları tekrar manyetik alan yönünde dizilim eğilimine geçtiği için absorbe ettikleri enerjiyi bırakırlar. Presesyon hareketi yaparak eski eksenlerine geri dönerler. Eski eksenlerine dönerken bıraktıkları enerji indükleme bobinleri ile akıma dönüştürülür. Bu akım analog dijital dönüştürücüler ile sayısallaştırılarak k-alanı denilen grafik matris alana depolanır. Daha sonra 2B Fourier Dönüşümü ile ilgili bölgenin görüntüsü oluşmaktadır. Görüntüler aksiyal, sagittal ve koronal olmak üzere üç eksende alınabilmektedir. Aksiyal eksen kafanın üzerinden boyuna kadar, sagittal eksen bir yüzden diğer yüze kadar, koronal eksen kafanın arka tarafından ön yüze kadar olan kesitlerdir (Herek ve Karabulut, 2010). Şekil 4.1'de sırasıyla koronal, sagittal ve aksiyal eksenlerde MR görüntüleri ve üç boyutlu modelleri verilmiştir.



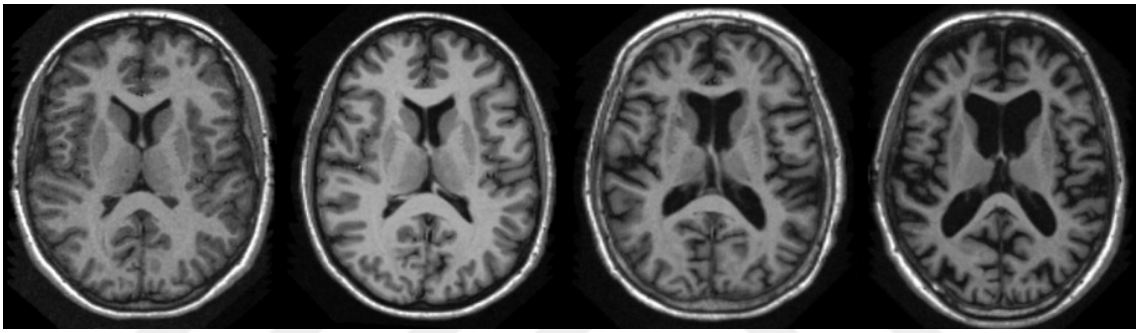
Şekil 4.1. Sırasıyla koronal, sagittal, aksiyal eksen MR görüntüleri ve üç boyutlu modelleri(MRIcro programı ile çizdirilmiştir)

Hastalar MR cihazı içine yatırıldıktan sonra hangi eksende ve hangi görüntüleme protokolleri ile görüntü alınacağı operatör tarafından belirlenir. Görüntülerdeki en önemli parametrelerden bir tanesi kesit kalınlığıdır. MR kesit görüntüleri her ne kadar iki boyutlu görünse de aslında bir kalınlığa sahip üç boyutlu bir görüntüdür. Bundan dolayı üç boyutlu analizlerde piksel yerine voksel ifadesi kullanılır. Voksel üç boyutlu uzayda en, boy, yükseklik özelliklerine sahip olan en küçük birimdir. Kesit kalınlığı hastanelerde genellikle 5-6 milimetre (mm) civarı alınmaktadır. Bu kalınlık manuel yorumlar için yeterli olabilir. Ancak bilgisayar ortamındaki sayısal analizlerde bu kalınlık çok fazla anlamlı bilginin kaybolmasına neden olmaktadır. Bu nedenle tez çalışmasında 1mm kalınlığında görüntüler kullanılmıştır. MR görüntüleri bir yığın olarak düşünüldüğünde kesitlerden oluşan kümülatif bir görüntü kümesidir. Her bir görüntü aynı kalınlık ve görüntü boyuna sahiptir. Bir yığın olarak MR görüntüsü *görüntü boyu * görüntü eni * kesit sayısı* olarak ifade edilir. Şekil 4.2'de 121*145*121 boyutlu, kesit kalınlığı 1.5 mm olan aksiyal çekimli bir insana ait MR görüntüsü verilmiştir.



Şekil 4.2. 121*145*121 boyutlu, kesit kalınlığı 1.5 mm olan aksiyal eksen bir MR yığını (SPM8 programı ile çizdirilmiştir)

Alzheimer hastalığından dolayı beyinde meydana gelen hacimsel kayıplar MR görüntülerinde net bir şekilde izlenebilir. Şekil 3.1'de gösterildiği gibi lateral ventrikül, hafız ve dil bölgelerinde hacimsel azalma, sulkus ve giruslarda değişim, tüm beyin hacminde küçülme, simetri bozuklukları, beynin dış bölgesini saran gri madde bölgesinde hacimsel azalmalar beyin morfolojisinde değişimlere neden olur. AH'de evreler arttıkça bu bölgelerdeki dejenerasyon artmakta ve hızlanmaktadır. Evreler arasında artan dejenerasyon MR görüntülerinde katı değişimler olarak izlenebilir. Şekil 4.3'te OASIS veri tabanından alınan MR kesitlerinden KDR:0-2 arasında etiketlenen görüntüler verilmektedir. Şekil 4.3'te verilen MR görüntülerinde, Şekil 3.1'de gösterilmekte olan beyindeki katı değişimler, evreler ilerledikçe net bir şekilde izlenebilmektedir.



Şekil 4.3. Sırasıyla KDR 0 (Normal), KDR 0.5 (Hafif Bilişsel Bozulma), KDR 1 (Hafif Evre), KDR 2 (Orta Evre) skorları ile etiketlenmiş kesitler (OASIS veri tabanından alınmıştır)

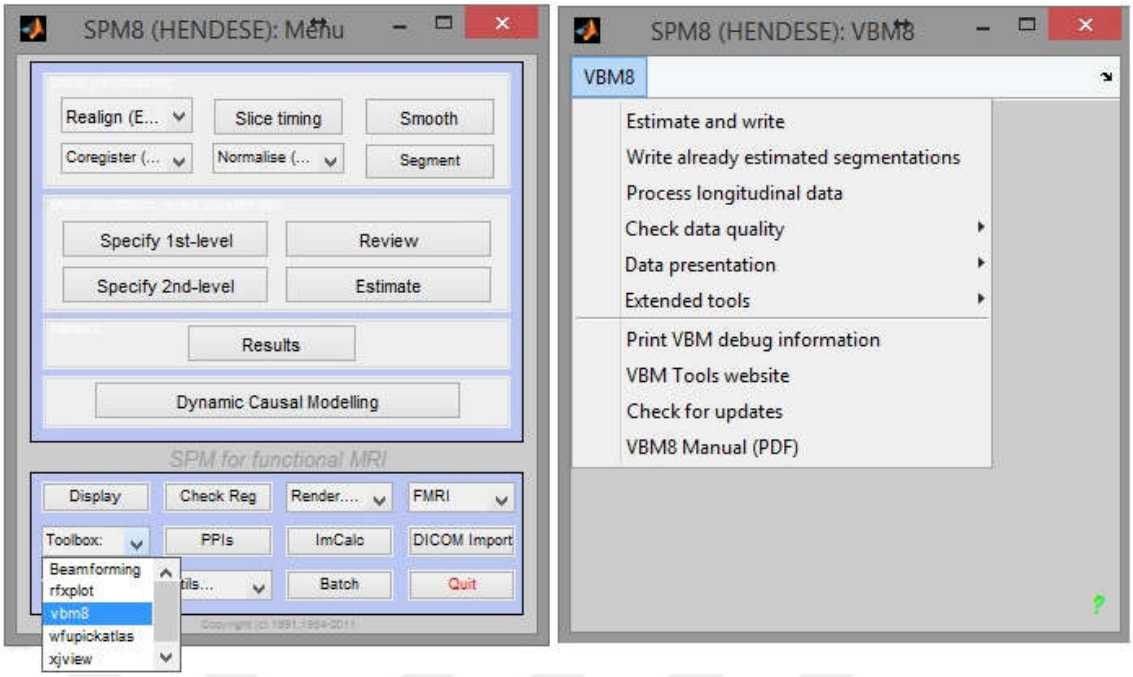
4.1. Veri Tabanları

Dünyada birçok ülkede hem AH hem de diğer demanslar için ciddi çalışmalar yürütülmektedir. Bazı projelerde, çalışmalar süresince alınan MR görüntüleri ve diğer veriler internet üzerinden tüm dünyadaki araştırmacıların kullanımına sunulmaktadır. Bu veriler üzerinden bazı kongrelerde hastalık sınıflandırma yarışmaları düzenlenmektedir. *Alzheimer Disease Neuroimaging Initiative* (ADNI) (Jack ve ark., 2008), *The Open Access Series of Imaging Studies* (OASIS) (Marcus ve ark., 2007), *Minimal Interval Resonance in Alzheimer's Disease* (MIRIAD) (Malone ve ark., 2013) literatürde kullanılan bazı veri tabanlarıdır. Tez çalışmasında OASIS veri tabanı kullanılmıştır. Bu veri tabanında yaşları 18 ile 96 arasında değişen deneklerin MR görüntüleri ve diğer demografik veriler bulunmaktadır. Bu veriler Washington Üniversitesi ve diğer ortak araştırma enstitüleri vasıtası ile toplanmış, ücretsiz olarak

araştırmacıların kullanımına sunulmuştur. Veri tabanında MR görüntüleri KDR:0 ile KDR:2 arasında değişen skorlar ile etiketlenmiştir (Marcus ve ark., 2007).

4.2. Paket Programlar

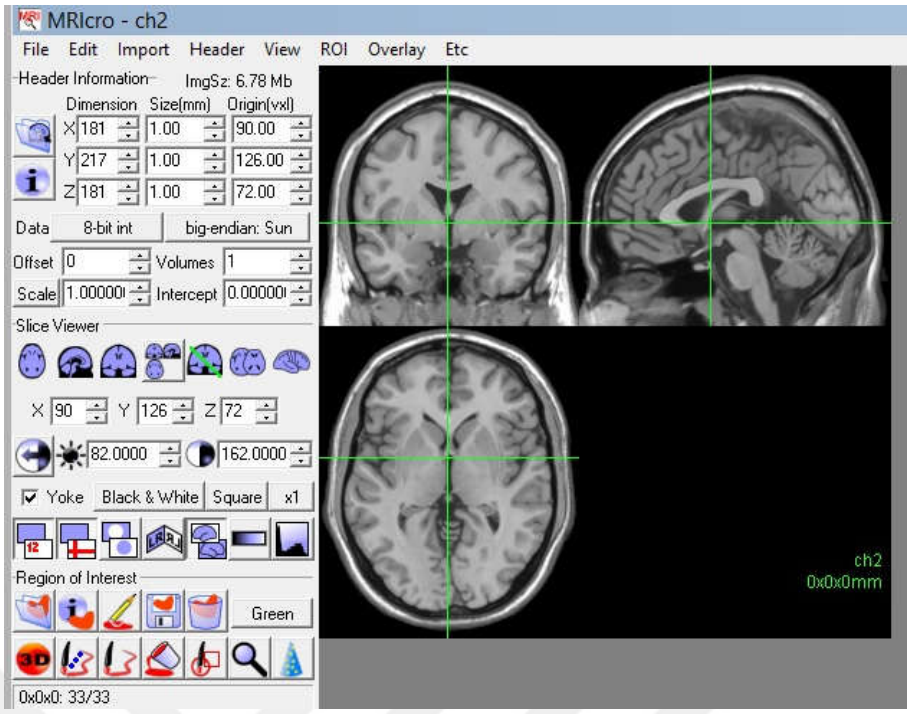
Yapısal MR görüntülerinin analizi için literatürde birçok paket program kullanılmaktadır. Her bir program kendi içerisinde farklı analiz araçları bulundurmaktadır. Aynı zamanda açık kaynak kodlu programlarda kullanıcılar paket programların altyapısındaki kütüphaneleri kullanarak kendi araçlarını bir eklenti olarak gerçekleştirebilmektedir. *Medical Image Processing, Analysis and Visualization* (MIPAV) (McAuliffe, 2009), SPM (Ashburner ve ark., 1994), *Freesurfer* (Fischl, 2012), FSL (Jenkinson ve ark., 2012) kullanılan programlardan bazılarıdır. Ancak literatürde FSL, Freesurfer ve SPM programları ile daha sık karşılaşıldığından bu üç program tez kapsamında incelenmiştir. FSL ve Freesurfer linux tabanlı, SPM ise MATLAB tabanlıdır. FSL ve Freesurfer programları linux terminali üzerinden yönlendirilerek MR analizleri yapılmaktadır. SPM programı MATLAB ortamında bir ara yüz ile yönlendirilmektedir. Her program kendine özel önişleme ve segmentasyon platformları sunmaktadır. Freesurfer programının bir MR görüntüsü için çok fazla süre harcaması ve FSL programının sadece 15 alt bölgenin segmentasyonunu vermesi tez çalışması için dezavantajlar oluşturmuştur. Bundan dolayı SPM programının SPM8 versiyonu, araç olarak bazı istekleri karşılamasa da önişleme fonksiyonları son derece kullanışlıdır. SPM8 kütüphanesini kullanarak kullanıcılar çeşitli ihtiyaçlara karşı SPM8 eklentisi geliştirilebilmekte ve SPM web sitesinden bunları dünyadaki tüm araştırmacılar ile paylaşmaktadır. Tez çalışmasında SPM8 kütüphanesi ile çalışan VBM8 (Kurth ve ark., 2010) ve WFU PickAtlas (Maldjian ve ark., 2003; Maldjian ve ark., 2004) kütüphaneleri kullanılmıştır. Bu programlar dışında MR görüntülerinin görselleştirilmesi, eksenel olarak incelenmesi ve bazı basit araçların kullanımına olanak sunan MRIcro paket programı tez kapsamında kullanılmıştır (Anonim, 2017b). Şekil 4.4a'da SPM8 ve VBM8, Şekil 4.4b'de WFU PickAtlas ve Şekil 4.4c'de MRIcro ara yüzleri gösterilmektedir.


SPM8 (HENDESE): Menu
Realign (E...
Slice timing
Smooth
Coregister (...
Normalise (...
Segment
Specify 1st-level
Review
Specify 2nd-level
Estimate
Results
Dynamic Causal Modelling
SPM for functional MRI
Display
Check Reg
Render....
FMRI
Toolbox:
PPIs
ImCalc
DICOM Import
Batch
Quit
Beamforming
rfxplot
vbm8
wfupickatlas
xjview
SPM8 (HENDESE): VBM8
VBM8
Estimate and write
Write already estimated segmentations
Process longitudinal data
Check data quality
Data presentation
Extended tools
Print VBM debug information
VBM Tools website
Check for updates
VBM8 Manual (PDF)

(a)


WFU PickAtlas Tool
HUMAN ATLAS
TD brodmann areas+
TD Lobes
TD Hemispheres
TD Labels
TD Type
aal
IBASPM 71
IBASPM 116
Shapes
Atlas Information
BASIC
ADVANCED
ADD ->
MOVE ALL ->>
<- REMOVE SELECTED
<<- REMOVE ALL
2D
3D
DILATE
0
Flip Lock
L/R
U/D
Left
Left + Right
Right
Display: Neurologic
37
L
R
RESULTS
Write Independent R...
SAVE MASK
DONE
CANCEL
WORKING REGION1
CUBE
MNI
Tal
46
64
37
0
0
0
0
0
0
GO
ATLAS
TD brodmann ar...
TD Lobes
SUBREGION
NA
NA
VALUE
1000
1500

(b)



(c)

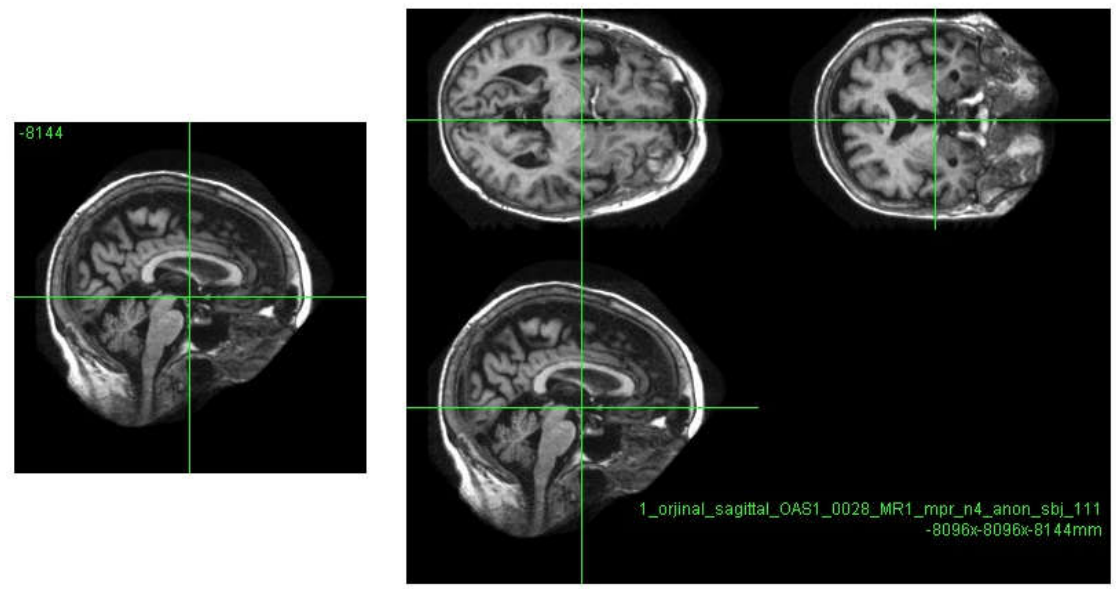
Şekil 4.4. (a) SPM8 ve VBM8 ara yüzleri (b) WFU PickAtlas MATLAB Platformu (c) MRIcro platformu

4.3. MR Görüntülerinde Önişleme Yöntemleri

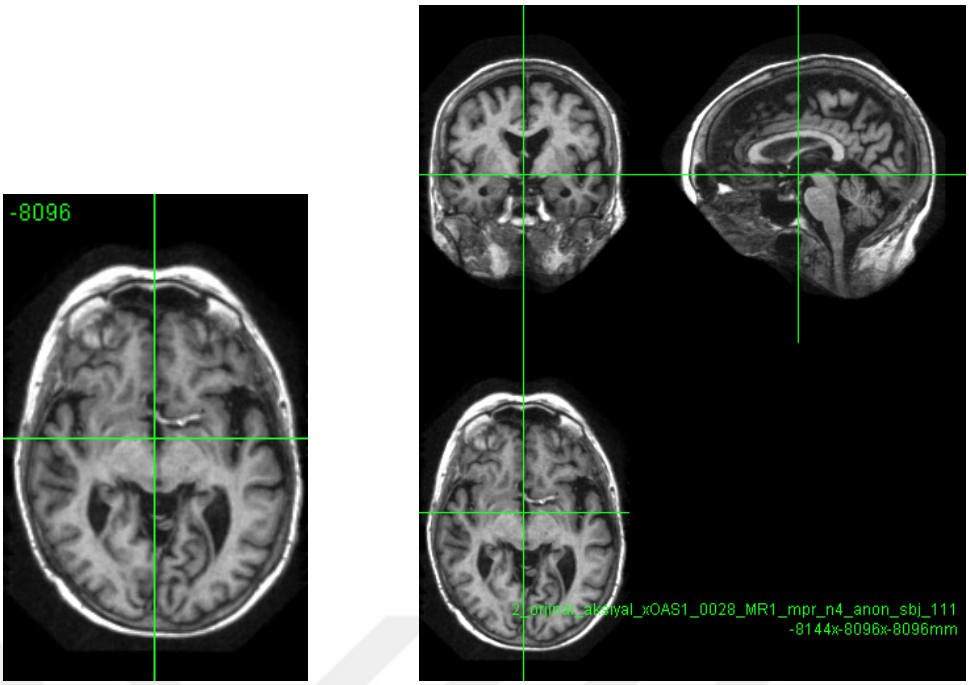
MR görüntüleri cihazdan alındığı gibi sayısal analiz için bilgisayar ortamında işlenemez. Her ne kadar radyologlar için bu çekimler yeterli olsa da sayısal analizler için bir takım önişlemelerin yapılması gerekmektedir (Hemanth ve Anitha, 2012; Patil ve Udupi, 2012). Bu nedenle MR görüntülerinde özellik çıkarma işlemine geçmeden önce hangi önişlemelerin nasıl ve hangi araçlarla kullanılacağı detaylı bir şekilde araştırılmıştır. Eksen dönüştürme, görüntü reoryantasyonu, gürültü ve bias giderme, beyin dışı yapıların atılması, segmentasyon, bulanıklaştırma, normalizasyon, modülasyonlu ve modülasyonsuz segmentasyon, birlikte çakıştırma olmak üzere dokuz önişleme yöntemi incelenmiştir. Önişleme metodlarının hangi yöntemlerle yapılacağı ve hangi algoritmaların kullanılacağı literatürde sıklıkla çalışılan konular olduğu için bu yöntemlerin geliştirilmesi bu tezin kapsamı dışındadır. Önişleme yöntemleri tez çalışması için bir araç olduğundan dolayı hâlihazırda geliştirilen algoritmalar ve yöntemler kullanılmıştır. Kullanılan önişleme yöntemlerinin çıktıları OAS1_0028 numaralı ve klinik demans skoru bir (KDR1) olan kadın denek MR görüntüsü üzerinde gösterilecektir.

4.3.1. Eksen Dönüştürme

Eksen dönüştürme görüntülerin çekilmiş olduğu eksenden diğer eksenlere dönüştürülmesidir. Bu işlem için MRIcro programı kullanılmıştır. Tez çalışmasında kullanılan OASIS veri tabanından alınan görüntüler sagittal eksende çekilmiştir. SPM8 programındaki şablonların aksiyal eksende oluşturulmasından dolayı görüntülerin aksiyal eksene dönüştürülme ihtiyacı ortaya çıkmıştır (Ashburner ve ark., 2008). Bu işlem sırasında görüntülerin içerikleri değişmez sadece görüntüye bakılan yön değişir. Görüntüler sagittal eksende 256*256*160 görüntü boyutlu ve 1*1*1 mm^3 voksel boyutlu iken aksiyal eksende 160*256*256 görüntü boyutu ve 1*1*1 mm^3 voksel boyutuna dönüşmektedir. Görüntü boyutu bakılan yönden dolayı düşmekte, voksel boyutları değişmemekte, görüntüye bakış açısı değiştiği için kesit sayısı artmaktadır. Bu işlem görüntünün bilgi içeriğini değiştirmez, sadece görüntünün *header* dosyası içindeki *Voxel World Mapping* matrisi değiştirilir. Bu matrisin değiştirilmesi ile görüntülerin yönelimi değişmektedir (Şenvardar, 2011). Şekil 4.5a'da OAS1_0028 nolu deneğin sagittal eksen görüntüsü, Şekil 4.5b'de sagittal eksenden aksiyal eksene dönüştürülmesi ile ortaya çıkan görüntü gösterilmektedir.



(a)



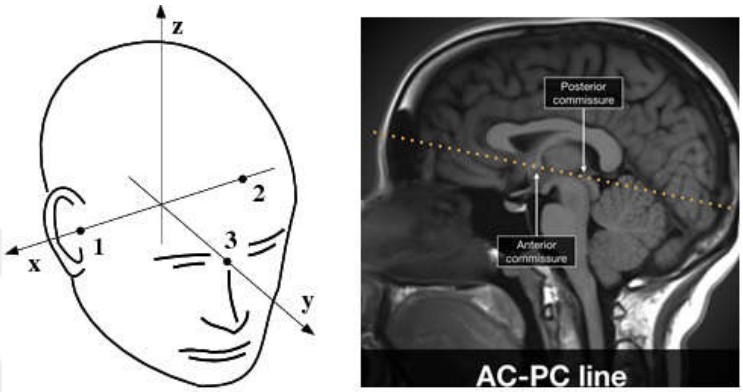
(b)

Şekil 4.5. (a) Sagittal eksen ve üç eksende görüntünün gösterimi (256*256*160 görüntü boyutu ve 1*1*1 mm^3 voksel boyutu) (b) Aksiyal eksen ve üç eksende görüntünün gösterimi (160*256*256 görüntü boyutu ve 1*1*1 mm^3 voksel boyutu)

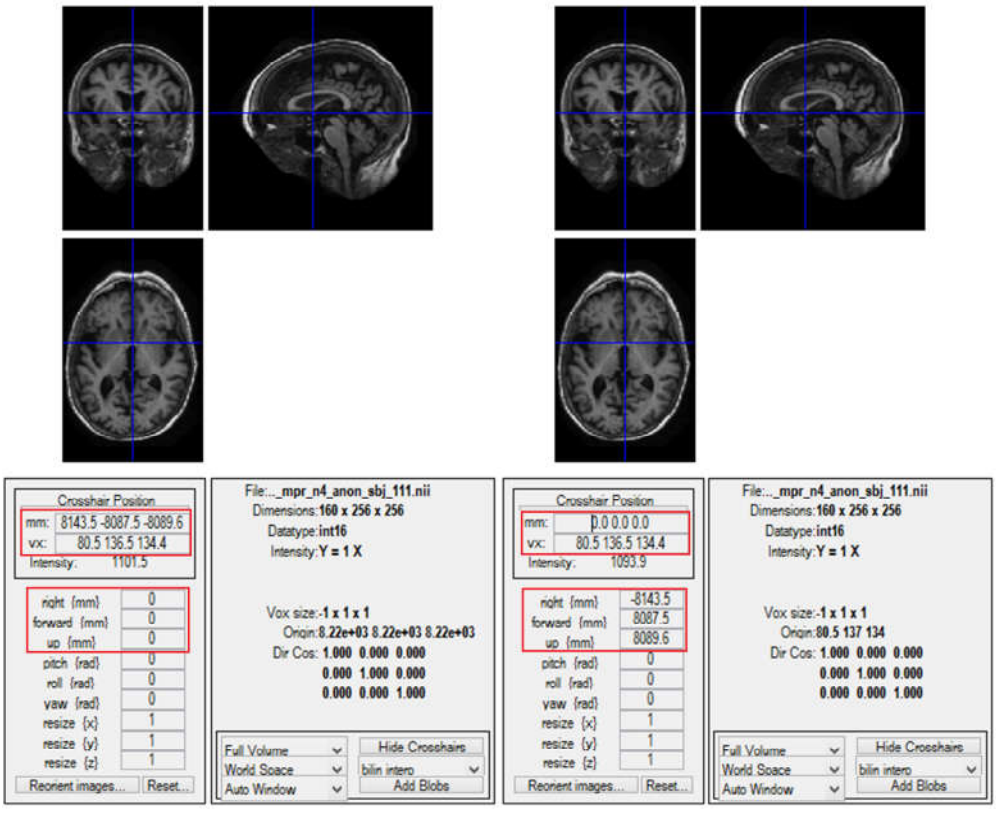
4.3.2. Görüntü Reoryantasyonu

Görüntü reoryantasonu görüntünün x, y, z yönü ve *yaw, pitch, roll* açılarına göre koordinatsal olarak üç boyutlu uzayda kaydırılmasıdır. Bu işlem sırasında voksel koordinatları öteleme (*translation*) ve döndürme (*rotation*) olmak üzere iki hareketle değiştirilir. İşlem yapılırken voksel komşulukları ve değerli bilgiler kaybedilmez. Sadece katı dönüşüm gerçekleştirilir (Davis ve Loh, 2011). Bu işlem tez çalışmasında iki amaçla kullanılmıştır. Birincisi çekim esnasında kafa hareketinden kaynaklı kaymaların manuel olarak düzeltilmesidir. İkinci olarak MR görüntülerinde merkezlerin x,y,z=0 noktasına kaydırılmasıdır. Bu nokta talairach tarafından belirlenen ve halen günümüzde kullanılan *Anterior Commissure* (AC) noktasıdır. Bu nokta beynin merkezi olarak kabul edilir ve bu nokta ile *Posterior Commissure* (PC) noktasından geçen çizgi AC/PC çizgisi olarak kabul edilir (Anonim, 2017a). Bu çizgi bir düzlem olarak z yönünde uzatılırsa oluşan düzlem beyni tam ortadan ikiye ayırır ve orta sagittal düzlem (*midsagittal plane*) olarak isimlendirilir (Liu ve ark., 2001). Görüntüler x,y,z=0 noktasına ayarlanmazsa analiz sırasında VBM8 kütüphanesi hata vermektedir. Bu nokta manuel olarak SPM8 programının reoryantasyon (*reorientation*) aracı ile ilgili uzaklık değerleri girilerek düzeltilebilir. Her ne kadar x,y,z=0 noktası tam olarak oturtulamazsa

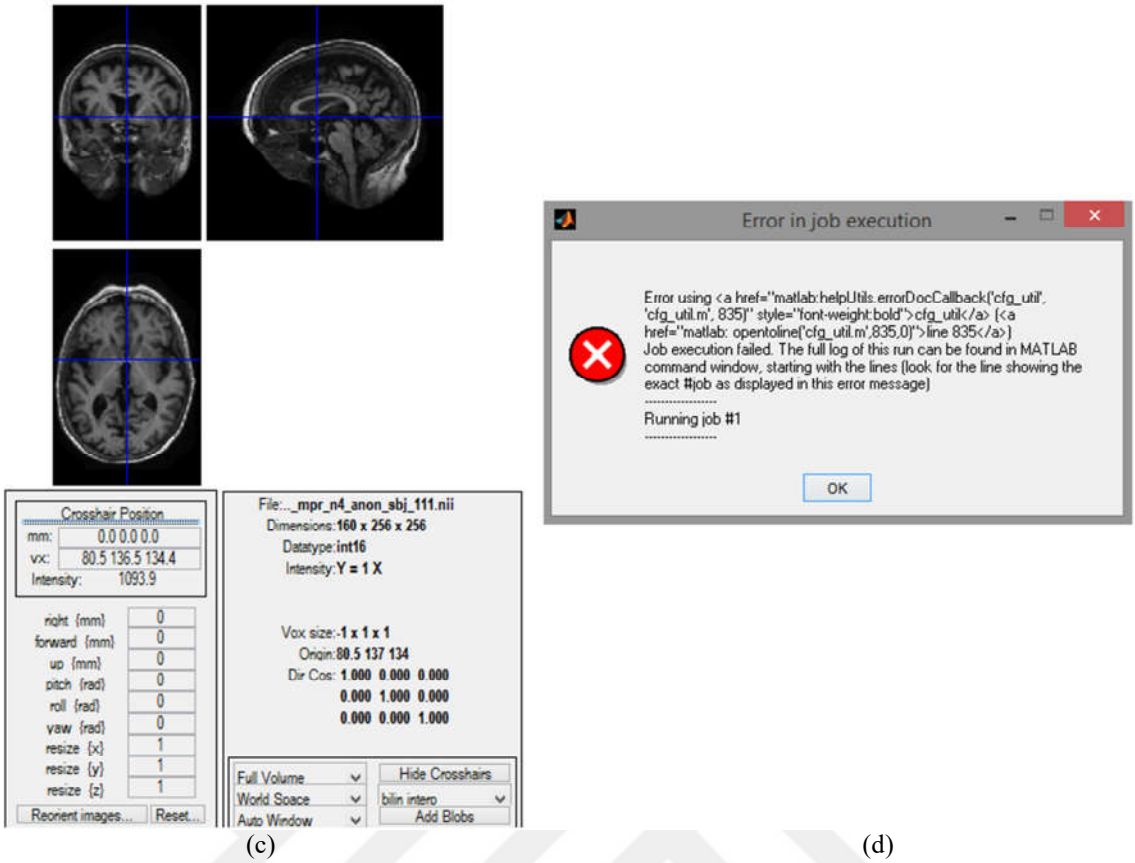
da kaynaklarda analiz için olabildiğince yakın olmasının yeterli olabileceği belirtilmektedir (Ridgway, 2010a). Şekil 4.6a'da bir kafa görüntüsünde x, y, z eksenleri gösterilmekte, Şekil 4.6b'de AC/PC çizgisi bir MR görüntüsünde gösterilmektedir. Şekil 4.7a'da ham görüntü ve koordinatları (kırmızı kutu içerisinde), 4.7b'de düzeltme için girilen koordinatlar, 4.7c'de görüntünün x,y,z=0 olarak ayarlanmış hali, 4.7d'de ilgili koordinat değişimi yapılmadığında MATLAB'ın vermiş olduğu hata görüntüsü verilmiştir.



Şekil 4.6. (a) Bir kafa görüntüsünde x, y, z eksenleri (Anonim, 2017j) (b) Bir MR görüntüsünde AC/PC çizgisi (Anonim, 2017i)



(a) (b)



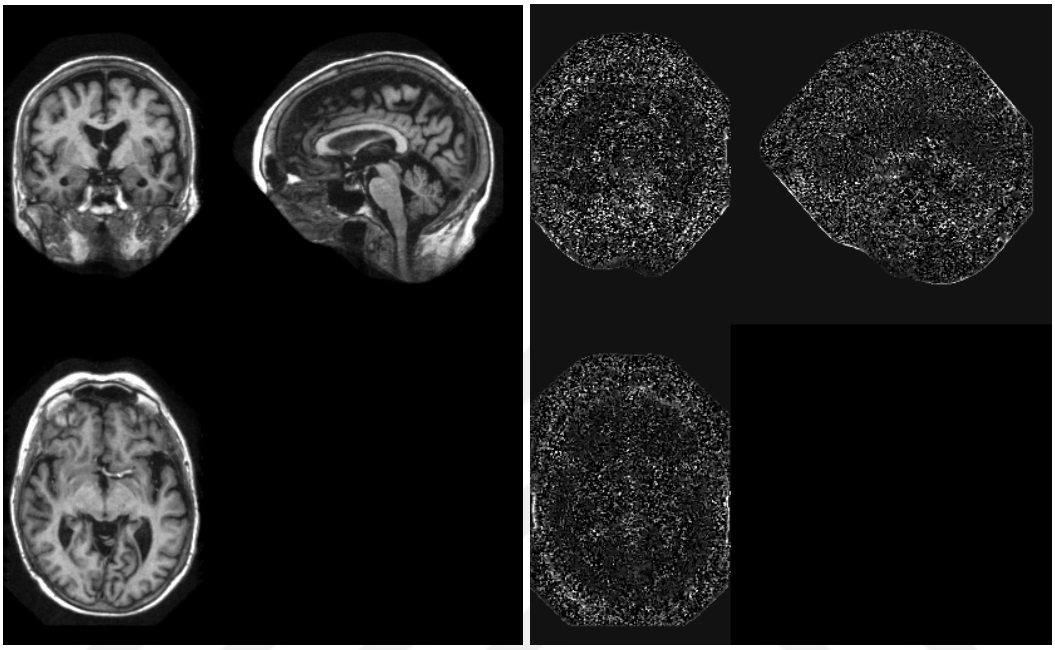
(c) (d)

Şekil 4.7. (a) Ham görüntü ve koordinatları(kırmızı kutu içerisinde) (b) Düzeltme için girilen koordinatlar (c) Görüntünün x,y,z =0 olarak ayarlanmış hali (d) İlgili koordinat değişimi yapılmadığında MATLAB'ın vermiş olduğu hata görüntüsü

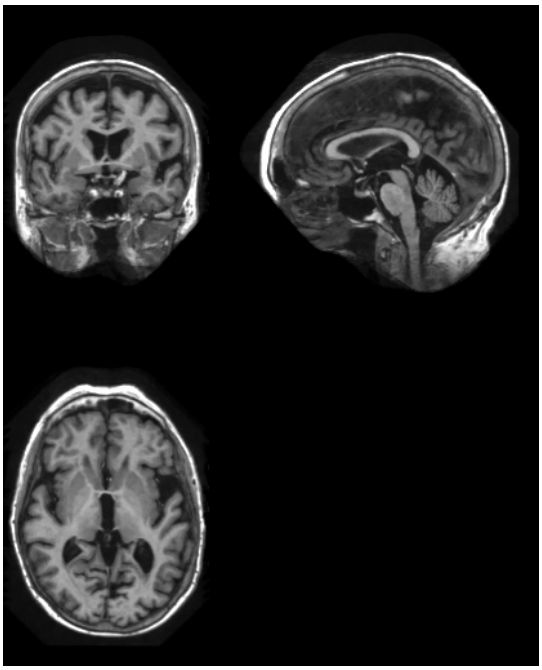
4.3.3. Gürültü ve Bias Giderme

Görüntü çekimi esnasında çevresel faktörlerden ve cihazdan kaynaklı gürültüler MR görüntüleri üzerinde istenmeyen voksellerin ortaya çıkmasına neden olmaktadır. Bu gürültüler rastgele ortam ve kaynaktan geldiği için basit gürültü giderme yöntemleri ile sonuç alınamaz. Arzu edilen gürültü giderme yönteminin istenmeyen vokselleri gidermesi ve anlamlı kenarları yok etmemesi gerekmektedir. Bundan dolayı her bir görüntüye uygun olacak şekilde gürültüyü tespit ederek gürültüyü elimine edecek adaptif bir algoritma gereklidir. Literatürde genel olarak bias ve rastgele gürültü olmak üzere iki gürültü çeşidi belirtilmektedir. Bias gürültüsü MR cihazının manyetik dalga kullanımından dolayı görüntüye eklenen gürültüdür. Bias harici rastgele gürültüler ise termal gürültü ve diğer gürültülerdir. Her iki gürültü çeşidini de gidermek için literatürde birçok farklı algoritma önerilmiştir (Gudbjartsson ve Patz, 1995; Van Leemput ve ark., 1999; Ahmed ve ark., 2002; Manjón ve ark., 2008; Tustison ve ark., 2010; Manjón ve ark., 2012). Bias ve rastsal gürültü giderme işlemleri SPM8 ve VBM8

kütüphanesi ile yapılabilmektedir. Bias giderme ayrık kosinüs dönüşümünün temel fonksiyonları ile (Ridgway, 2008), rastgele gürültü ise uzaysal adaptif yerel olmayan filtre ve markov rastgele alanları ile giderilmektedir (Rajapakse ve ark., 1997; Kurth ve ark., 2010; Manjón ve ark., 2010). Şekil 4.8a'da gürültülü görüntü, Şekil 4.8b'de görüntüden çekilen bias ve rastgele gürültü, Şekil 4.8c'de gürültülerden arındırılmış görüntü verilmiştir.



(a) (b)

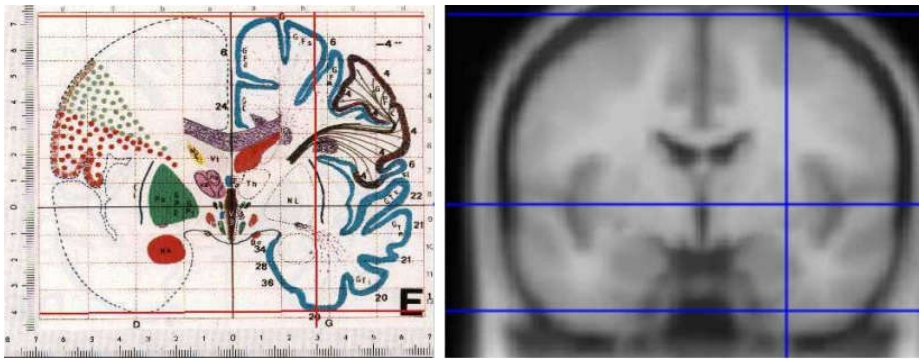


(c)

Şekil 4.8. (a)Gürültülü görüntü (b) Görüntüden çekilen bias ve rastgele gürültü (c) Gürültülerden arındırılmış görüntü

4.3.4. Normalizasyon

Normalizasyon işlemi MR görüntülerinin aynı koordinat sisteminde karşılaştırılması için gerçeklenen bir önişlemedir. Böylece farklı deneklerden alınan MR görüntülerinde analiz için bir standardizasyon getirilmiş olur. Bu işlem grup istatistiği yapmayı, grup içi ve gruplar arası hacimsel farklılıkların bulunmasını ve istatistiksel gücün artmasını sağlar (Şenvardar, 2011). SPM8 koordinat sistemi olarak *Montreal Neurological Institue* (MNI) uzayını kullanmaktadır. Bu uzay temel olarak Talairach koordinatlarını referans alır. Talairach ve Tourneux 1988 yılında beynin şekil ve büyüklüğünden bağımsız bir şekilde 60 yaşındaki Fransız bir kadının beyninden yola çıkarak beyin haritası ve koordinat sistemi ortaya çıkarmışlardır. AC noktasını orijin alan bu sistem, AC/PC noktasından geçen çizgiyi orta sagittal düzlemden geçen çizgi olarak kabul etmiştir. Bu sistem tek bir insan beynini temsil etmesine rağmen beyin normalizasyon ve çakıştırma işlemlerinde standart kullanılır hale gelmiştir. Sayısal analizlerde bu eksene çakıştırmak için normalden küçük olan beyin tekrar boyutlandırılırken sayısal sistemlerde hatalar meydana gelebilmektedir (Talairach ve Tournoux, 1988; Lancaster ve Fox, 2000; Brett ve ark., 2002; Dağdeviren, 2012). Ancak Talairach ve Tourneux'un geliştirdiği bu sistem tüm popülasyonu temsil edemediği düşünülerek popülasyon tabanlı bir sistem MNI tarafından geliştirilmiştir. Bu sistem iki aşamada oluşturulmuştur. Birinci aşamada 241 normal beyin MR görüntüsü Talairach koordinatlarına oturtulmuş ve ortalaması alınarak geçiş görüntüsü elde edilmiştir. İkinci aşamada 305 beyin MR görüntüsü oluşturulan bu geçiş görüntüsüne çakıştırılarak MNI305 şablon görüntüsü oluşturulmuştur. MNI305 şablonu MNI'nın ilk şablon görüntüsüdür. SPM 96 ve 99 versiyonları bu şablonları kullanmaktaydı. Güncel versiyonları 152 beyin görüntüsünün 9 parametreli bir afin dönüşümü ile MNI305 şablonuna çakıştırmış olduğu ICBM152 şablonunu kullanmaktadır (Evans ve ark., 1992; Evans ve ark., 1993; Anonim, 2017). Şekil 4.9a'da Talairach, Şekil 4.9b'de MNI koordinat sistemi gösterilmiştir.

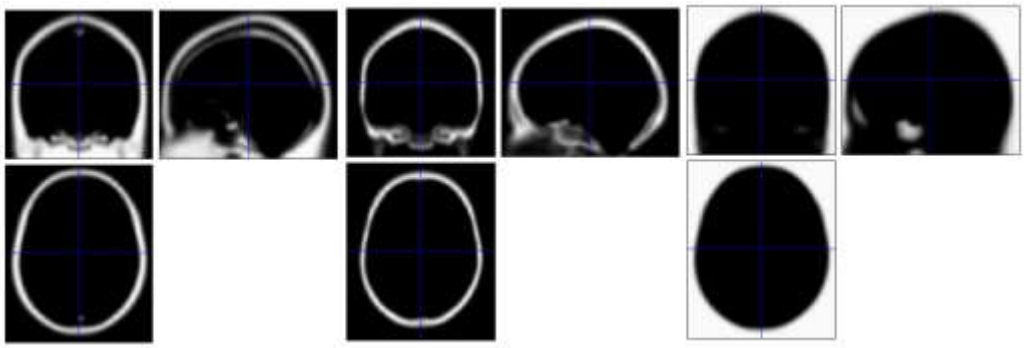


(a) (b)

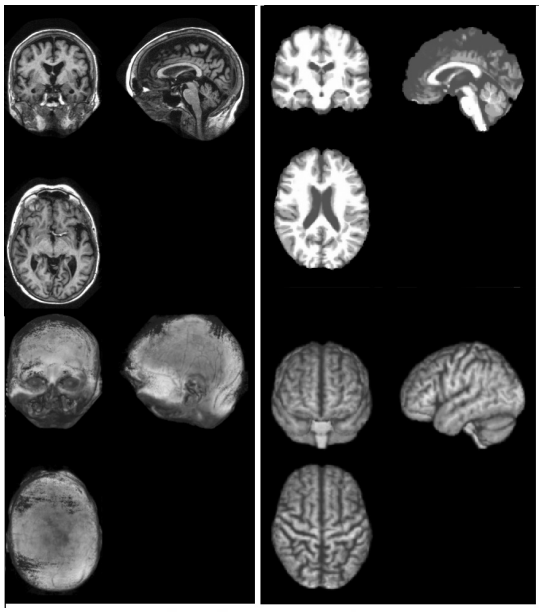
Şekil 4.9. (a) Talairach Koordinat Sistemi (b) MNI Koordinat Sistemi (Anonim, 2017)

4.3.5. Beyin Dışı Yapıların Atılması

Beyin MR görüntülerinin analizi sırasında beyin dışı yapılar analiz sürecini etkileyerek gereksiz işlemlerin yapılmasına neden olabilir. Bunun için bu yapılar anlamlı voksel değerleri yok edilmeden kaldırılmalıdır. SPM8 programı altında çalışan VBM8 kütüphanesi bu işlemi otomatik bir şekilde yapabilmektedir (Kurth ve ark., 2010). Görüntüler MNI uzayına normalize edilerek beyin dışı yapılar atılır. Bu işlem için daha önceden oluşturulmuş beyin dışı yapılar (kemik ve yumuşak dokular) öncül olasılık haritaları kullanılmaktadır (Ridgway, 2010b). Şekil 4.10'da SPM8 programında kullanılan beyin dışı yapılar öncül olasılık haritaları gösterilmiştir. Şekil 4.11'de OAS1_0028 nolu MR görüntünün normalizasyon işlemi ile beraber beyin dışı yapıların atılmış hali ve üç boyutlu modelleri gösterilmektedir.



Şekil 4.10. Beyin dışı yapılar öncül olasılık haritaları(Ridgway, 2010b)



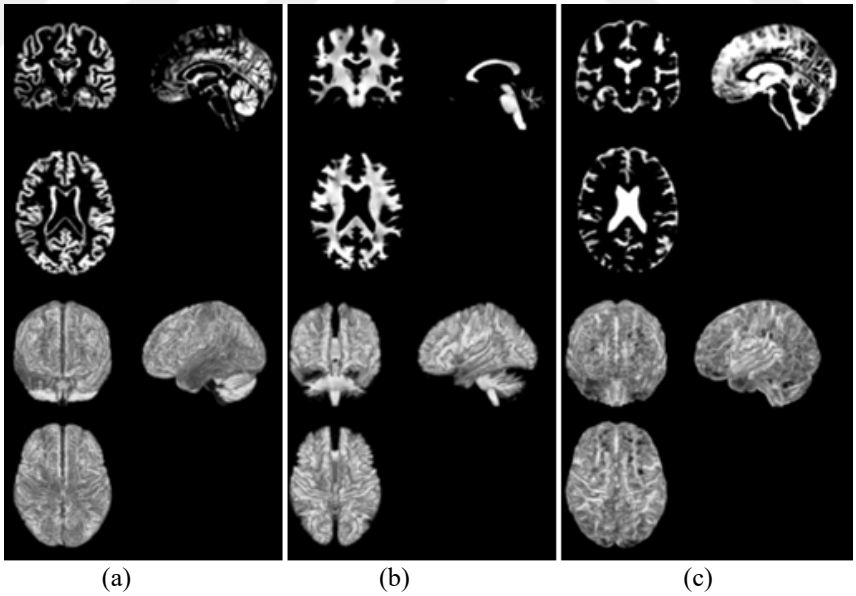
(a) (b)

Şekil 4.11. (a) OAS1_0028 nolu görüntü ve 3B model (b) Beyin dışı yapıların normalize koordinatlarda atılmış hali ve 3B Model

4.3.6. Segmentasyon

Beyin temel olarak Gri Madde (GM), Beyaz Madde (BM), Beyin Omurilik Sıvısı (BOS) olmak üzere üç kısma ayrılmaktadır. Gri madde beyindeki fonksiyonel merkezlerin bulunduğu kısım, beyaz madde fonksiyonel merkezle vücut fonksiyonları arasında iletişim kuran bir nevi haberleşme kabloları ve beyin omurilik sıvısı ise GM ve BM'yi çevreleyen, beyni dış müdahalelere karşı koruyan bir sıvıdır. Bu bölgeler MR görüntülerinde manuel olarak izlenebilmektedir. Ancak GM, BM ve BOS bölgelerinin sınırları net bir şekilde kestirilememektedir. En büyük problem bölgelerin komşuluklarında hangi voksellerin hangi bölgeye ait olduğu kararının verilmesidir. SPM programı bu bölgelerin segmantasyonu için gauss karışım modeli kullanmaktadır. Bu model bayes kuralı ve daha önce türetilmiş öncül olasılık haritaları kullanarak hangi vokselin ne kadar olasılıkla hangi doku sınıfına ait olduğunu belirlemektedir (Ashburner ve Friston, 2000). Ashburner ve Friston bias düzeltmesi, normalizasyon ve segmentasyon işlemlerinin bir arada yapılabildiği birleştirilmiş segmentasyon (*unified segmentation*) isimli bir model geliştirmiştirler ve bu model SPM8 programında kullanılmaktadır. Bu model ile tüm basamaklar bir arada yapılarak ara işlemlerin yapılmasına gerek kalmadan direkt olarak segmente ve normalize edilmiş görüntüler elde edilebilmektedir (Ashburner ve Friston, 2005). Ashburner sonraki çalışmalarında difeomorfik bir çerçevesi olan *Diffeomorphic Anatomical Registration Through*

Exponentiated Lie Algebra (DARTEL) isimli bir normalizasyon algoritması önermiştir (Ashburner, 2007). DARTEL yönteminin birçok normalizasyon yöntemi içerisinde en iyi çakıştırmayı ve farklı merkezlerden farklı görüntüleme protokolleri ile alınan görüntüler arasında en iyi çakıştırmayı verdiği belirtilmiştir (Klein ve ark., 2009; Goto ve ark., 2013). VBM8 kütüphanesi SPM'den farklı olarak segmentasyon işlemi için öncül olasılık bilgisine gerek kalmadan *Maximum A Posterior* tekniği ve parçalı hacim tekniğini kullanmaktadır (Rajapakse ve ark., 1997; Tohka ve ark., 2004; Kurth ve ark., 2010). Birleştirilmiş segmentasyon işleminde kullanılan doku olasılık haritaları burada sadece normalizasyon işleminde kullanılmaktadır. Eğer yüksek seviyeli DARTEL normalizasyon işlemi seçilirse MNI uzayına 550 normal beyin görüntülerinden türetilmiş DARTEL şablonu kullanılmaktadır (Kurth ve ark., 2010). VBM8 kütüphanesine ham bir görüntü verilerek segmentasyon ve normalizasyon parametreleri ayarlandığında GM, BM ve BOS bölgelerini otomatik bir şekilde vermektedir. OAS1_0028 no'lu deneğin VBM8 kütüphanesi ile elde edilen DARTEL normalizasyon işlemi uygulanmış GM görüntüsü ve 3B modeli Şekil 4.12a'da, BM görüntüsü ve 3B modeli Şekil 4.12b'de, BOS görüntüsü ve 3B modeli Şekil 4.12c'de gösterilmektedir.

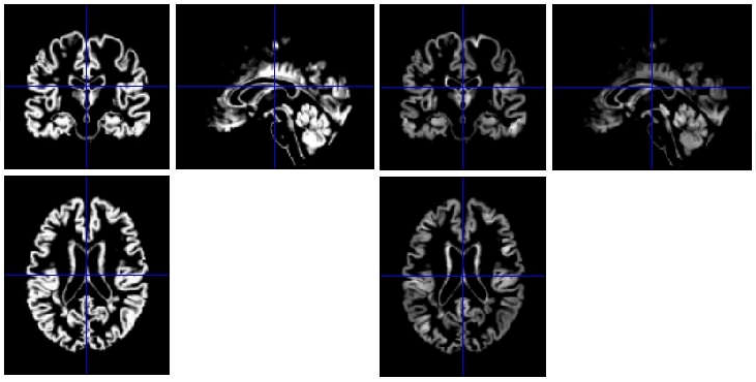


(a) (b) (c)

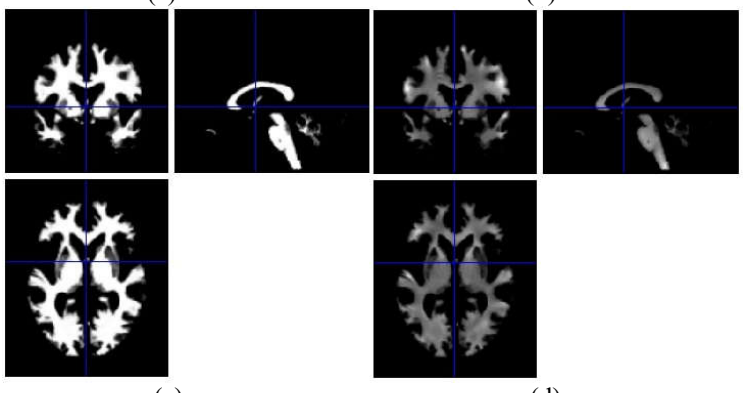
Şekil 4.12. OAS1_0028 nolu deneğin VBM8 kütüphanesi ile (a) GM segmentasyonu ve 3B modeli (b) BM segmentasyonu ve 3B modeli (c) BOS segmentasyonu ve 3B modeli

4.3.7. Modülasyonlu ve Modülasyonsuz Görüntüler

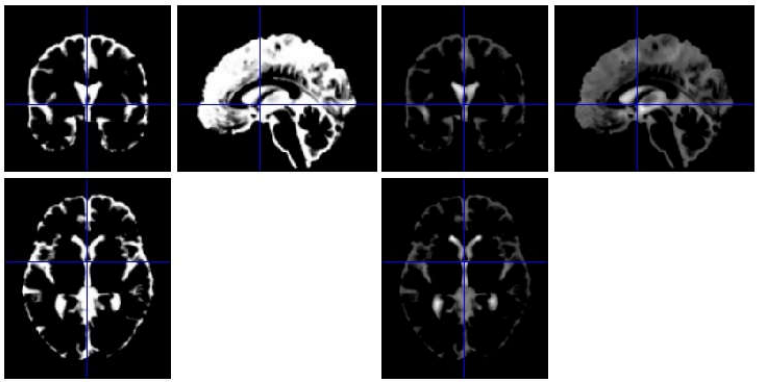
VBM8 kütüphanesi ile normalizasyonlu segmentasyon işlemi hacim bilgisini koruyan modülasyonlu ve konsantrasyon bilgisini koruyan modülasyonsuz görüntü olmak üzere iki şekilde yapılabilmektedir. Modülasyonlu görüntüler MR görüntüsünün alındığı gerçek uzaydaki hacim bilgisini jacobian determinant işlemi ile normalize uzaya taşımaktadır. Modülasyonsuz görüntü ise gerçek uzaydaki voksel konsantrasyonunu normalize uzaya taşımaktadır (Mechelli ve ark., 2005). Her iki görüntü çeşidi tez çalışmasındaki modellerde ihtiyaca göre kullanılmıştır. Her iki görüntü çeşidi VBM8 kütüphanesindeki parametreler ayarlanarak otomatik bir şekilde elde edilebilir. OAS1_0028 nolu deneğin Şekil 4.13a'da GM modülasyonsuz görüntüsü, Şekil 4.13b'de GM modülasyonlu görüntüsü, Şekil 4.13c'de BM modülasyonsuz görüntüsü, Şekil 4.13d'de BM modülasyonlu görüntüsü, Şekil 4.13e'de BOS modülasyonsuz görüntüsü, Şekil 4.13f'de BOS modülasyonlu görüntüsü verilmektedir.



(a) (b)



(c) (d)

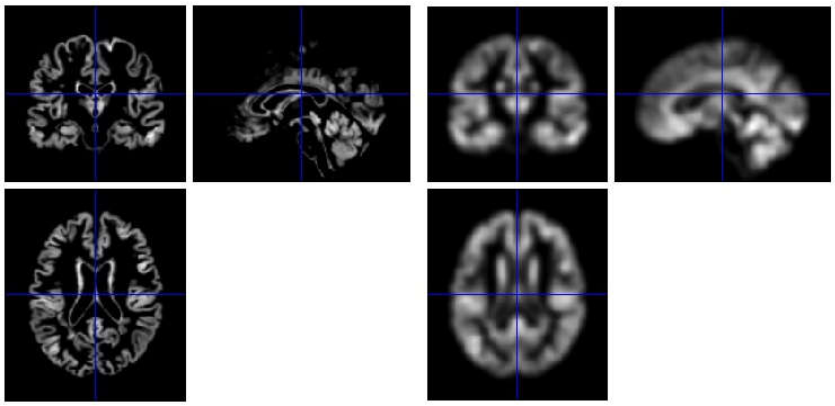


(e) (f)

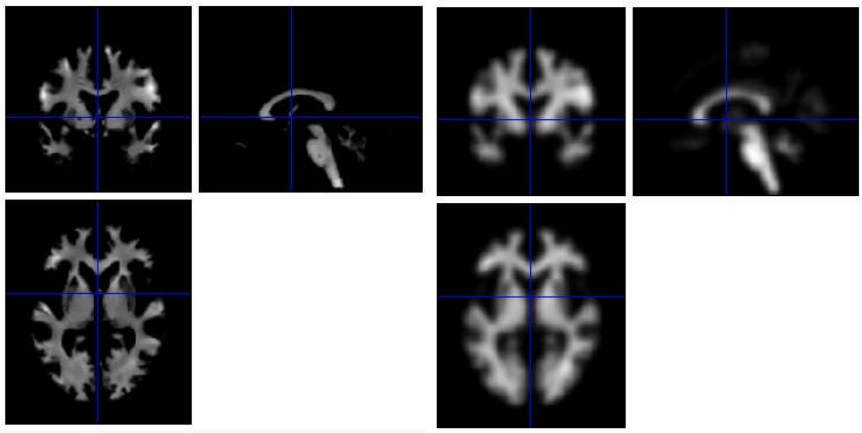
Şekil 4.13. (a) Modülasyonsuz GM (b) Modülasyonlu GM (c) Modülasyonsuz BM (d) Modülasyonlu BM (e) Modülasyonsuz BOS (f) Modülasyonlu BOS

4.3.8. Yumuşatma

Yumuşatma işlemi normalize segmente edilmiş görüntülerin bir gauss filtre ile yumuşatılmasıdır. Bu filtre ile görüntü konvolüsyon işlemine tabi tutulur. Yumuşatma işlemi fonksiyonel MR ve yapısal MR görüntülerinin grup analizlerinde sıklıkla kullanılır. Bu işlemin amacı grup analizi sırasında görüntülerde analiz sonuçlarını olumsuz etkileyebilecek voksel değerlerini yok etmektir. Böylece işlemin istatistiksel gücü arttırılır. Yumuşatma işleminde en önemli parametre gauss filtresinin *Full Width at Half Maximum* (FWHM) büyüklüğüdür (Ashburner ve ark., 2008; Şenvardar, 2011). Yumuşatma tez çalışmasında voksel tabanlı morfometri işlemi sırasında kullanılmaktadır. Modülasyonlu ve modülasyonsuz normalize GM ve BM görüntüleri SPM8 programının varsayılan değeri olan 8*8*8 mm FWHM ile yumuşatılmıştır. Bu işlemden sonra yumuşatılmış görüntüler VTM analizi için SPM programına girdi olarak verilmiştir. Şekil 4.14'te FWHM ile yumuşatılmış modülasyonlu OAS1_0028 GM ve BM görüntüleri gösterilmektedir.



(a) (b)



(c) (d)

Şekil 4.14. (a) Modülasyonlu GM (b) FWHM ile yumuşatılmış modülasyonlu GM (a) Modülasyonlu BM (b) FWHM ile yumuşatılmış modülasyonlu BM

4.3.9. Birlikte Çakıştırma

Birlikte çakıştırma (*coregister*) görüntü boyutu ve voksel boyutu farklı olan iki görüntünün aynı boyutlara getirilme işlemidir. Bu işlem SPM8 programının *Coregister-Reslice* aracı ile yapılmaktadır. Araca giriş olarak kaynak ve referans görüntüler verilir, parametre olarak istenen interpolasyon işlemi girilir. Kaynak görüntü referans görüntüye göre tekrar dilimlenerek görüntü ve voksel boyutları aynı değerlere getirilir. Böylece iki görüntü için standartlar sağlandığından aynı kesitler üzerinde istenen işlemler yapılır. Tez çalışmasında bu işlem WFU PickAtlas ile üretilen lokal beyin maskelerinin segmente edilen GM görüntü boyutlarına getirilmesi için kullanılmıştır (Ashburner ve ark., 2008).

5. MATERYAL VE YÖNTEM

Tez çalışmasında üç boyutlu yapısal beyin AH MR görüntülerinde özellik çıkarma ve sınıflandırma işlemi için farklı senaryolar ve yaklaşımlar önerilmiştir. 3B MR görüntüleri birbirini takip eden kesitlerden oluştuğu için komşuluklar dikkate alınmalıdır. Literatürde yapılan bazı özellik çıkarma ve sınıflandırma işlemleri tek kesit veya birkaç kesit üzerinden yapılarak komşulukları dikkate almadığı için güvenilirlikleri problemlidir. Tez çalışmasında MR görüntülerinde üç boyutlu uzayda komşuluklar dikkate alınarak özellik çıkarma işlemi için hacim, simetri ve doku özelliklerine yoğunlaşılmıştır. Hacimsel değişimler AH'de lokal ve global olmak üzere ikiye ayrılabilir. Bu bölge hacimlerinin sayısal yöntemlerle analizinin yapılabilmesi için bölgelerin segmentasyonunun yapılması gerekmektedir. Hacim analizlerinin yapılması için gerekli olan segmentasyon metotları ve hacimsel analiz araçları detaylı bir şekilde incelenmiştir. Simetri bozulması AH'de beyinde meydana gelen değişikliklerden bir diğeridir. İnsan beyni neredeyse simetriktir. AH'de bu simetri gittikçe bozulmaktadır. Dolayısıyla karar destek sistemi için bir öznitelik anlamı taşımaktadır. Literatürde yapılan çalışmalarda simetri bozulmasının sayısal yöntemlerle modellenmesinin problemli olduğu belirtilmektedir. Tez çalışmasında simetri bozulması için yeni modeller farklı senaryolar için önerilmiştir. Bir diğer özellik çıkarma metodu olarak doku analizi yöntemleri incelenmiştir. AH'de hacimsel kayıplar meydana geldikçe ilgili bölgelere beyin omurilik sıvısı dolmaktadır. Bu bölgelerdeki beyaz madde ve gri madde hacim kayıplarından dolayı ilgili bölgelerde örüntü beyazımsı veya grimsi tonlardan siyah tonlara doğru dönüşmektedir. Ancak hangi bölgelerde ne kadar doğrulukla hacimsel kayıpların bulunduğunun sayısal olarak belirlenmesi başlı başına bir problemdir. Bu problemin üstesinden gelmek için voksel tabanlı morfometri ile ilgili bölgelerin farklı senaryolar için hacim kayıp maskeleri türetilmiştir. Bu binary maskeler ile görüntülere maskeleme işlemi yapılarak ilgili bölge segmentasyonu yapılmıştır. Bu bölgelerde komşuluklar dikkate alınarak 3B ayrık dalgacık dönüşümü, 3B gri seviye eş oluşum matrisleri, voksel değerleri ile direkt örüntü oluşturma ve histogram tabanlı birinci dereceden istatistikler kullanılarak özellikler çıkarılmıştır. VTM maskeleri ile yapılan birçok sınıflandırma senaryosu literatürde ilk defa bu tez ile tanımlanmıştır. Özellik havuzunun oluşturulması ve özellik boyutlarının büyük olması boyutun laneti problemini meydana getirmiştir. Bu problemi aşabilmek için yoğun bir literatür araştırmasından sonra özellik derecelendirme (*feature ranking*) yöntemi ile özellik

azaltma ve seçme işlemi yapılmıştır. Özellik derecelendirme bazı kriterlere göre verileri en anlamlıdan en anlamsıza doğru derecelendirmektedir. Bu veriler sırayla birleştirilip destek vektör makinalarına 10 kat çapraz geçerleme ile verilerek sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonuçları özgüllük, hassasiyet, doğruluk ve eğri altında kalan alan performans kriterlerine göre değerlendirilmiştir. Veri kümesi OASIS veri tabanından 70 AH ve 70 NK MR görüntüleri alınarak oluşturulmuştur. Bu veri kümesinin oluşturulmasında 65 yaş risk faktörü dikkate alınmış, segmentasyon işlemi sırasında bozulma gösteren veriler kovaryans kalite kontrol aracı ile belirlenerek çalışmadan çıkarılmıştır. OASIS veri tabanında en yüksek sınıflandırma doğruluğunu veren sınıflandırma modelleri belirlenerek Selçuk Üniversitesi Tıp Fakültesi veri tabanından alınan 21 AH MR görüntüsü ile validasyon işlemi yapılmıştır.

5.1. Veri Kümesi

5.1.1. OASIS Veri Tabanı

Veri kümesi üç boyutlu MR görüntülerinden oluşan OASIS veri tabanından elde edilmiştir. Veri kümesi oluşturulurken 65 yaş AH'de bir risk faktörü olduğu için bu yaş üzeri veriler alınmıştır. OASIS veri tabanında hâlihazırda önişlemeleri yapılmış ve talairach eksenine çakıştırılmış veriler bulunmaktadır. Ancak özellikle hacim analizi yapılırken önişleme yapılmış verilerin kullanılması sonuçlarda yanlışlık ortaya çıkaracaktır. Talairach eksenine çakıştırılmış verilerin MR cihazından çekilmiş olduğu gerçek uzaydaki hacim bilgisi kaybolmuştur. Bir başka problem ise talairach eksenine çakıştırılmış görüntülerin tekrar MNI uzayına normalize edilmesinin veri kayıplarına neden olmasıdır. Bu nedenle OASIS veri tabanından önişlemeye tabi tutulmamış *"OAS1_xxxx_MRy_mpr _ni_anon_sbj_111"* ön ekli, 256*256*160 görüntü boyutlu, 1*1*1 voksel boyutlu sagittal görüntüler alınmıştır. Bu görüntülerin çekim protokolleri TR= 9.7 msn, TE= 4.0 msn, FA= 10, TI= 20 msn, TD= 200 msn olmak üzere Siemens (Erlangen, Germany) marka 1.5 T cihaz ile alınan *Magnetization Prepared Rapid Gradient-Echo* (MP-RAGE) uzantılı volümetrik görüntü ve NIfTI dosya formatı şeklindedir (Marcus ve ark., 2007).

Literatürde veri kümesinin oluşturulması için genel olarak bir standart görülmemektedir. Her çalışma kendi içinde bir veri kümesi tanımlamıştır. Sınıflandırma sonuçları diğer çalışmalardaki veri kümeleri de verilerek karşılaştırmalar yapılmaktadır.

Tez çalışmasında oluşturulan kümelerin dağılımına istatistiksel olarak yaş açısından bakılmıştır. İki gruptaki yaş dağılımları birleştirilerek *Kolmogorov-Smirnov* normal dağılım testi SPSS istatistik programı ile uygulanmıştır (Wilcox, 2005; Güriş ve Astar, 2014). Akabinde AH ve NK kümelerinin yaş dağılımı bağımsız örneklem t-testi ile incelenerek iki küme yaş dağılımı arasında anlamlı bir fark olup olmadığı incelenmiştir. Diğer bir veri kontrol işlemi GM, BM, BOS segmentasyon işlemi yapıldıktan sonra görüntülerde kalite analizinin yapılmasıdır. Bu işlem için VBM8 kütüphanesinde *Check sample homogeneity using covariance* aracı ile normalize segmente (NS) ve modülasyonlu normalize segmente (MNS) görüntülerin kovaryans analizi yapılmıştır. Bu araç tüm segmente edilmiş görüntülerin birbirlerine ne kadar yakın hareket ettiğini analiz ederek bir kutu-bıyık grafiği çıktısı vermektedir. Grafik üzerinde aykırı hareket eden veriler çalışmadan çıkarılmıştır. Aykırı veriler segmentasyon işlemi sırasında verinin bozulduğunu göstermektedir. Bu problem görüntü orijinin tam oturmaması veya bias gürültünün doğru bir şekilde temizlenememesinden kaynaklanmaktadır (Kurth ve ark., 2015). Literatürde bazı kaynaklarda bu kalite kontrol işlemi yapılsa da birçok çalışmada göz ardı edilmiştir. Kalite kontrol analizi, 65 yaş faktörü etkileri elendikten sonra veri kümesi yaş değişiminin normal dağılım testleri yapılarak OASIS veri tabanından 70 AH ve 70 NK veri kümesi oluşturulmuştur. Çizelge 5.1'de hazırlanan veri kümesinin demografik dağılımı ve nöropsikolojik test sonuçları dağılımı verilmiştir. Ek1'de tez çalışmasında OASIS veri tabanından oluşturulan verilerin numaraları ve demografik dağılımları detaylı bir şekilde verilmiştir. Şekil 5.1'de tüm görüntülerin yaş dağılımlarının histogram ve normal dağılım grafikleri verilmiştir. Şekil 5.2'de normalize segmente edilmiş NS ve MNS GM görüntüler için kovaryans analizi kutu-bıyık grafikleri verilmiş, aynı analiz modülasyonlu ve modülasyonsuz BM ve BOS için de yapılmıştır. Her iki denek grubunun toplam yaş dağılımının Kolmogorov-Smirnov normal dağılım testine bakıldığında $p=0.200$ ($p>0.05$) olarak bulunmaktadır. NK ve AH arasındaki yaş farkına bağımsız örneklem t-testi ile bakıldığında $p=0.915$ ($p>0.05$) bulunmaktadır. Bu sonuçlar AH ve NK arasındaki yaş dağılımında anlamlı bir fark olmadığını ve toplam yaş dağılımının normal dağılıma uyduğunu göstermektedir.

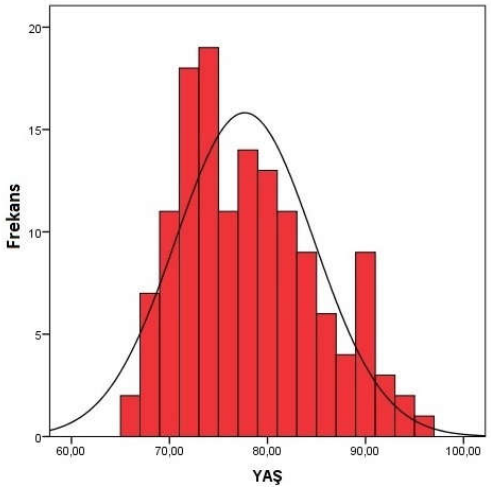
Çizelge 5.1. OASIS veri tabanından oluşturulan NK ve AH MR görüntülerinin demografik ve nöropsikolojik test sonuçları dağılımı

NORMAL KONTROL

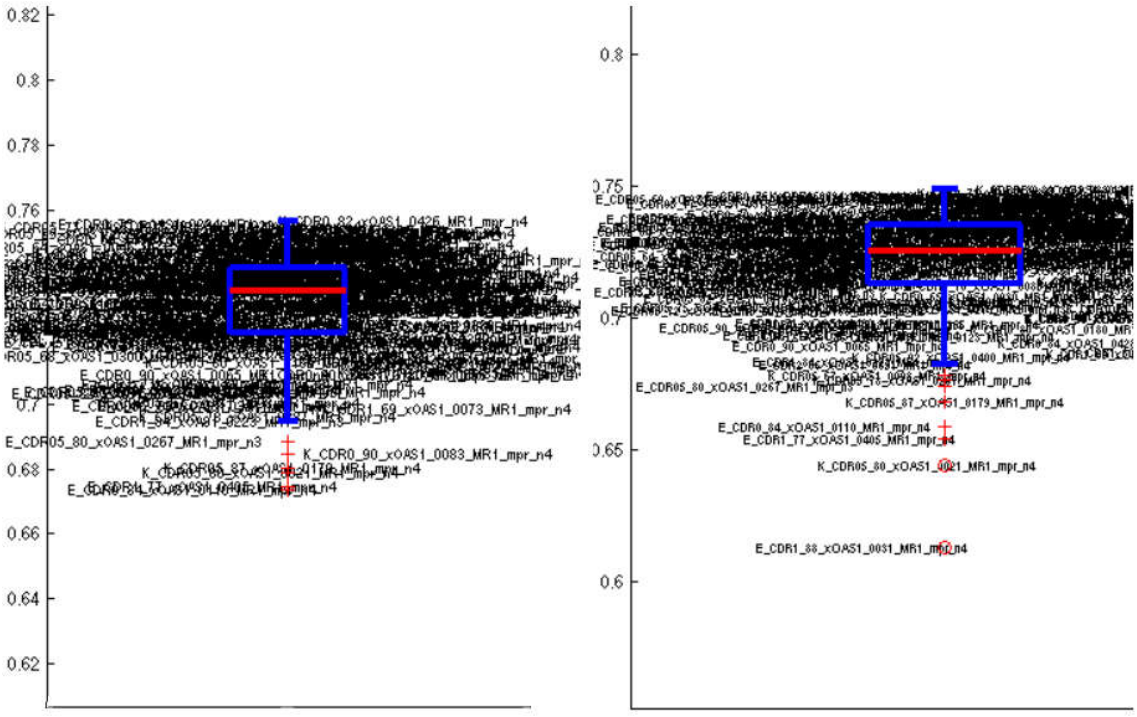
Yaş Grubu	Adet	E\K	Ort. Yaş.	Ort.MMSE	KDR
60s	9	3\6	68.00±1.11	28.77±1.64	0
70s	32	8\24	73.37±2.44	29.15±0.91	0
80s	22	6\16	83.40±3.27	28.77±1.26	0
90s	7	1\6	91.14±1.67	28.57±1.71	0
TOPLAM	70	18\52	77.61±7.48	28.92± 1.21	0

ALZHEİMER HASTA

Yaş Grubu	Adet	E/K	Ort. Yaş.	Ort.MMSE	KDR 0.5\1\2
60s	7	3\4	67.85± 1.21	23.42± 4.85	5\2\0
70s	35	14\21	74.42±2.61	24.54±4.21	23\11\1
80s	23	11\12	82.69± 2.61	24.47 ±4.06	16\6\1
90s	5	2\3	92.00± 2.44	23.80±1.92	4\1\0
TOPLAM	70	30\40	77.74 ±6.66	24.35 ±4.05	48\20\2



Şekil 5.1. Tüm MR görüntüleri için yaş histogramı ve normal dağılım grafiği



(a) (b)

Şekil 5.2. (a) NS GM kovaryans kutu-bıyık grafiği (b) MNS GM kovaryans kutu-bıyık grafiği (Her bir x_CDRx_xOAS1_XXXX_MR1_mpr_n4 deneğe ait özellikleri veren yazı biçimi ve deneğin kod ismidir. Aykırı hareket eden denek isimleri kutu-bıyık grafiği dışında görülmektedir. Denek isimleri grafikte üst üste geldiği için üst üstte binmiş kararmış yazı formatları olarak görülmektedir.)

5.1.2. Tıp Fakültesi Verileri

Tez çalışmasında geliştirilen özellik çıkarma ve sınıflandırma modellerinde OASIS veri tabanı ile eğitim ve test işlemleri gerçekleştirilmiştir. En iyi modeller ortaya konulduktan sonra eğitilmiş sistemler Selçuk Üniversitesi Tıp Fakültesi Nöroloji ve Radyoloji Anabilim Dalları ile ortak alınan MR görüntüleri üzerinde validasyon işlemi uygulanarak sınıflandırma sistemlerinin farklı bir veri kümesindeki performansları analiz edilmiştir. Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalında hâlihazırda çekilen veriler tez çalışması için yeterli değildir. Hastane ortamında genel olarak 5-6.5 mm kesit kalınlığı, kesitler arası boşluklar ve tüm beyin çekimi yerine beynin sadece ihtiyaca göre belli kesitlerinin çekimi gerçekleştirilmektedir. Bunun sebebi çekim için sırada çok sayıda hastanın beklemesi ve radyoloji uzmanının görüntüyü yorumlaması için minimum kesit sayısının yeterliliğidir. Böylece hasta bekleme ve görüntü yorumlama süresinde optimum miktarlar yakalanmak istenmektedir. Ancak tez çalışması için ince kesitli, kesitler arası boşlukların olmadığı volümetrik tüm beyin MR görüntüleri gerekmektedir. Bundan dolayı verilerin

alınmasında OASIS veritabanındaki görüntüleme protokolleri ile aynı olacak şekilde hastaneden 3B beyin MR görüntüleri istenmiştir. Ancak tıp fakültesinde bulunan MR cihazının Siemens marka farklı bir model olması ve görüntülemeyi alacak yeterli donanıma sahip operatörün bulunmaması verilerin farklı bir protokolde alınmasına neden olmuştur. Alınan görüntüler MP-RAGE uzantılı, ince kesitli, kesitlerarası boşluk bırakılmamış 3B volumetrik görüntüler olmasına rağmen diğer parametrelerde değişiklikler görülmektedir. Bundan dolayı OASIS veritabanı ile eğitilen sınıflandırma sistemleri parametre bakımından heterojen bir yapıya sahip olan hastane verileri ile validasyon işlemi yapılmıştır. Literatürde farklı merkezlerden farklı görüntüleme protokolleri ile alınan verilerin analizine çoklu merkez *(multi-center)* çalışmalar denilmektedir. Bu kapsamda farklı merkezlerden farklı görüntüleme protokolü ile alınan MR görüntülerinin sınıflandırma çalışmalarında nasıl kullanıldığı detaylı bir şekilde araştırılmıştır. Hastane verilerinin etiketlenmesi için Washington Üniversitesi tarafından önerilen KDR ölçeği kullanılmıştır. Hastane ortamında alınan verilerde AH'ler özellikle seçilmiş olup diğer demans nedenleri dışlandıktan sonra etiketleme yapılmıştır. Ek2'de Selçuk Üniversitesi Tıp Fakültesi Dekanlığı tarafından verilen Girişimsel Olmayan Klinik Araştırmalar Etik Kurul İzni, Ek3'te Selçuk Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Bilgilendirilmiş Gönüllü Olur Formu Asgari İçeriği, Ek4'te Washington Üniversitesi tarafından önerilen Klinik Demans Derecelendirme skorlama sayfası verilmiştir. Hastane görüntüleme protokolleri TR: 600msn, TE: 7.2msn, FA: 120, kesit kalınlık: 0.9mm, sagittal eksende 256x256 matris boyutlu 192 kesit, MP-RAGE uzantılı 3B volümetrik görüntüler ve DICOM (*Digital Imaging and Communication in Medicine*) dosya formatı şeklindedir. Çizelge 5.2'de Selçuk Üniversitesi Nöroloji ve Radyoloji Anabilim Dallarının beraber çalışması sonucu alınan MR verilerinin KDR ve yaş dağılımları verilmiştir.

Çizelge 5.2. Selçuk Üniversitesi Tıp Fakültesinden alınan verilerin KDR ve yaş dağılımları (H: Hasta)

SN	İSİM	KDR	YAŞ
1	H1	3	65
2	H2	0.5	78
3	H3	0.5	65
4	H4	3	65
5	H5	2	79
6	H6	0.5	78
7	H7	3	47
8	H8	3	47
9	H9	0.5	68
10	H10	3	69
11	H11	1	69
12	H12	3	54
13	H13	3	74
14	H14	3	59
15	H15	2	80
16	H16	3	65
17	H17	3	78
18	H18	1	83
19	H19	3	80
20	H20	2	88
21	H21	0.5	80

5.2. VBM8 Kütüphanesi ile Segmentasyon İşlemi

Üç boyutlu MR görüntüleri eksen dönüştürme ve AC/PC düzeltme önişleme aşamaları yapıldıktan sonra VBM8 kütüphanesine girdi olarak verilmiştir. VBM8 kütüphanesi SPM8 programı içerisinde sadece yapısal MR görüntülerinin analizi için toplanmış bir dizi araçlarla pratik bir kullanım sunmaktadır. SPM8 ile ayrı ayrı yapılabilecek işlemler VBM8 kütüphanesi ile gerekli parametreler ayarlandıktan sonra otomatik olarak tek bir ara yüzle istenen segmentasyon ve normalizasyon çıktıları alınmaktadır. Tez çalışmasında kullanılan MR görüntülerinin gürültü giderme, normalizasyon, segmentasyon, modülasyon işlemleri bu arayüz ile gerçekleştirilmiştir. Özellik çıkarma işlemi için normalize segmente (NS) ve modülasyonlu normalize segmente (MNS) görüntüler kullanılmıştır. Bu görüntülerin VBM8 normalize segmente çıktıları *"wrp"* ve modülasyonlu normalize segmente çıktıları *"mwrp"* önekleri ile elde edilmektedir. Öneklerdeki harfler *"m-modulated, w-warped, r-dartel warped, s-*

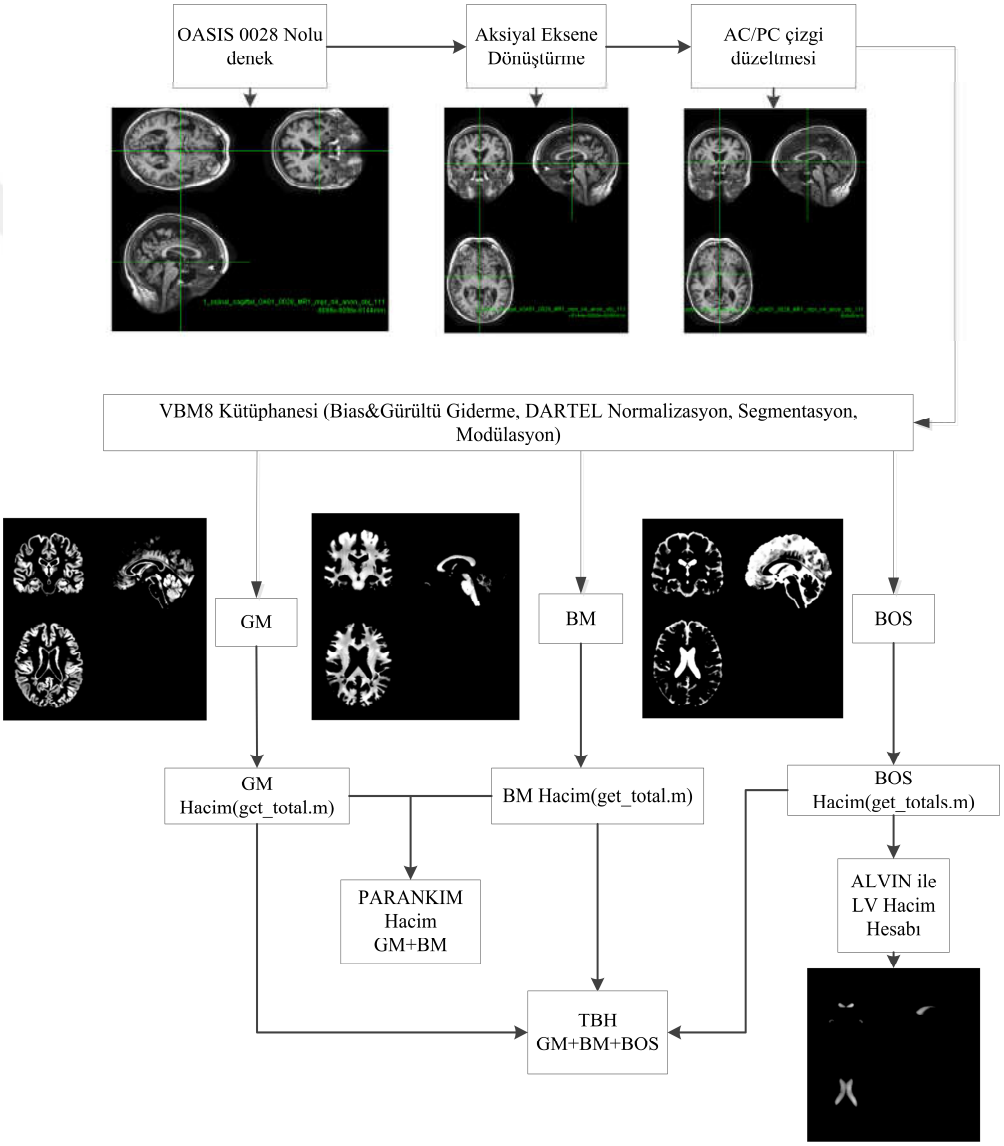
segmented" olarak yapılan işlemlerin kısaltmalarıdır (Kurth ve ark., 2010). MNS GM, BM, BOS görüntüler normalizasyon işleminden sonra gerçek çekim uzayındaki hacmini koruduğu için lokal ve global hacim analizlerinde kullanılmıştır. Simetri işlemleri için hem MNS GM, BM görüntüler hem de NS GM, BM görüntüler kullanılmıştır. Doku analizi işlemlerinde voksel tabanlı morfometri ile maskelerin türetilmesi için hem MNS GM, BM hem de NS GM, BM görüntüler kullanılmış, performans karşılaştırılması yapılmıştır.

5.3. Hacim Analizi

AH başlangıcında ve ileri evrelerinde beyinde meydana gelen hacimsel kayıplar dikkat çeken ilk özniteliklerdir. Bu kayıplara global ve lokal olarak bakılabilir. Hacimsel kayıplar MR görüntülerinde izlenebilse de keskin sınırların manuel olarak çizilmesi son derece zordur. Genel olarak MR görüntüleri hastanelerde manuel olarak yorumlanmaktadır. MR görüntülerinin sayısal metotlarla analizinin çok zaman alması ve bekleyen çok fazla hasta görüntüsünün yorumlama problemi, sayısal analiz yöntemlerini doktorlar açısından güç kılmaktadır. Dolayısıyla görüntüler için hızlı ve alternatif yorumlama çözümleri tıp alanında geliştirilmesi beklenen gelecekteki konulardır. MR görüntülerinde GM, BM ve BOS bölgeleri nispeten gözle ayırt edilebilmektedir. Ancak sınır bölgelerde voksel komşuluklarının hangi bölgeye ait olduğu manuel olarak kestirilemeyebilir. GM üzerinde bulunan alt kortikal bölgeler ise sınırları belli olmamakla beraber tamamen yorumlayan doktorun tecrübesine dayanmaktadır. Tez çalışmasında hem global hem de lokal bölgelerin hacimlerinin hesaplanması için literatürdeki sayısal metotlar incelenmiştir. Literatürde sıklıkla kullanılan Freesurfer (Fischl, 2012) çok süre aldığından ve FSL programı (Jenkinson ve ark., 2012) sadece 15 alt bölge hacmi verdiği için tercih edilmemiştir. Global ve lokal hacimler VBM8 kütüphanesi çıktıları (Kurth ve ark., 2010) ve Ged Ridgway tarafından geliştirilen *"get_totals.m"* MATLAB kod parçası kullanılarak hesaplanmıştır (Anonim, 2017f). Lokal hacimler için WFU PickAtlas ile bölgelerin maskeleri oluşturulmuştur(Maldjian ve ark., 2003; Maldjian ve ark., 2004). Görüntüler ile maskeler arasında boyut uyumsuzlukları birlikte çakıştırma yöntemi ile giderilerek hacim hesapları yapılmıştır.

5.3.1. Global Hacimler

Üç boyutlu MR görüntülerinde global hacim için altı bölgenin segmentasyonu yapılmıştır. GM, BM, BOS, Parankim (GM+BM), Tüm Beyin Hacmi (GM+BM+BOS), Lateral Ventrikül (LV) hacimleri modulasyonlu normalize segmente görüntüler ile hesaplanmıştır. Modulasyonlu görüntüler için gerekli önişlemeler ve hacim hesabı akış diyagramı Şekil 5.3'te gösterilmektedir.



Şekil 5.3. Global hacimlerin hesaplanması için takip edilen akış diyagramı

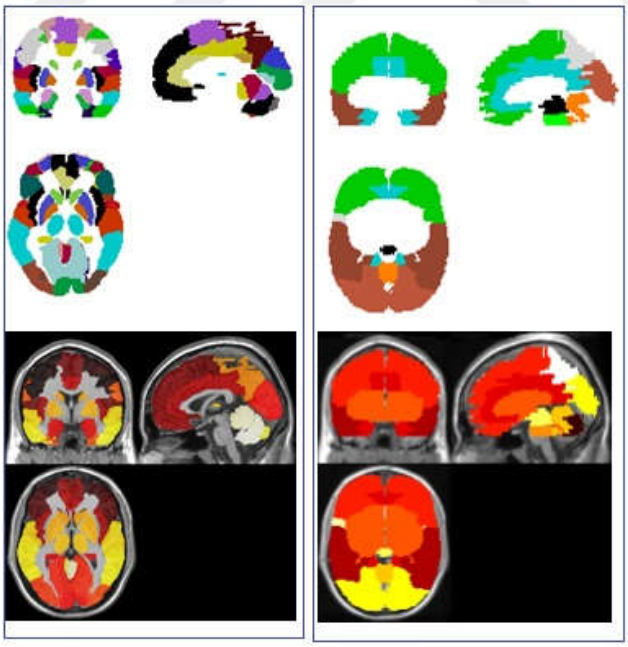
Şekil 5.3'te görüldüğü gibi GM, BM ve BOS görüntüleri segmente edildikten sonra *"get_totals.m"* kod parçası ile hacimleri hesaplanmıştır (Anonim, 2017g; 2017f). Parankim dokusu için GM ve BM hacimleri toplanmış, total beyin hacmi için GM, BM ve BOS toplanmıştır. LV hacmi için ALVIN programı kullanılmıştır (Kempton ve ark.,

2011). Hacmi hesaplanan bu bölgeler AH'de hacimsel artış veya azalma göstermektedir. GM genel olarak azaldığı için bu bölgelere BOS dolmaktadır. Aynı zamanda beynin tam ortasında bulunan LV ise GM ve BM azalmasına mukabil genişlemektedir. BM kayıpları literatürde belirtilse de GM kadar bir hacim azalması meydana gelmemektedir. Ancak beynin içerisindeki katı bölgeyi oluşturan GM ve BM toplamı Parankim (PRNKM) dokusu ise büyük miktarda değişmektedir. Tüm beyin hacmi genel olarak değişmemektedir. Çünkü her ne kadar beyindeki bölgelerin AH'den kaynaklı hacim artış veya azalması meydana gelse de kemik dokusunda bir değişiklik meydana gelmediği için toplam beyin hacmi sabit kalmaktadır. Dolayısıyla TBH değişmese bile diğer beş bölgenin TBH'ye oranı hastalığı tanımlayabilen metriklerdir. Aynı zamanda diğer bölgelerin birbirine oranı da hastalığı tanımlayan metriklerdir. Bu oranların bir kısmı literatürde daha önce tanımlanmamış oranlardır. Bu amaçla elde edilen altı bölgenin farklı kombinasyonlarından 26 adet metrik oluşturulmuştur. Bu metriklerden 140x26 matris büyüklüğü olan özellik kümesi oluşturularak sınıflandırma çalışmaları yapılmıştır.

5.3.2. Lokal Hacimler

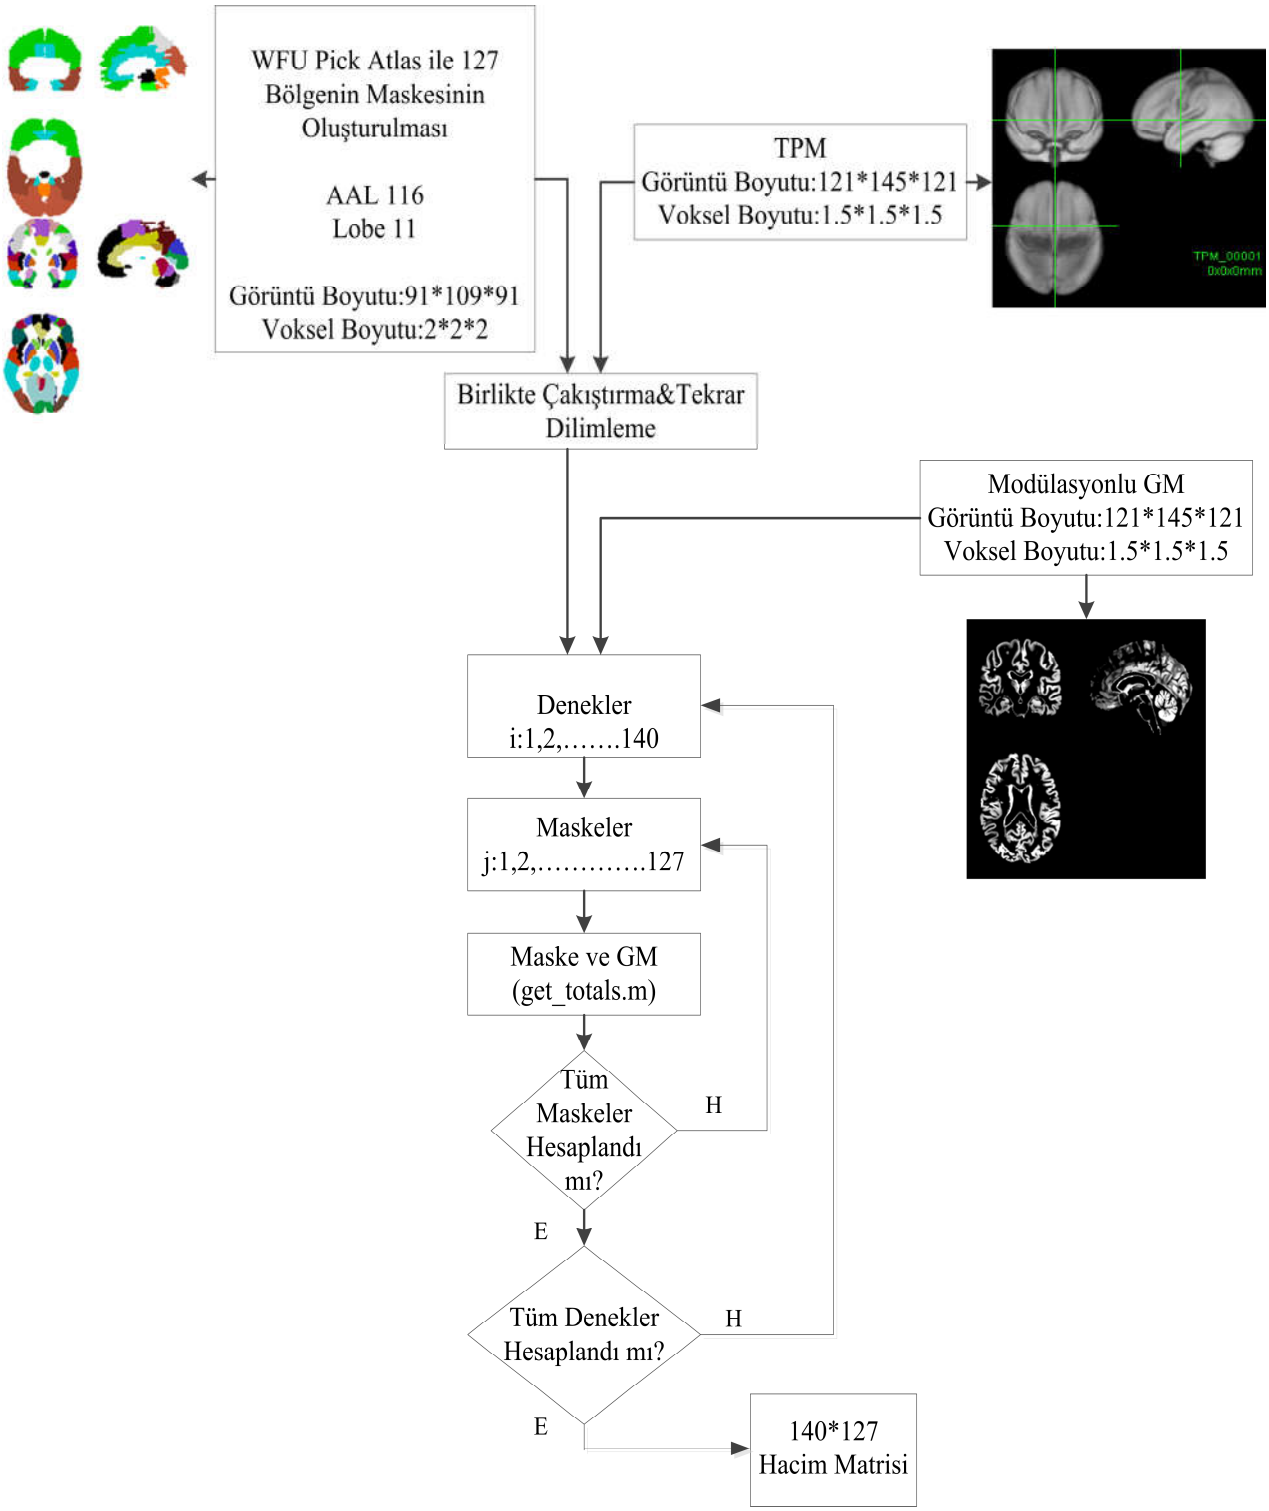
Lokal bölgeler GM içindeki fonksiyonel bölgelerdir. Ancak bu bölgelerin net sınırları GM üzerinde görülememektedir. Bu bölgelerin analizi radyolog veya nörologlar tarafından manuel bir şekilde yorumlanmaktadır. Bu bölgelerin segmentasyonu doktorlar tarafından yapılsa da göreceli olacaktır. Bu bölgelerin segmentasyonu ve hacim analizi için uluslararası standartlarda belirlenmiş ve güvenilirliği kabul edilmiş üç boyutlu elektronik beyin atlasları kullanılmaktadır (Anonim, 2017g). Literatürde popüler bir şekilde yer alan *Automated Anatomical Labeling* (AAL) (Tzourio-Mazoyer ve ark., 2002) ve Talairach tarafından önerilen talairach lob atlası (Talairach ve Tournoux, 1988; Lancaster ve ark., 2000) tez kapsamında kullanılmıştır. Elektronik beyin atlaslarının maskeleri MATLAB tabanlı WFU PickAtlas kütüphanesi ile türetilmiştir (Maldjian ve ark., 2003; Maldjian ve ark., 2004). WFU PickAtlas ile elde edilen maskeler MNI uzayına oturtulmuş bir şekilde türetilmektedir (Maldjian, 2017). Ancak görüntüler ile atlas maskeleri arasında hem görüntü boyutu hem de voksel boyutu uyumsuzdur. Bu uyumsuzluğu gidermek için VBM8'de GM için kullanılan *Tissue Probability Map* (TPM) olasılık haritaları ve SPM8 *Coregister-Reslice* işlemi kullanılmıştır. Görüntüler TPM uzayına normalize

edildiği için referans görüntüye TPM ve kaynak görüntüye binary maskeler girilerek interpolasyon işlemi *Nearest Neighbour* olarak seçilmiştir. Bu işlem ile hem modülasyonlu görüntüler hem de atlas maskeleri voksel ve görüntü boyutu olarak aynı boyutlara getirilmiştir. Boyut uyumsuzluğu giderildikten sonra modülasyonlu GM görüntüler ve maskeler *"get_totals.m"* koduna verilmiştir (Anonim, 2017g; 2017f). Böylece AAL atlas ile 116 bölge, TD lob maskeleri ile 11 lob bölgesinin hacim hesabı yapılmıştır. Bu işlem için görüntü ve maskeleri bir döngü halinde otomatik olarak alan bir kod parçası geliştirilmiştir. Böylece sınıflandırma aşaması için 140x127 lik bir hacim matrisi oluşturulmuştur. Ancak her insanda kafa büyüklüğü farklı olduğu için analizlerde görecelik olmaması amacıyla normalizasyon yapılması önerilmektedir (Whitwell ve ark., 2001). Tez çalışmasında ham lokal hacim verilerinin GM, PRNKM ve TBH oranları da hesaplanarak normalizasyon yapılmamış veriler ile beraber dört farklı senaryo için sınıflandırma performans analizi yapılmıştır. Şekil 5.4'te AAL ile TD lob atlasları ve yapısal MR görüntülerine çakıştırılmış görüntüleri verilmiştir. Şekil 5.5'te modulasyonlu GM görüntüler ile atlas maskeleri arasındaki boyut uyuşmazlıkların giderilmesi ve hacim hesabı bir akış diyagramı halinde verilmiştir.



(a) (b)

Şekil 5.4. (a) AAL atlas ve yapısal MR görüntüsüne çakıştırılması (b) TD Lob atlas ve yapısal MR görüntüsüne çakıştırılması



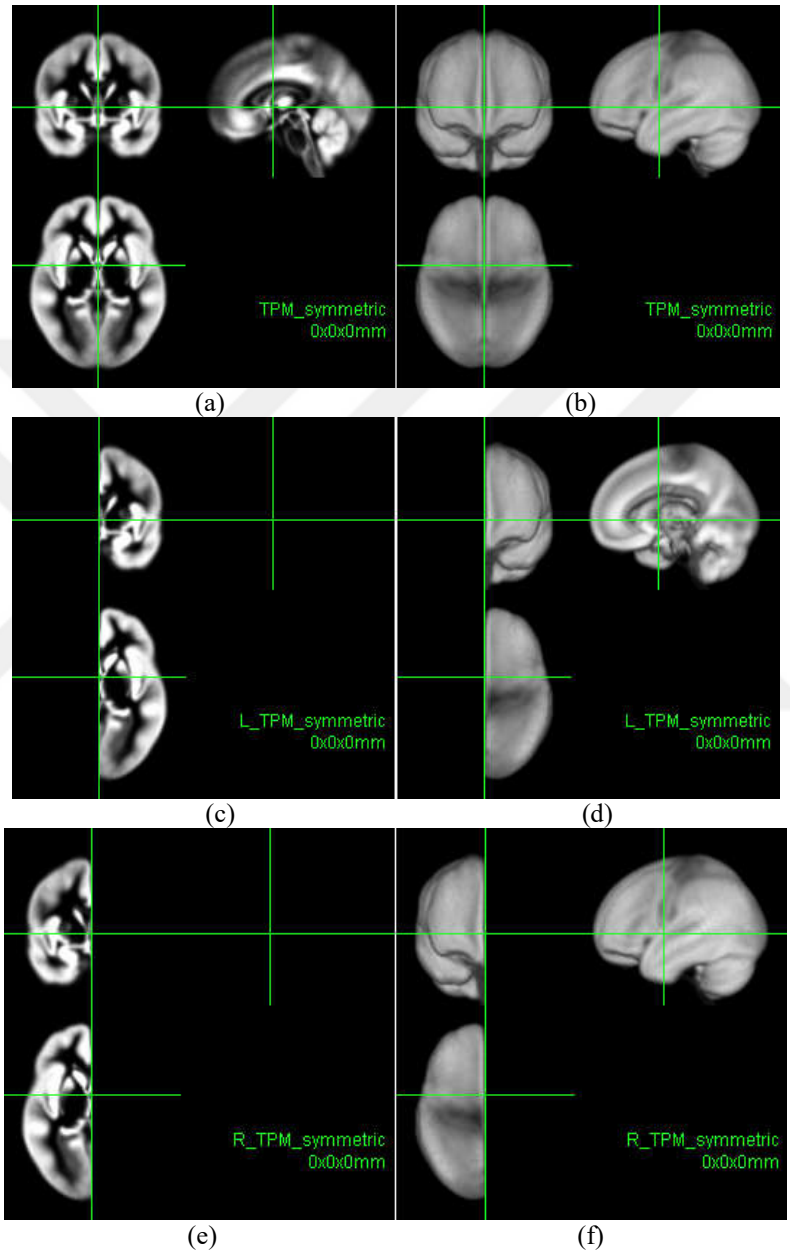
Şekil 5.5. Modülasyonlu GM görüntüler ile atlas maskeleri boyut uyuşmazlıkların giderilmesi ve hacim hesabı için akış diyagramı

5.4. Simetri Analizi

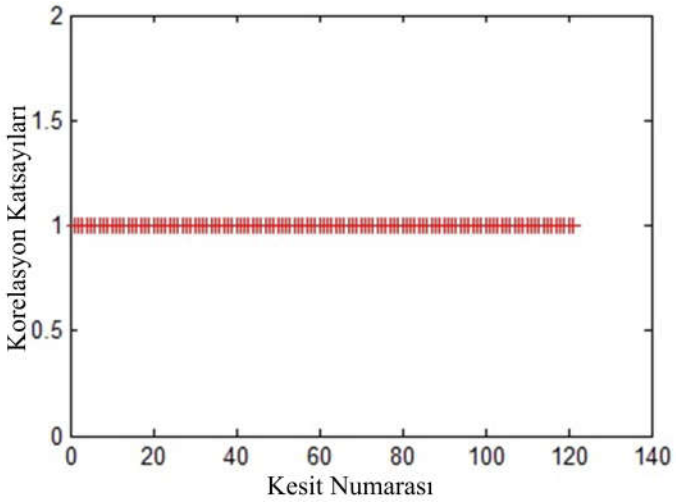
İnsan beyni sağ ve sol olmak üzere iki yarım küreden oluşmaktadır. Bu iki yarım küre tam olmasa da neredeyse simetriktir (Maes ve ark., 1999). Ancak AH'nin beyinde meydana getirdiği hacimsel kayıplar ve dokusal bozukluklardan dolayı simetri zamanla değişmektedir. Bu değişme nörolojik hastalıların erken safha teşhislerinde ve hastalığın zamanla beyinde meydana getirdiği farklılığın takip edilmesinde bir biyoişaretçi olarak kabul edilir (Liu, 2009). Ancak beyinde oluşan simetri değişiminin sayısal yöntemlerle analizinin problemli olduğu belirtilmektedir (Fan ve ark., 2008). Sağ ve sol yarımküre hacim oranları (Heckemann ve ark., 2011), görüntünün aynalanması ve birbirinden çıkarılması (Hopkins ve ark., 2008), voksel tabanlı simetri analizi (Luders ve ark., 2004) genel olarak kullanılan yöntemlerden bazılarıdır. Beyinde önce hafıza bölgelerinde başlayan dejenerasyon zamanla diğer bölgelere yayılır. Bu hacim kaybı aynı zamanda lokal ve global bölgelerde simetrinin bozulmasına neden olur. AH'de gri madde (Derflinger ve ark., 2011), temporal, parietal, prefrontal (Minoshima ve ark., 1995) gibi bölgelerde bileteral bozulmalar belirlenmiştir.

MR görüntülerinin simetri ekseninin bulunması için literatürde birçok çalışma yapılmıştır. Yapılan çalışmalar genellikle tek bir kesit üzerinden yapılmaktadır (Liu ve ark., 1998; Kuijf ve ark., 2013). Ancak simetri bozulmasının analiz edilmesi için birbirini takip eden kesitlere bakmak çalışmaların güvenilirliğini arttıracak bir etkendir. Çünkü simetri bozulması ile meydana gelen değişiklik bilgisi komşu kesitler ile beraber saklanmaktadır. Bu amaçla bu çalışmada üç boyutlu bir simetri ekseni alınarak tüm bir yığın tam ortadan ikiye bölünmüştür. Görüntüler MNI uzayına normalize edilip segmente edildikten sonra orta sagittal düzlemden ikiye bölünmelidir. Orta sagittal düzlem (x,y,z)=0'dan geçen ve beyni tam ortadan ikiye ayıran düzlemdir. GM görüntüleri normalizasyon ve segmentasyon işlemlerinden sonra 121*145*121 boyutlarına dönüşmektedir. X yönünde 121 kesit bulunmaktadır. Görüntü eğer x=61 kesitten ikiye ayrılırsa görüntü simetrik olarak ikiye ayrılır. Bu işlemin validasyonu Şekil 5.6'da verilen "TPM_symmetric" şablon üzerinde yapılmıştır (Anonim, 2017l). Bu şablonun sağ ve sol yarımkürelerindeki voksel değerleri aynı gri ton değerlerini taşımaktadır. X=61 düzleminden ikiye bölündükten sonra her bir kesit aynalanarak birbirine göre iki boyutlu korelasyon işlemi yapılmıştır. Korelasyon işlemi sonucunda her bir kesit için katsayının bir çıkması şablon görüntünün tam ortadan ikiye ayrılmasının validasyonudur. Bu sonuçlarda görüntüde alınan düzlemin doğru olduğunu

göstermektedir. Şekil 5.6a ve 5.6b'de sırasıyla TPM_symmetric ve 3D modeli (Anonim, 2017l), Şekil 5.6c ve 5.6d'de önerilen yöntem ile ayrılmış sol yarımküre ve 3B modeli, Şekil 5.6e ve 5.6f'de önerilen yöntem ile ayrılmış sağ yarımküre ve 3B modeli verilmiştir. Önerilen düzlem bulma yöntemi ile ayrılan her bir kesitin kesit içi korelasyon sonuçları Şekil 5.7'de gösterilmektedir.



Şekil 5.6. (a) TPM_symmetric template (b) TPM_symmetric template 3B Model (c) TPM_symmetric template sol yarımküre(d) TPM_symmetric template sol yarımküre 3B model (e) TPM_symmetric template sağ yarımküre (f) TPM_symmetric template sağ yarımküre 3B model



Şekil 5.7. TPM_ symmetric template sağ ve sol yarımküre korelasyon katsayılarının kesit numaralarına göre çizimi

Orta sagittal düzlem validasyon işleminden sonra MNS GM, BM ve NS GM, BM görüntüler belirtilen model ile iki yarım küreye bölünmüştür. İki yarım küre görüntüsünde siyah olan bölgeler görüntülerden atılmıştır. Daha sonra sağ yarım küre görüntüsü sol yarım küre koordinatlarına aynalanmıştır. Bu işlemden sonra simetri analizi için iki farklı yaklaşım önerilmiştir. Görüntülerin ikiye bölünmüş durumları genellikle kalite ölçüm için kullanılan *The Peak-Signal-to-Noise Ratio* (PSNR) ve *The Structural Similarity Index Measure* (SSIM) metrikleri kullanarak iki yarımküre arasındaki değişikliklerin katsayıları bulunmuştur. Diğer yaklaşım ise aynalan görüntüler bir vektöre dönüştürülerek iki yarım küre arasındaki uzaklık ve benzerlik katsayılarının hesaplanmasıdır. Bu iki yaklaşımda literatürde ilk defa önerilmektedir. Eğer AH beyinde var olan yüksek simetriyi bozuyorsa iki yarım küre görüntülerinin önerilen katsayılarının farklı olması düşüncesi ile bu fikir ileri sürülmüştür.

PSNR ve SSIM metrikleri genellikle görüntülerde kalite ölçümü için kullanılmaktadır. Bu ölçümler görüntüler üzerinde herhangi bir işlem uygulandıktan değişimin iyi veya kötü olduğunu belirler. Gürültü giderme ve görüntü sıkıştırmada sıklıkla kullanılır (Hore ve Ziou, 2010). SSIM Wang ve ark. tarafından geliştirilen ve iki görüntü arasında benzerliği ölçerek kalite ölçen bir yöntemdir (Wang ve ark., 2004). *"x"* ve *"y"* iki görüntü olmak üzere *MxN* resim boyutudur. Ortalama karesel hata *Mean Square Error* (MSE) değeri PSNR hesabı için gerekli bir metriktir. MSE sıfıra yaklaştıkça PSNR sonsuza yaklaşır. μ_x, μ_y, σ_x, σ_y, σ_{xy} sırasıyla görüntülere ait piksel yoğunluk ortalaması, standart sapmasını ve ortak kovaryansı vermektedir. MSE'nin matematiksel tanımı Eşitlik 5.1'de (Hore ve Ziou, 2010), PSNR'ın matematiksel tanımı

Eşitlik 5.2'de (Hore ve Ziou, 2010) ve SSIM'ın matematiksel tanımı Eşitlik 5.3'te verilmiştir (Boztoprak, 2016). (C_1 ve C_2 sabitler, A gri seviye sayısı)

$$MSE(x,y) = \frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}\left(x_{ij} - y_{ij}\right)^2 \tag{5.1}$$

$$PSNR(x,y) = 10\log_{10}(A^2 / MSE(x,y)) \tag{5.2}$$

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_x\sigma_y + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \tag{5.3}$$

Aynalan görüntülerin bir boyutlu vektör olarak dönüştürülmesi ile istatistikte sıklıkla kullanılan öklit, kare öklit, cityblock, minkowski, chebyshev, korelasyon, hamming, kosine, spearman benzerlik ve uzaklık katsayıları bulunmuştur. Bu yöntemler iki adet verinin birbirine ne kadar yakın hareket ettiğinin benzerlik veya uzaklık katsayılarını vermektedir. Bu yaklaşım AH'de iki yarım küre arasında aynı koordinatlara denk gelen noktalar vektörlerinin simetrik olarak ne kadar değiştiği hakkında katsayılar türetecektir. *"p"* değişkenli bir yapıda *i.* ve *j.* gözlemler arasında x_{ik} *i.* gözlemin *k.* Değişkeni, x_{jk} *j.* gözlemin *k.* değişkeni olmak üzere Eşitlik 5.4'te öklit, Eşitlik 5.5'te kare öklit, Eşitlik 5.6'da cityblock, Eşitlik 5.7'de minkowski, Eşitlik 5.8'de chebyshev, Eşitlik 5.9'da korelasyon, Eşitlik 5.10'da hamming, Eşitlik 5.11'de kosine, Eşitlik 5.12'de spearman denklemleri verilmiştir (Alpar, 2011; Anonim, 2017e).

$$d_{ij} = \sqrt{\sum_{k=1}^{p}(x_{ik} - x_{jk})^2} \tag{5.4}$$

$$d_{ij} = \sum_{k=1}^{p}(x_{ik} - x_{jk})^2 \tag{5.5}$$

$$d_{ij} = \sum_{k=1}^{p}\left|x_{ik} - x_{jk}\right| \tag{5.6}$$

$$d_{ij} = \left[\sum_{k=1}^{p}\left|x_{ik} - x_{jk}\right|^m\right]^{1/m} \tag{5.7}$$

$$d_{ij} = \max_k\left\{\left|x_{ik} - x_{jk}\right|\right\} \tag{5.8}$$

$$d_{ij} = 1 - \frac{(x_i - \bar{x_i})(x_j - \bar{x_j})'}{\sqrt{(x_i - \bar{x_i})(x_i - \bar{x_i})'}\sqrt{(x_j - \bar{x_j})(x_j - \bar{x_j})'}} \tag{5.9}$$

$$\bar{x_i} = \frac{1}{p}\sum_k x_{ik} \qquad \bar{x_j} = \frac{1}{p}\sum_k x_{jk}$$

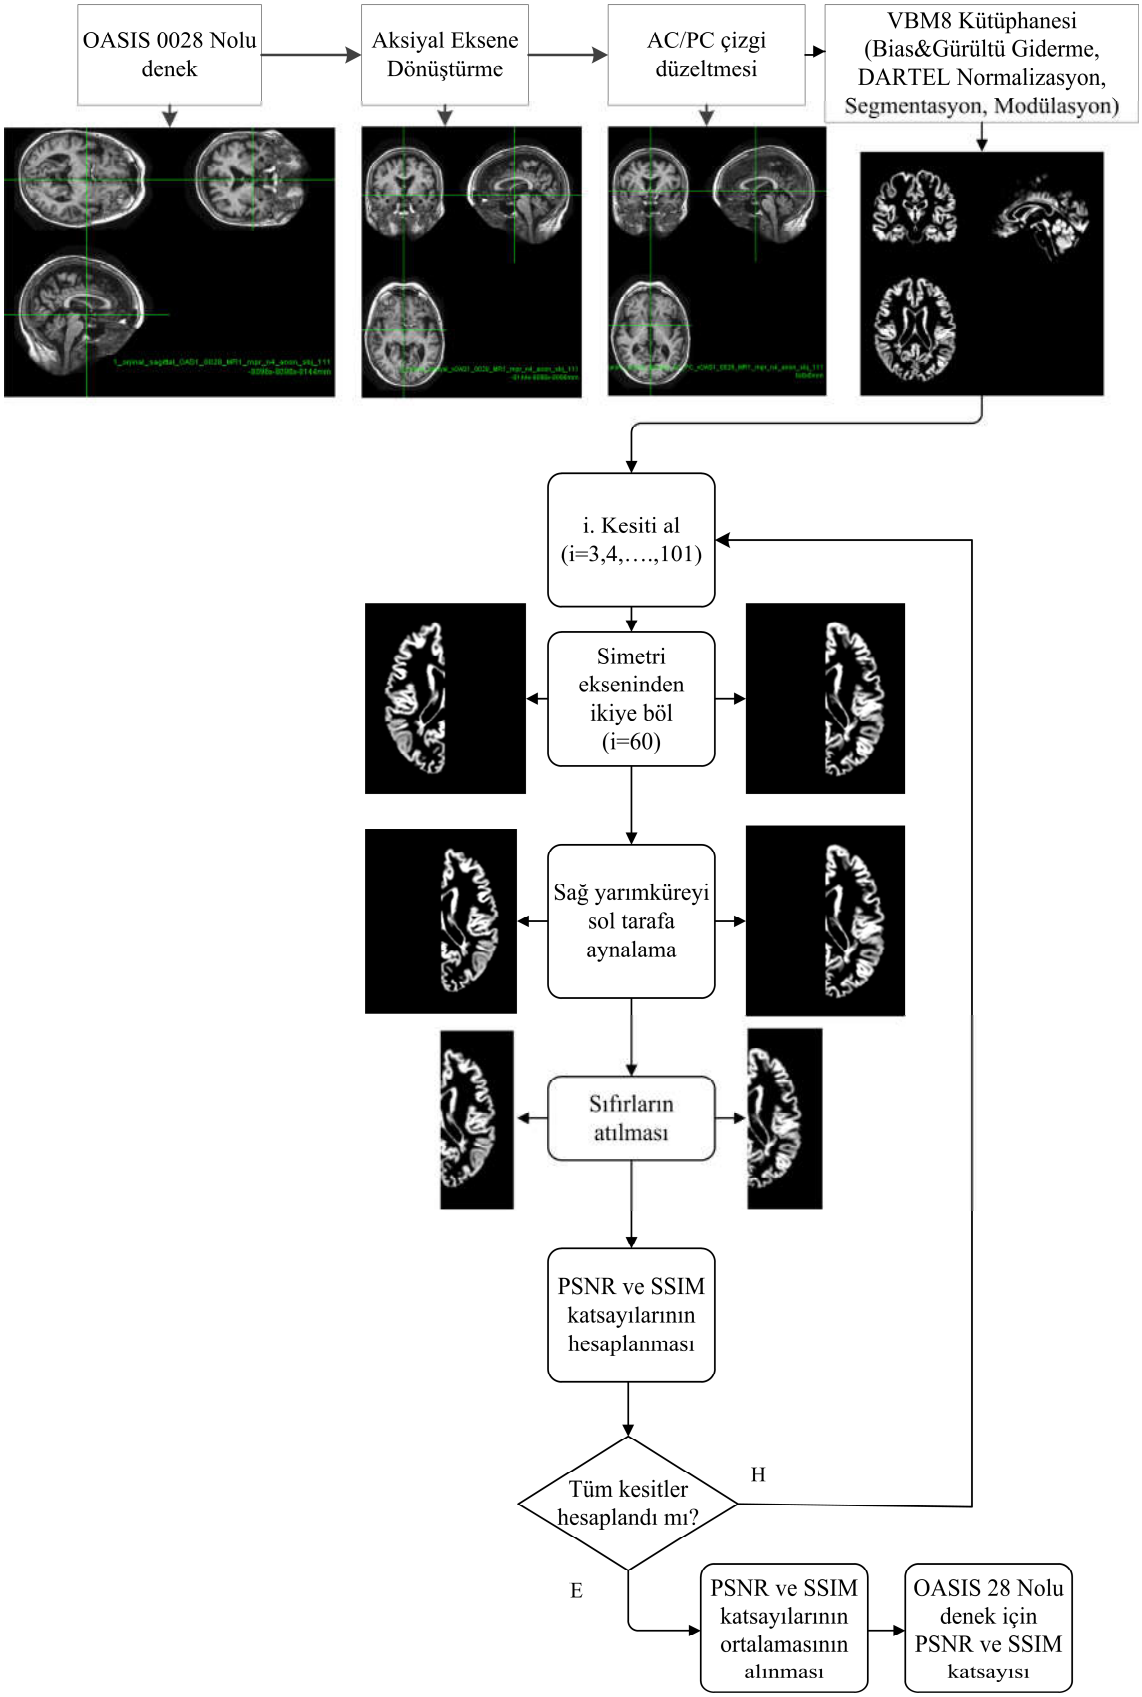
$$d_{ij} = (\#(x_{ik} \neq x_{jk}) / p) \tag{5.10}$$

$$d_{ij} = 1 - \frac{x_i x_j}{\sqrt{(x_i x_i')(x_j x_j')}} \tag{5.11}$$

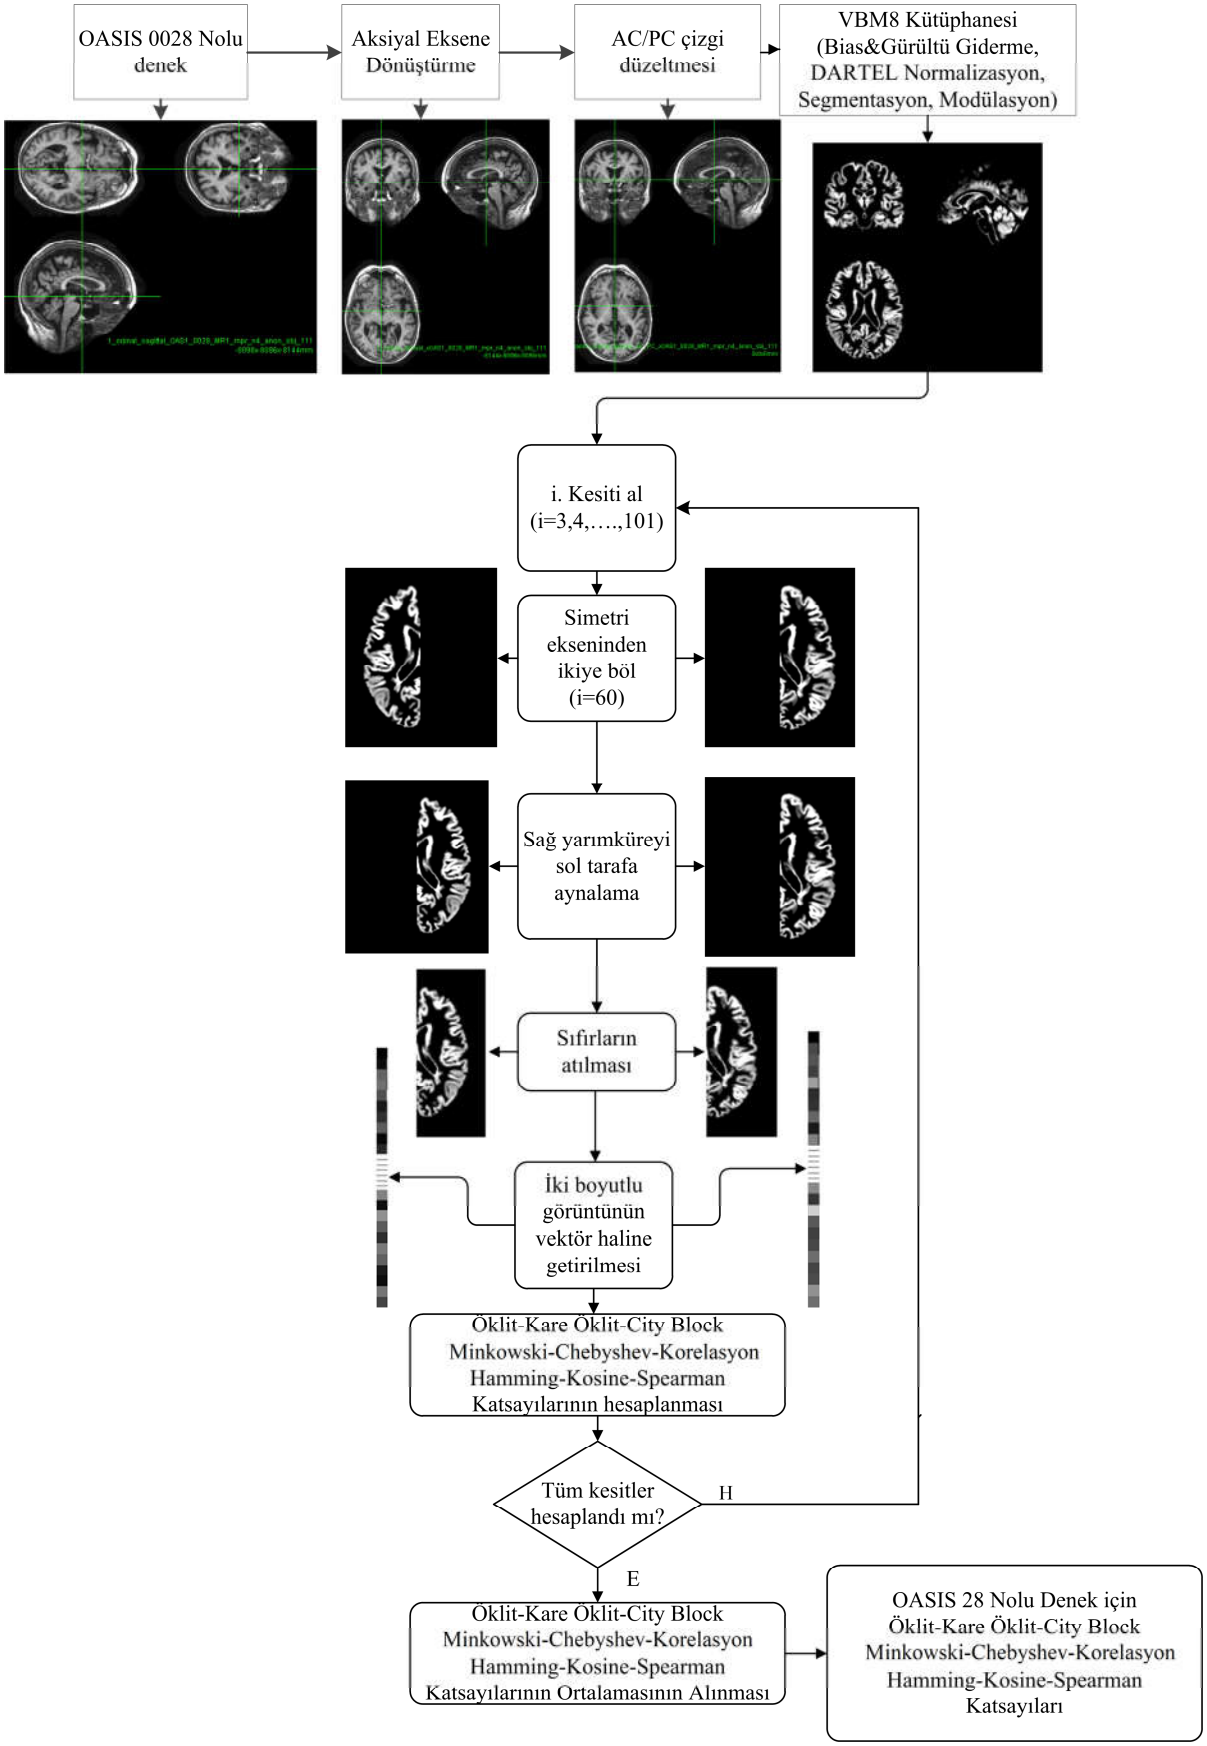
$$d_{ij} = 1 - \frac{(r_i - \bar{r_i})(r_j - \bar{r_j})'}{\sqrt{(r_i - \bar{r_i})(r_i - \bar{r_i})'}\sqrt{(r_j - \bar{r_j})(r_j - \bar{r_j})'}} \tag{5.12}$$

$$\bar{r_i} = \frac{1}{p}\sum_k r_{ik} = (\frac{p+1}{2}) \qquad \bar{r_j} = \frac{1}{p}\sum_k r_{jk} = (\frac{p+1}{2})$$

Her bir MR görüntüsünde tüm kesitler için katsayılar hesaplandıktan sonra kullanılan yöntem için tüm kesitlerin ortalaması alınmıştır. Böylece bir 3B MR görüntüsü için tek bir katsayı ortaya çıkacaktır. Bir denek için MNS GM görüntüsü ele alınırsa PSNR ve SSIM ile iki özellik, istatistiksel katsayılar ile dokuz özellik olmak üzere toplam onbir özellik elde edilmiştir. Şekil 5.8'de PSNR ve SSIM ile özellik çıkarma için OAS1_0028 nolu denek görüntüsünde önişlemeler ile beraber takip edilen model verilmiştir. Şekil 5.9'da OAS1_0028 nolu denek için istatisiksel özellikler için önişlemeler ile beraber takip edilen model verilmiştir. Tüm işlemler MNS GM, BM ve NS GM ve BM için yapılmış, her bir küme için elde edilen 11 özelliğin sınıflandırma performansları karşılaştırılmıştır.



Şekil 5.8. PSNR ve SSIM ile özellik çıkarma için OAS1_0028 nolu denek görüntüsünde önişlemeler ile beraber takip edilen model



Şekil 5.9. OAS1_0028 nolu denekte istatistiksel özellikler için önişlemeler ile beraber takip edilen model

5.5. Doku Analizi

Üç boyutlu yapısal MR görüntülerinde beyindeki hacimsel kayıplara bağlı olarak örüntü değişimleri olmaktadır. Gri madde ile başlayan ve daha sonra beyaz madde de görülen hacim kayıpları beyin omurilik sıvısının artmasına neden olmaktadır. Bundan dolayı gri madde ve beyaz madde hacim kaybının olduğu bölgelerde örüntü gri ve beyaz renk tonlarından siyahımsı renk tonlarına dönmektedir. Sayısal analizde en büyük problem beynin hangi bölgelerinde ne kadar bir hacim kaybı olduğu ve bu bölgelerin keskin sınırlarının nasıl belirleneceğidir. Bu işlem için literatürde sıklıkla Voksel Tabanlı Morfometri (VTM) yöntemi kullanılmaktadır. VTM genellikle grup içi, gruplar arası ve grup boylamsal MR görüntülerinde hacimsel kayıpların lokalizasyonu işlemlerinde kullanılmaktadır. Tıbbi çalışmalarda bu yöntem ile bulunan hacimsel kayıp bölgeleri yorumlanmakta, hastalığın niçin ilgili bölgelerde dejenerasyon meydana getirdiği tartışılmaktadır (Mechelli ve ark., 2005). Ancak karar destek sistemleri için üç boyutlu VTM maskesi kullanarak doku analizi yapan çalışma sayısı çok azdır (Savio ve ark., 2011; Ding ve ark., 2015; Beheshti ve ark., 2016a; Beheshti ve ark., 2017). VTM maskeleri ile hastalığın kayıplar meydana getirdiği bölgelerin keskin sınırları belirlenerek hastalık için anlamlı ve değerli bilginin bulunduğu voksel intensite değerleri belirlenir. Böylece tüm bir görüntü ile uğraşmak yerine VOI ile özellik çıkarmak hem özelliklerin kalitesi açısından hem de işlem süresi açısından büyük avantaj sağlayacaktır. Bu amaçla OASIS veri tabanından alınan MR grubu arasında meydana gelen kayıpların VTM lokalizasyonu işlemi yapılmış, hacimsel farklılıkların oluştuğu bölgelerin binary maskeleri türetilmiştir. Bu maskeler GM ve BM görüntüleri ile maskelenerek ilgili bölgelerin segmentasyonu yapılmıştır. Segmente edilen görüntülerden histogram tabanlı birinci dereceden istatistikler, maske altında kalan voksel intensite değerleri, 3B gri seviye eş oluşum matrisleri, 3B ayrık dalgacık dönüşümü olmak üzere dört farklı yöntem ile bir kısmı literatürde ilk defa tanımlanacak olan özellik kümeleri oluşturulmuştur.

5.5.1. Voksel Tabanlı Morfometri

Morfoloji canlı ve cansız varlıklarda ilgili bölgeleri şekil bakımından inceleyen bir bilim dalıdır. MR görüntülerinde beyinde meydana gelen değişimlerin sayısal

yöntemlerle morfolojik şekilde inceleyen en popüler yöntem voksel tabanlı morfometridir. Voksel tabanlı morfometri üç boyutlu MR görüntü grupları arasında hacimsel farklılıkları yakalayan ve bu bölgeleri lokalize eden sayısal bir yöntemdir. Bu yöntem ile normalize edilen GM ve BM görüntülerinde tüm deneklerde koordinatsal olarak aynı noktaya gelen voksel değerleri istatistiksel olarak incelenmektedir (Mechelli ve ark., 2005). AH'de GM ve BM'de meydana gelen hacimsel kayıpların yerini BOS doldurmaktadır. Dolayısıyla bu bölgelerdeki voksel intensite değerleri siyah renge doğru dönmektedir. Normal görüntülerde bu bölgelerde beyazımsı veya grimsi renk olacağı için intensite bakımından istatistiksel farklılıklar olacaktır. VTM yöntemi tüm vokselleri operatörün gireceği parametrelere göre karşılaştırarak istatistiksel olarak farklı olan bölgelere bir renk tonu atamaktadır. Tıbbi çalışmalarda bu yöntem ilgili bölgelerin kayıp lokalizasyonunun bulunması olarak kullanılmaktadır. Elde edilen cam beyin görüntüsü atlaslar ile çakıştırılarak hangi bölgede hacimsel kayıp olduğu net bir şekilde ortaya konulmaktadır. Bu kayıplar üzerinden doktorlar kayıpların neden meydana geleceği ve ne kadarlık bir kayıp olduğu üzerinde yorum yapmaktadırlar. Tez çalışmasında karar destek sistemi modelleri için lokalizasyon haritaları VOI olarak kullanılacaktır. 3B binary maskeler elde edildikten sonra NS GM, BM ve MNS GM, BM görüntülerde VOI'lerin üç boyutlu otomatik bir şekilde segmente edilmesi için bir MATLAB kod parçası geliştirilmiştir.

VTM yöntemi için gerçeklenen basamaklar şöyledir:

1-) VBM8 kütüphanesinde bulunan TPM, x,y,z=0 olacak şekilde birlikte çakıştırma işlemi yapılmıştır. Varsayılan olarak bulunan TPM koordinatsal olarak kaymış bulunmaktadır. OASIS veri tabanından alınan MR görüntüleri Şekil 5.10'da verilen önişlemelerden geçirilmiştir. VBM8 kütüphanesi ile DARTEL normalizasyon yöntemi kullanılarak NS GM, BM ve MNS GM, BM olmak üzere dört farklı segmente edilmiş görüntü elde edilmiştir. Bu görüntüler Şekil 5.10'da görüldüğü gibi programda varsayılan parametre değeri 8*8*8 mm'lik FWHM ile yumuşatılmıştır.

2-) SPM8 menüsünden *"Specify 2nd-level"* seçilir. İki grup arasında karşılaştırma yapıldığı için *"Two sample t-test"* tercih edilmiştir.

3-) Yaş, cinsiyet ve TBH kodeğişken olarak girilmiştir.

4-) *"Absolute Threshold"* 0.2 seçilmiştir. Bu parametrelerin girişinden sonra ilgili arayüz çalıştırılarak *"SPM.mat"* dosyası ve Şekil 5.11'de gösterilen istatistiksel deney dizaynı elde edilir.

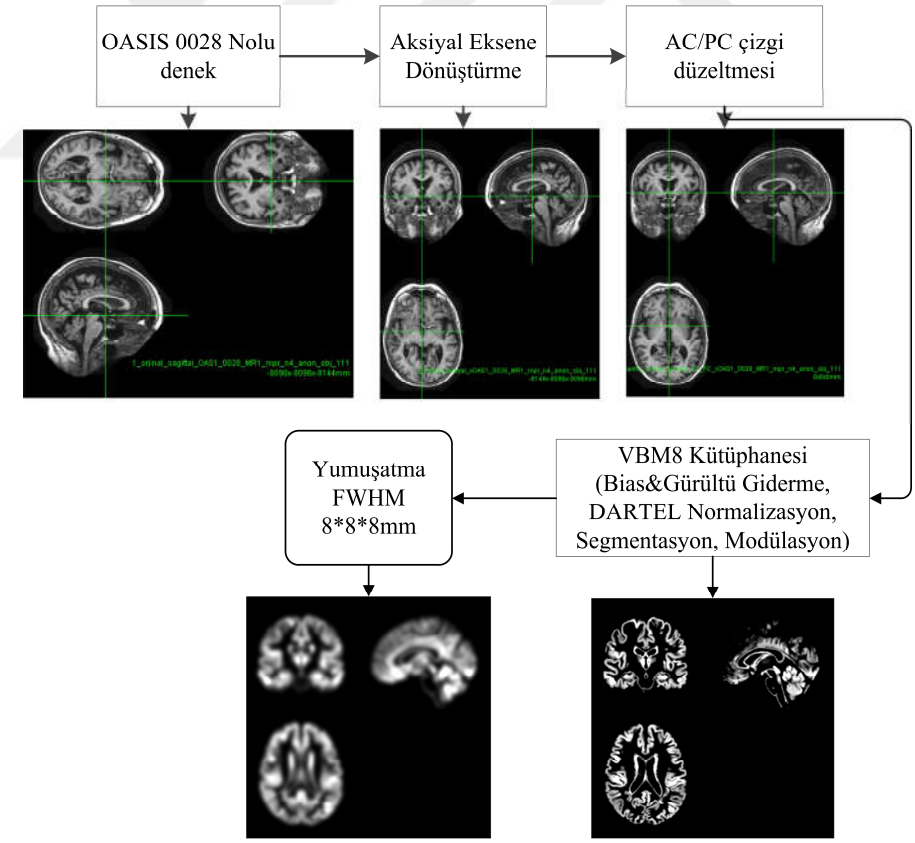
5-) SPM8 arayüzünden *"Estimate"* aracına *"SPM.mat"* dosyası girilerek model tahmini yapılmıştır.

6-) Model tahmin işleminden sonra SPM8 ara yüzünden *"Results"* seçilerek yeniden *"SPM.mat"* dosyası seçilir. Şekil 5.12'de verilen arayüzler üzerinden *"t-contrast"* seçilerek karşılaştırılmak istenen parametreler girilir.

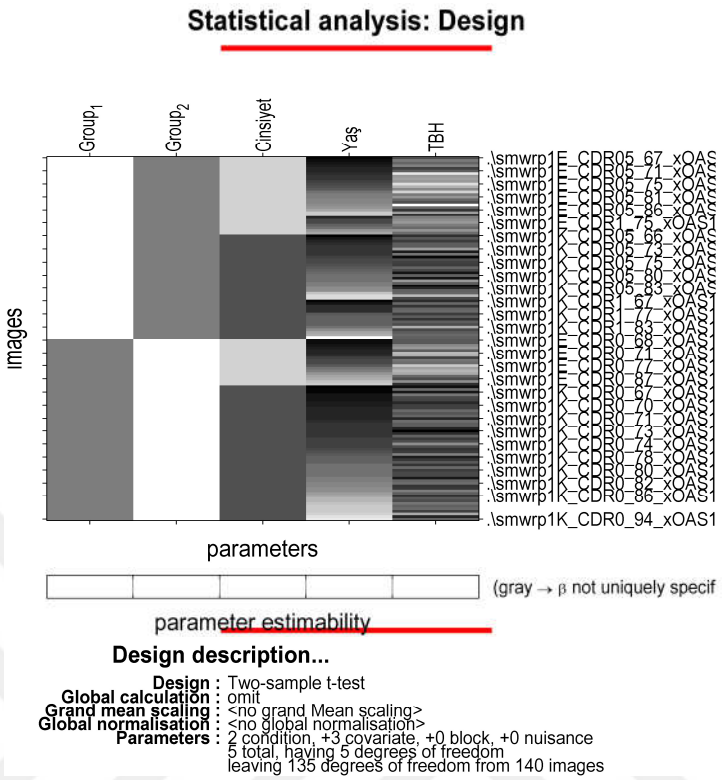
7-) Diğer parametreler *"apply masking: none", "Threshold (T or p value) :0.001", "extent threshold (voxels): 0 veya 200 (opsiyonel)"*.

8-) Yanlış pozitif sonuçları azaltmak için *"Family Wise Error (FWE)"* değeri 0.05 seçilmiştir.

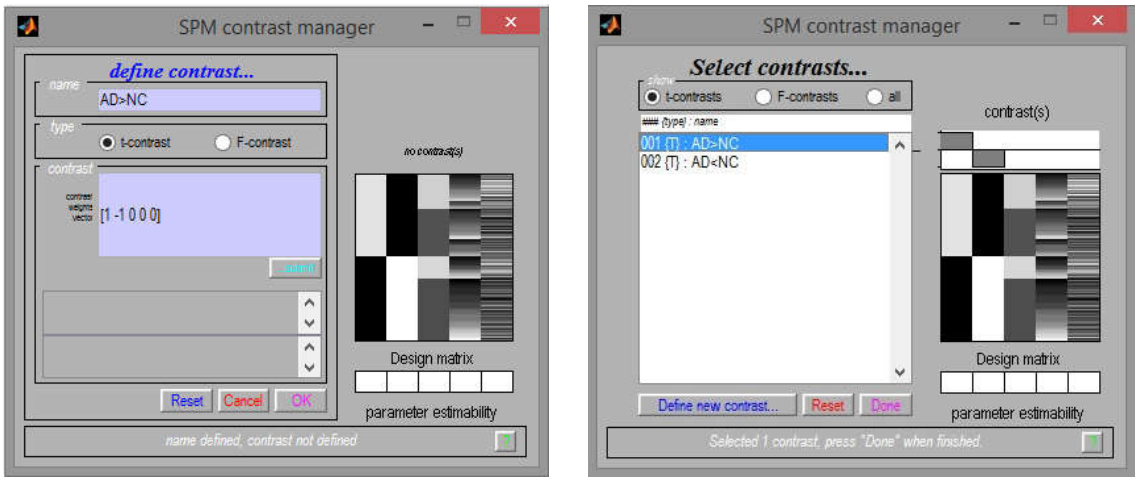
9-) Bu işlemden sonra hacimsel kayıpların gösterildiği cam beyin elde edilmektedir. Menüden *"hotmap"* seçildiğinde otomatik olarak *"hot.img"* ve *"hot.hdr"* maske dosyaları oluşmaktadır. Bu görüntüler binary olmadığı için intensite değeri 0'dan büyük vokseller MATLAB ortamında 1 değerine atanmıştır. Böylece kayıp hacimsel farklılık gösteren bölgelerin 3B binary maskeleri oluşturulmuştur.



Şekil 5.10. VTM için takip edilen önişleme yöntemlerinin MNS GM için OAS1_28 nolu denek üzerinden gösterimi



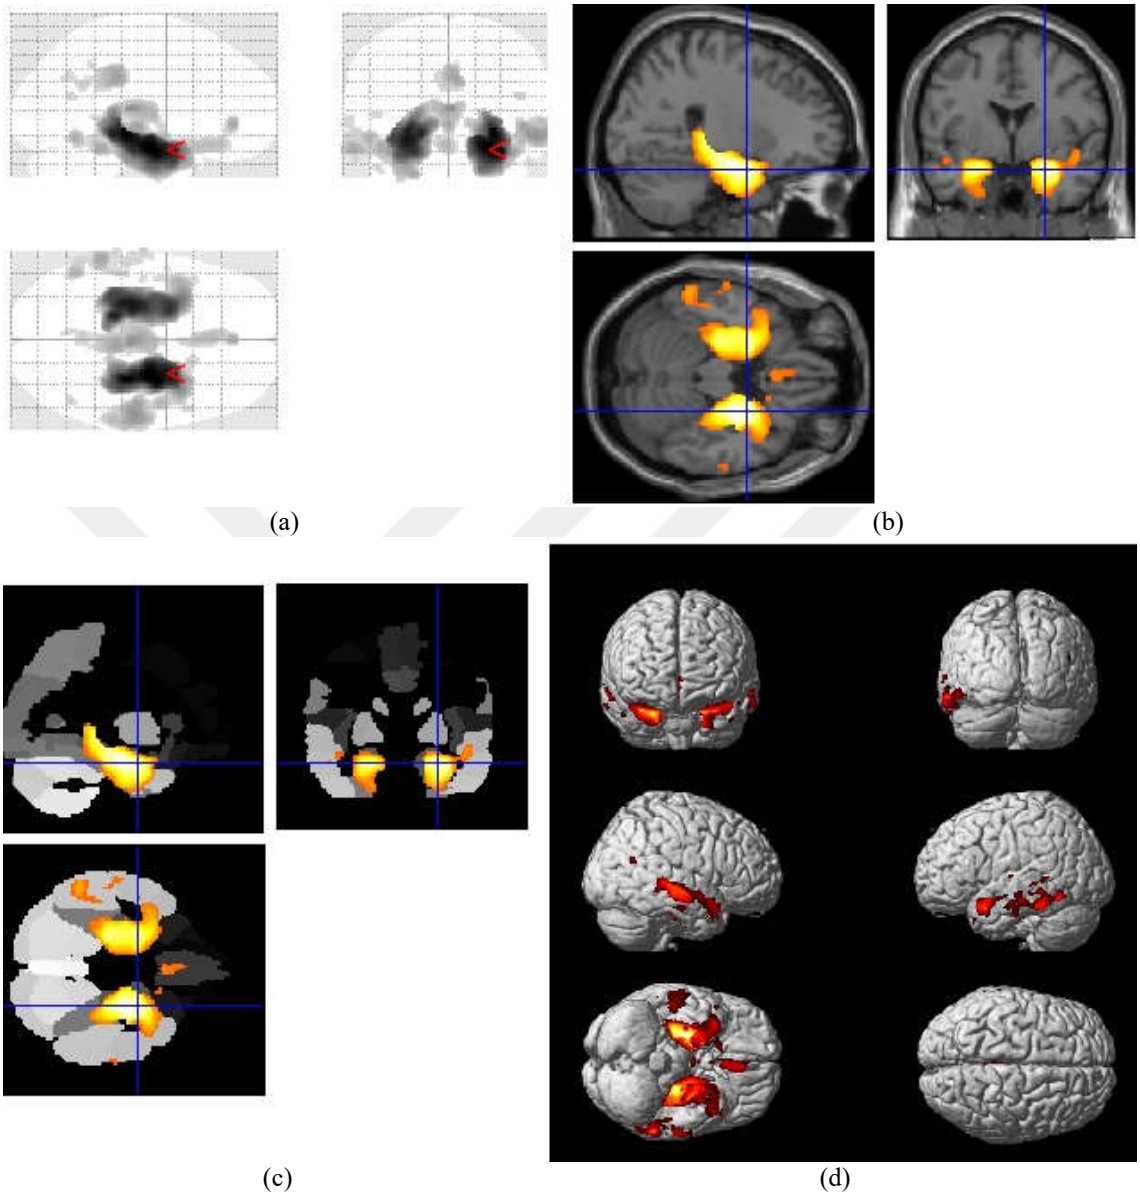
Şekil 5.11. VTM için elde edilen istatistiksel deney dizaynı



Şekil 5.12. VTM için kontrast parametrelerinin girilmesi için kullanılan arayüzler

Elde edilen maskeler kullanarak SPM8 altında çalışan *"xjview"* programı altında kayıp bölgeler farklı atlas, şablonlar, 3B modeller ile görselleştirilebilmektedir. Bu görüntüler ile kayıp bölgeler manuel olarak yorumlanabildiği gibi görüntüler koordinatların yorumlanabildiği uzaya çakıştırıldığı için hangi bölgede ne kadar kayıp olduğu da voksel bazında hesaplanabilmektedir. Şekil 5.13'te VTM ile elde edilen MNS

GM hacim kayıpları için cam beyin, tek MR görüntüsü, AAL atlas ve 3B beyin modeli üzerinde lokalizasyon işlemleri gösterilmektedir.

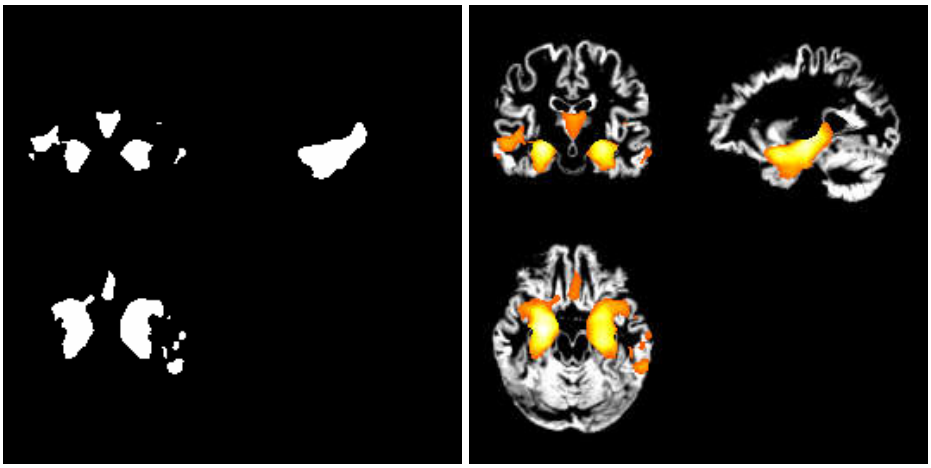


Şekil 5.13. (a) Cam beyin görüntüsü (b) Tek bir MR görüntüsü üzerinde lokalizasyon (c) AAL atlas ile lokalizasyon (d) 3B model ile lokalizasyon işlemi

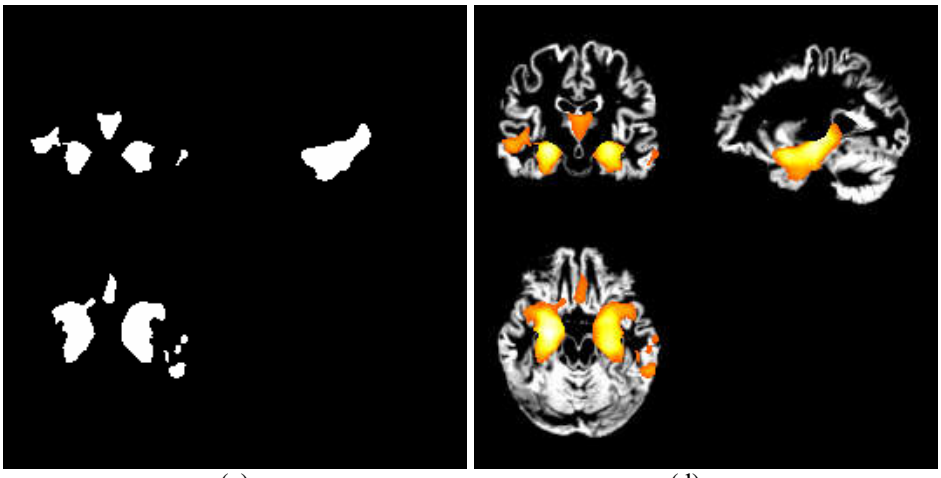
Şekil 5.13'te görüldüğü gibi GM kayıpları özellikle temporal lob ve limbik sistem üzerinde yoğunlaşmaktadır. Bu bölgelerdeki hacimsel kayıplar literatürde belirtilen hacimsel kayıp bölgeleri ile tutarlılık göstermektedir (Baron ve ark., 2001; Busatto ve ark., 2003).

NS GM, BM ve MNS GM, BM görüntüler için VTM işlemleri yukarıda verilen basamaklar halinde gerçeklenmiştir. Literatürde *"extent threshold"* değeri sürekli olarak

farklı değerler almaktadır. Bu büyüklük ne kadarlık bir voksel kümesi üzeri değerin anlamlı kabul edildiğini gösteren değerdir. Literatürde kaç voksel kümesi üzeri anlamlı seçileceği, eşik değerinin ne olacağı net bir şekilde belirtilmemektedir (Matsunari ve ark., 2007; Kopřivová ve ark., 2009; Chyzhyk ve Savio, 2010). Bu değer kullanıcı tarafından girilmektedir. Karşılaştırma yapmak amacı ile maske türetilen görüntülerde 200 voksel kümesi üzeri anlamlı kabul edilen dört maske daha türetilmiştir. Tüm denemeler türetilen bu sekiz maske üzerinden sekiz farklı senaryo ile gerçeklenmiştir. Hedeflenen nokta belli bir küme üzerindeki eşik değerinin sınıflandırma performansını ne kadar etkilediğinin ölçülmesidir. Şekil 5.14a ve Şekil 5.14b'de MNS GM 3B binary maskesi ve GM üzerindeki lokalizasyonu, Şekil 5.14c ve Şekil 5.14d'de MNS GM_200 3B binary maskesi ve GM üzerindeki lokalizasyonu, Şekil 5.15a ve Şekil 5.15b'de MNS BM 3B binary maskesi ve BM üzerindeki lokalizasyonu, Şekil 5.15c ve Şekil 5.15d'de MNS BM_200 3B binary maskesi ve BM üzerindeki lokalizasyonu, Şekil 5.16a ve Şekil 5.16b'de NS GM 3B binary maskesi ve GM üzerindeki lokalizasyonu, Şekil 5.16c ve Şekil 5.16d'de NS GM_200 3B binary maskesi ve GM üzerindeki lokalizasyonu, Şekil 5.17a ve Şekil 5.17b'de NS BM 3B binary maskesi ve BM üzerindeki lokalizasyonu, Şekil 5.17c ve Şekil 5.17d'de NS BM_200 3B binary maskesi ve BM üzerindeki lokalizasyonu verilmiştir. (*_200 eki 200 voksel üzeri kümelerin anlamlı kabul edildiği maskeler, NS: Normalize Segmente, MNS: Modülasyonlu Normalize Segmente)

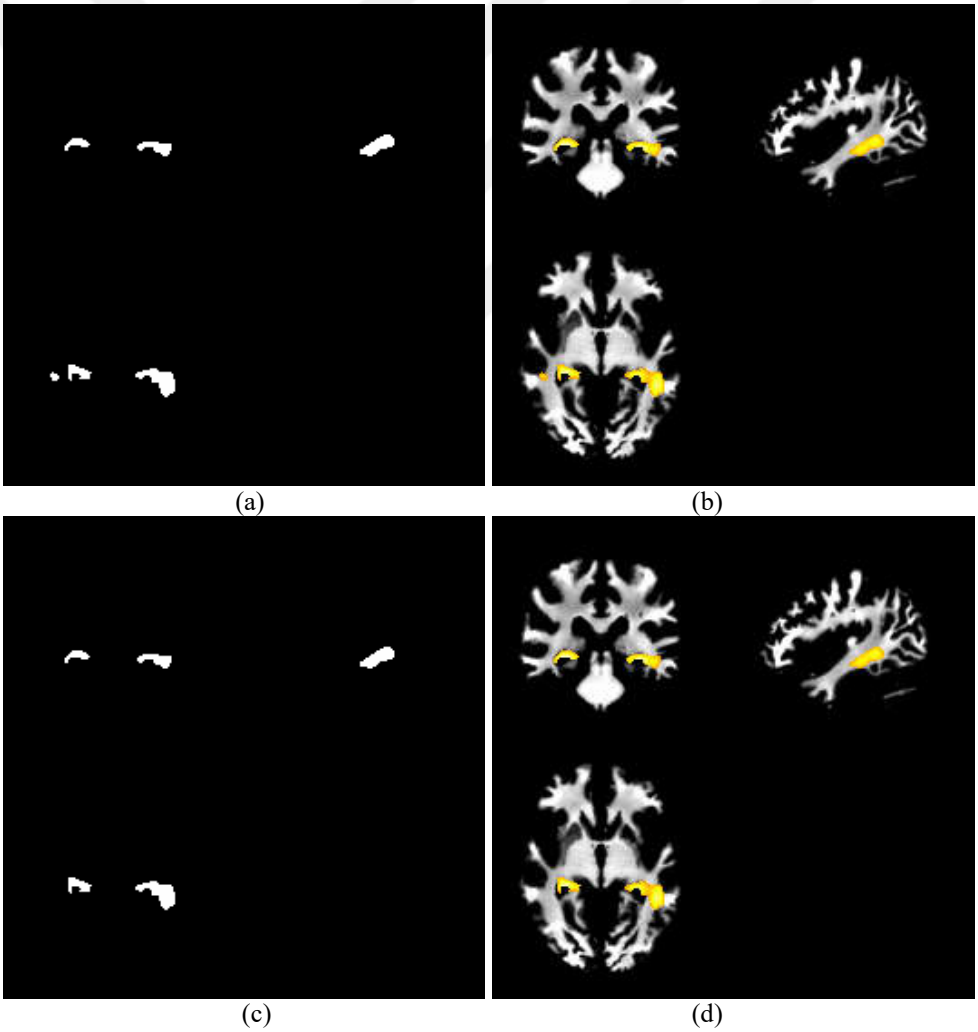


(a) (b)



(c) (d)

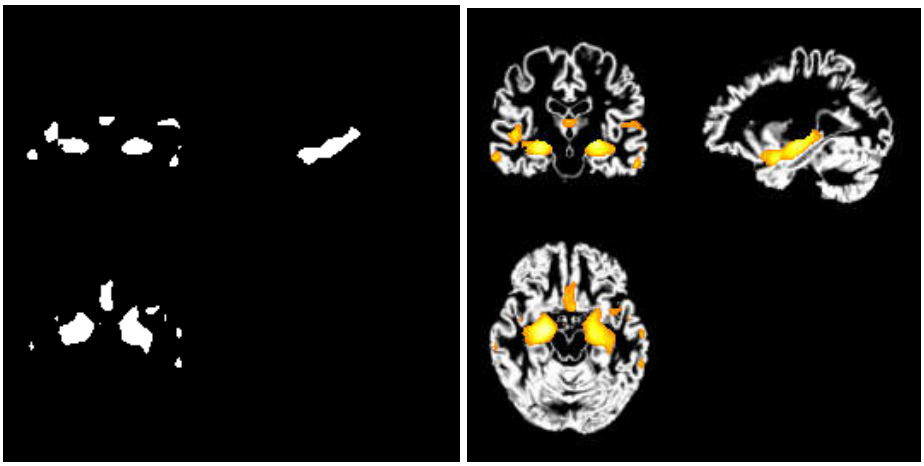
Şekil 5.14. (a)(b)MNS 3B GM binary maske ve GM üzerinde lokalizasyonu (c)(d) MNS GM 200 voksel üzeri anlamlı olarak alınan 3B binary maske ve GM üzerinde lokalizasyonu



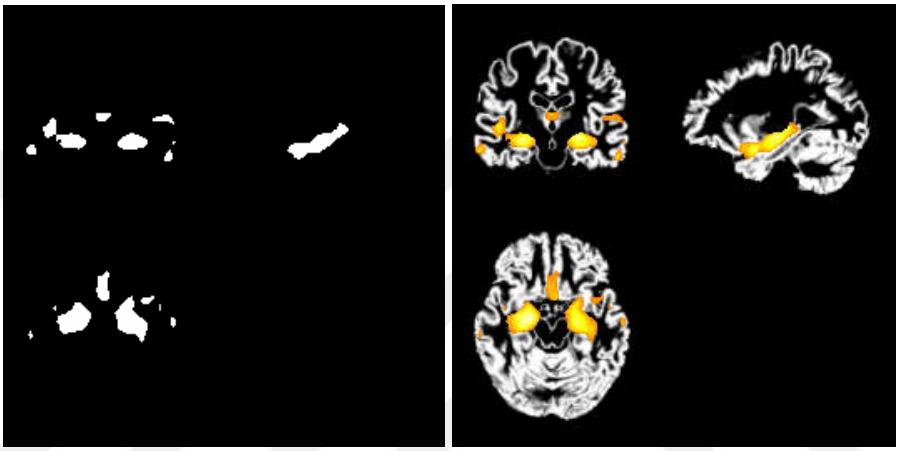
(a) (b)

(c) (d)

Şekil 5.15. (a)(b)MNS BM 3B binary maske ve BM üzerinde lokalizasyonu (c)(d) MNS BM 200 voksel üzeri anlamlı olarak alınan 3B binary maske ve BM üzerinde lokalizasyonu

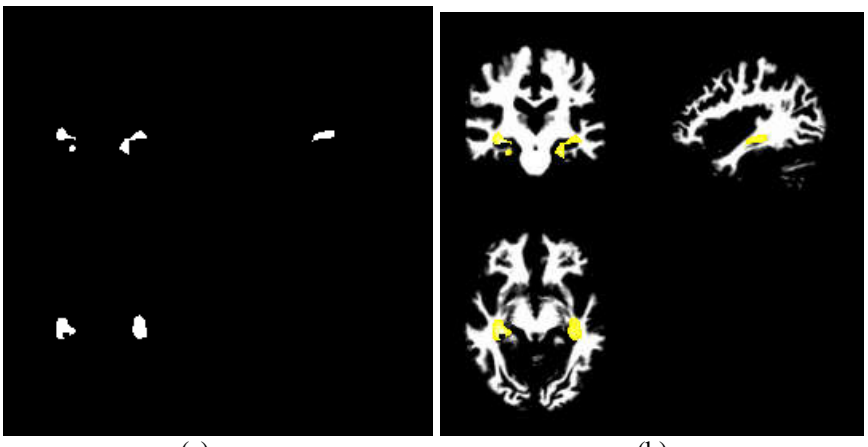


(a) (b)

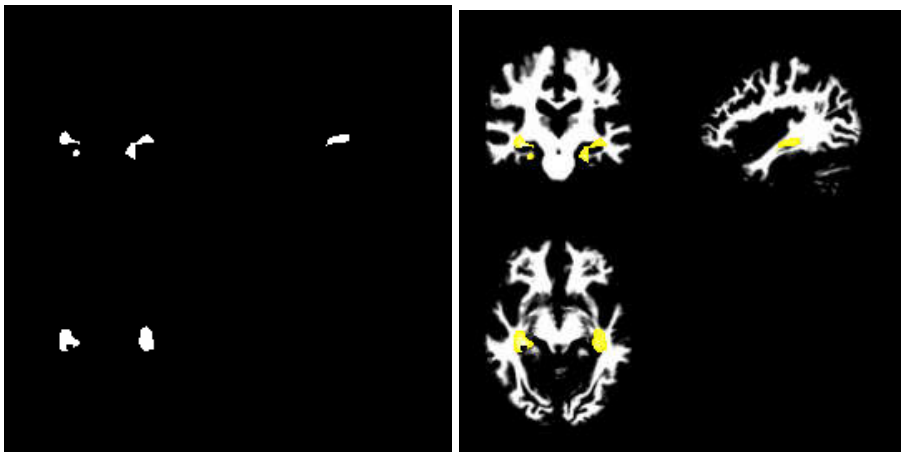


(c) (d)

Şekil 5.16. (a)(b)NS GM 3B binary maske ve GM üzerinde lokalizasyonu (c)(d) NS GM 200 voksel üzeri anlamlı olarak alınan 3B binary maske ve GM üzerinde lokalizasyonu



(a) (b)

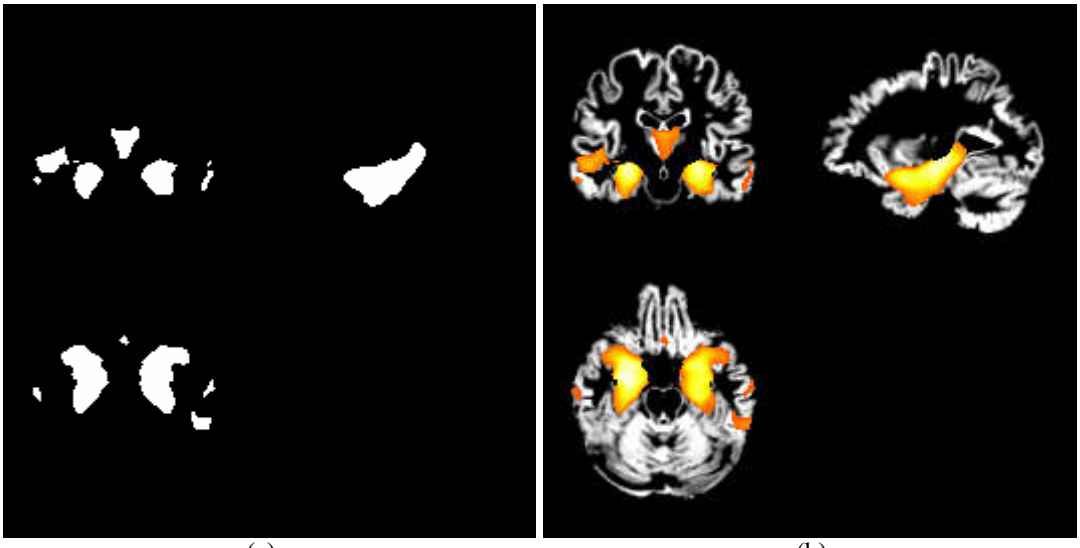


(c) (d)

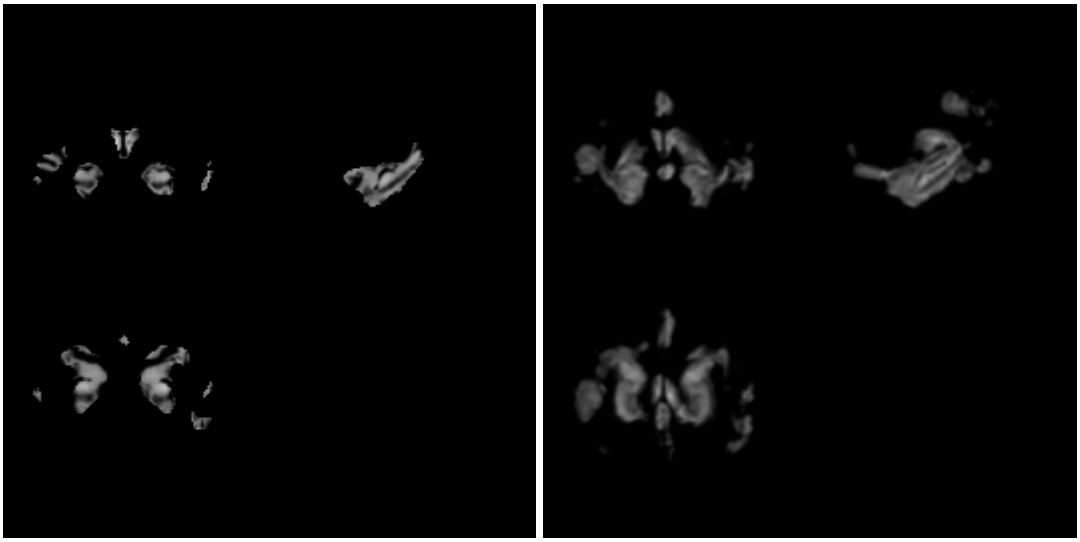
Şekil 5.17. (a)(b)NS BM 3B binary maske ve GM üzerinde lokalizasyonu (c)(d) NS BM 200 voksel üzeri anlamlı olarak alınan 3B binary maske ve GM üzerinde lokalizasyonu

5.5.2. Hacim Kayıp Maskesi ile 3B Maskeleme İşlemi

Sekiz farklı senaryo için maskeler türetildikten sonra MNS ve NS görüntüler maskelenmiş ve 3B olarak NIfTI formatında tekrar kaydedilmiştir. Bu işlemi gerçekleştirmek için MATLAB'ta bir kod geliştirilmiştir. Görüntü ve maskeler aynı koordinat sisteminde olduğu için görüntü ve maskenin kesitleri tek tek çarpılmıştır. 0 ile çarpılan bölgeler sıfır değerini alırken 1 ile çarpılan bölgeler aynen kalmaktadır. Şekil 5.18'de MNS GM 3B maske, GM ile üst üste örtüştürülmesi, 3B segmentasyon işlemi ve üç boyutlu modeli verilmiştir.



(a) (b)

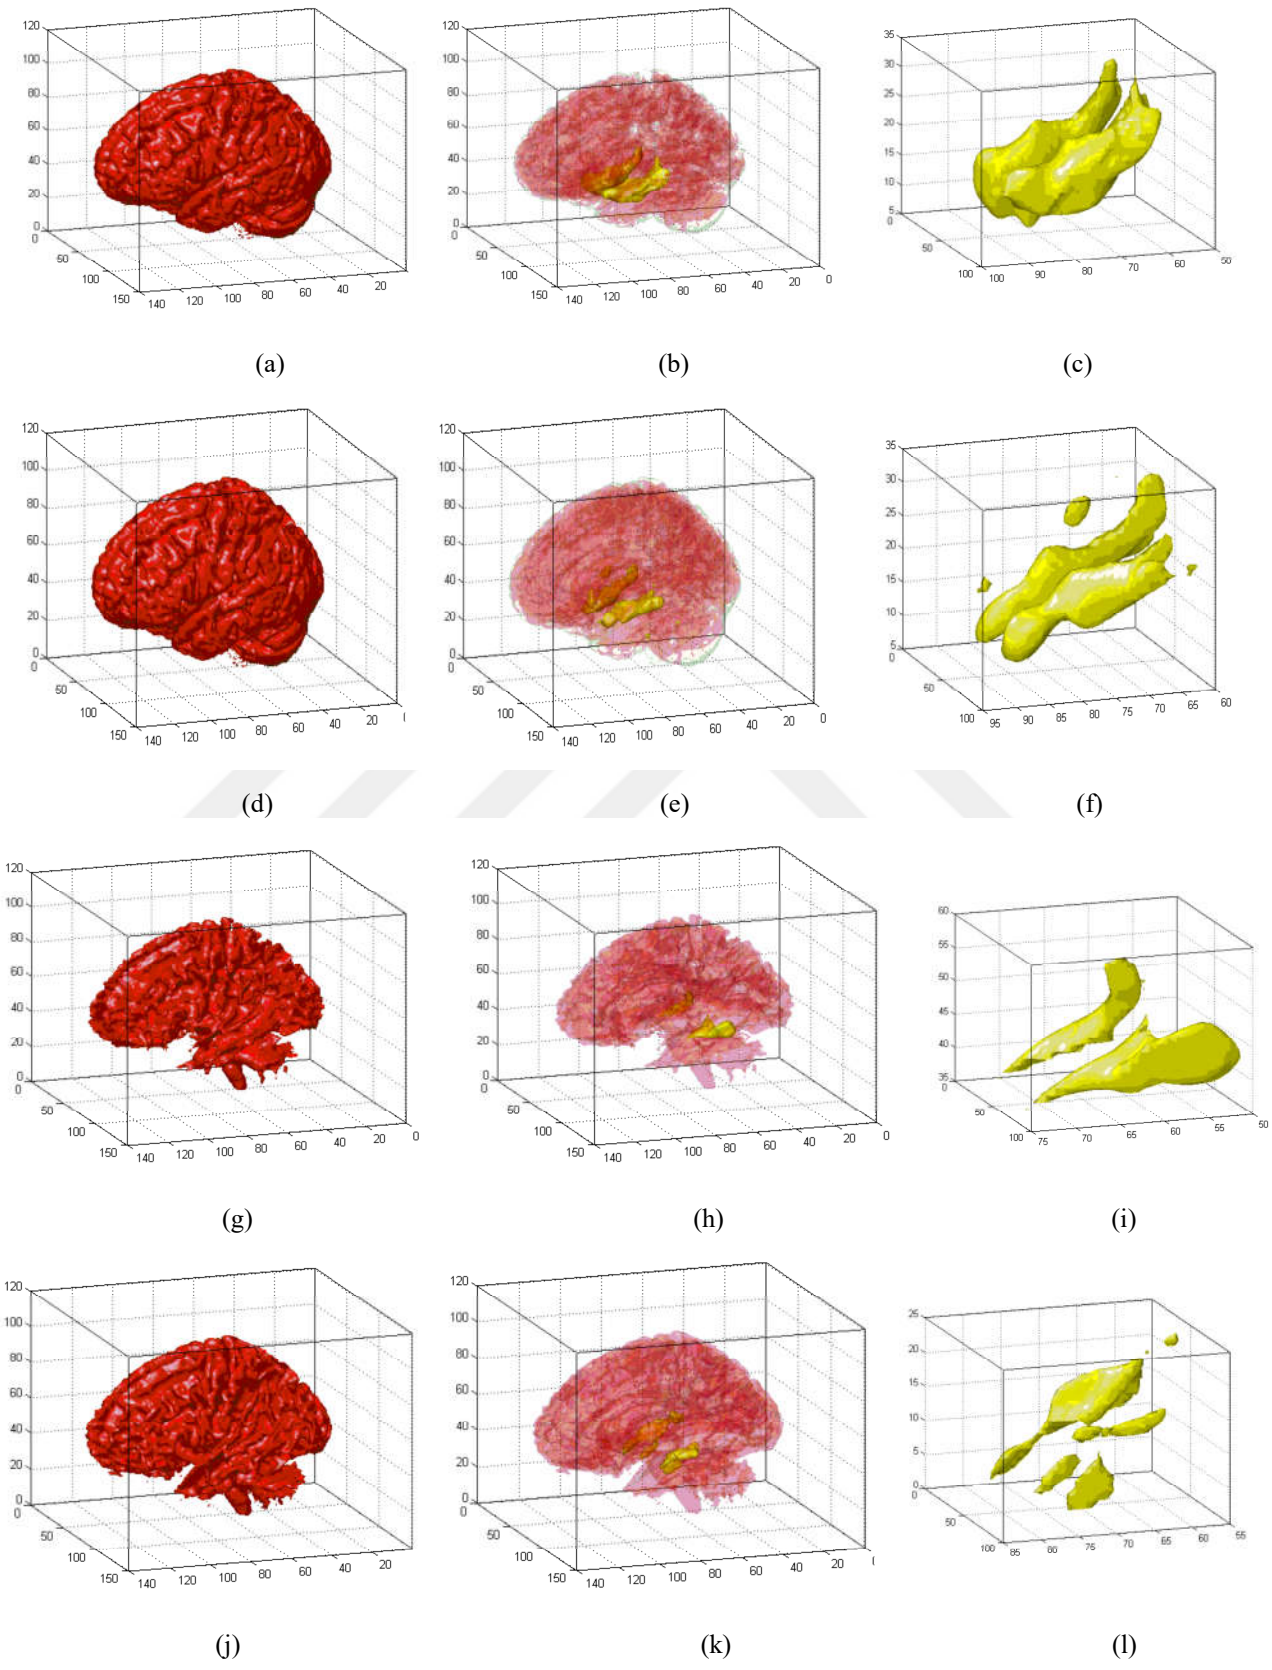


(c) (d)

Şekil 5.18. (a) MNS GM binary maske (b) MNS GM ile maskenin örtüştürülmesi (c) Maske altında kalan bölgenin kesilmesi (d) Maske altında kalan bölgenin 3B modeli

70 AH ve 70 NK 3B MR görüntülerinden MNS GM, MNS BM, NS GM, NS BM ve 200 voksel üzeri anlamlı maskeler ile 8 farklı senaryoda VOI segmentasyon işlemi gerçekleştirilmiştir. Böylece VOI bölgeleri çıkarılmış toplamda 1120 3B görüntü elde edilmiştir. Hem MNS hem de NS görüntülerde VTM yöntemi literatürde bulunan bir karmaşadan dolayı kullanılmıştır. VTM için lokalizasyon işlemi yapılırken bazı yayınlar MNS görüntüleri bazıları ise NS görüntüleri kullanmaktadır (Mechelli ve ark., 2005; Pell ve ark., 2008; Radua ve ark., 2014). Aynı zamanda bazı yayınlarda anlamlı küme voksel eşik değeri farklı değerlerde kullanılmaktadır. Tez çalışmasında hem MNS hemde NS görüntüler üzerinde lokalizasyon işlemi yapılarak literatürde kullanılan ortalama bir eşik değeri ile sekiz farklı senaryo üzerinden doku analizi işlemleri VOI bölgelerde gerçekleştirilmiştir. VOI olarak segmente edilen görüntülerde toplamda 121 kesit bulunmaktadır. Ancak her bir görüntüde VOI segmentasyonundan dolayı çok fazla 0 değeri içeren kesit ortaya çıkmıştır. Bundan dolayı işlemlerin uzamaması ve anlamsız çok fazla 0 değerinin hesaba katılmaması için sadece VOI maskelerinin bulunduğu ilgili kesit aralıkları alınmıştır. MSN GM görüntüler için 20. ve 79. kesit arasından 60 kesit, NS GM görüntüler için 22. ve 70. kesit arasından 49 kesit, MNS BM görüntüler için 33. ve 72. kesit arasından 40 kesit, NS BM görüntüler için 29. ve 56. kesit arasından 28 kesit alınmıştır. 200 voksel üzeri eşik değeri alınan veriler için de aynı kesit aralıkları alınmıştır. Bu kesitler 3B ADD ve 3B GSEOM için kullanılmış, HTBDİ ve sadece anlamlı voksel değerleri için kendilerine özel yöntemler kullanılmıştır. Şekil 5.19'da MNS GM, NS GM, MNS BM, NS BM için 3B modeller, maske ile görüntülerin 3B

uzayda çakıştırılmasının 3B modelleri, sadece VOI olarak incelenen alanın 3B modelleri gösterilmiştir.



(a) (b) (c)

(d) (e) (f)

(g) (h) (i)

(j) (k) (l)

Şekil 5.19. (a) MNS GM 3B Model (b) MNS GM ve VTM maske 3B model (c) MNS GM VOI bölgesi 3B model(d) NS GM 3B Model (e) NS GM ve VTM maske 3B model (f) NS GM VOI bölgesi 3B model (g) MNS BM 3B Model (h) MNS BM ve VTM maske 3B model (i) MNS BM VOI bölgesi 3B model (j) NS BM 3B Model (k) NS BM ve VTM maske 3B model (l) NS BM VOI bölgesi 3B model

5.5.3. Histogram Tabanlı Birinci Dereceden İstatistikler

Histogram Tabanlı Birinci Dereceden İstatistikler (HTBDİ) görüntünün histogramından yani bir piksel değerinin ne kadar tekrarlandığından yola çıkan bir doku analizi yöntemidir. Kayıp maskeleri görüntüler ile çarpılıp VOI'ler oluşturulduğunda bu bölgelerin HTBDİ ile ortalama, varyans, çarpıklık, basıklık, enerji ve entropi olmak üzere altı adet özelliği çıkarılmıştır. Ancak VOI görüntülerin üç boyutlu olması HTBDİ özelliklerinin çıkarılmasını zorlaştırmaktadır. Bunun için üç boyutlu görüntülerden iki boyutlu bir örüntü elde edilmiştir. *M*N* bir MR kesitinin boyutu ve *Y* kesit sayısı olmak üzere öncelikle 3B binary maskeler *1*(M*N*Y)* boyutlu vektör haline getirilmiştir. Bu vektör üzerinde değeri bir olan noktaların koordinat indisleri MATLAB ile elde edilmiştir. MNS ve NS görüntüler de *1*(M*N*Y)* boyutlu bir vektör haline getirilerek 3B maske vektöründen oluşturulan koordinat indislerine denk gelen noktalar ile ayrı bir vektör oluşturulmuştur. Böylece değerli bilginin bulunduğu voksel değerleri tüm görüntülerde bir boyutlu ayrı bir vektör haline getirilmiştir. Her ne kadar bir boyutlu bir vektör olarak elde edilse de bu değerlerin voksel intensite sıklıklarına bakılacağı için iki boyutlu bir görüntü gibi düşünülebilir. Anlamlı voksel intensite değerlerinin bulunduğu vektör ile HTBDİ tabanlı ortalama, varyans, çarpıklık, basıklık, enerji ve entropi değerleri elde edilmiştir. Yönteme sayısal olarak bakılırsa bir görüntü *"x"* ve *"y"* iki uzaysal değişkenin bir fonksiyonu *f(x,y)* olarak *x=0,1,……N-1, y=0,1,……M-1* düşünülebilir. *f(x,y)* fonksiyonu *i=0,1,.....,G-1* olmak üzere ayrık intensite değerleri alır. G görüntüdeki maksimum intensite değeridir. Görüntünün histogramı Eşitlik 5.13'te gösterildiği gibi tüm görüntüdeki voksel intensite değeri taranarak hesaplanır. Eşitlik 5.14'te $\delta(j,i)$ Kronecker Delta fonksiyonu verilmiştir.

$$h(i) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(f(x,y),i) \tag{5.13}$$

$$\delta(j,i) = \begin{cases} 1, j = i \\ 0, j \neq i \end{cases} \tag{5.14}$$

Histogramın intensite seviyeleri görüntünün içerdiği voksel dağılımın istatistiksel bir özetidir. Hangi voksel değerinden ne kadar bulunduğu histogram ile kolayca izlenebilir. Bir nevi görüntünün renk tonu dağılımının karakteristiğini verir. Her bir voksel seviyesi *h(i)* değerini toplam voksel sayısına bölmek, o voksel değerinin yaklaşık olasılık yoğunluğunu verir (Eşitlik 5.15).

$$p(i) = \frac{h(i)}{1*(M*N*Y)} \quad i=0,1,2,3\ldots\ldots\ldots,G\text{-}1 \tag{5.15}$$

Bu olasılık değeri kullanılarak görüntünün birinci dereceden istatistiksel özellikleri kantitatif olarak çıkarılabilir. Histogram üzerinden çıkarılan özellikler Eşitlik 5.16'da ortalama, Eşitlik 5.17'de varyans, Eşitlik 5.18'de basıklık, Eşitlik 5.19'da çarpıklık, Eşitlik 5.20'de enerji, Eşitlik 5.21'de entropi olmak üzere matematiksel ifadeleri gösterilmektedir (Materka ve Strzelecki, 1998).

$$\mu = \sum_{i=0}^{G-1} ip(i) \tag{5.16}$$

$$\sigma^2 = \sum_{i=0}^{G-1} (i-\mu)^2 p(i) \tag{5.17}$$

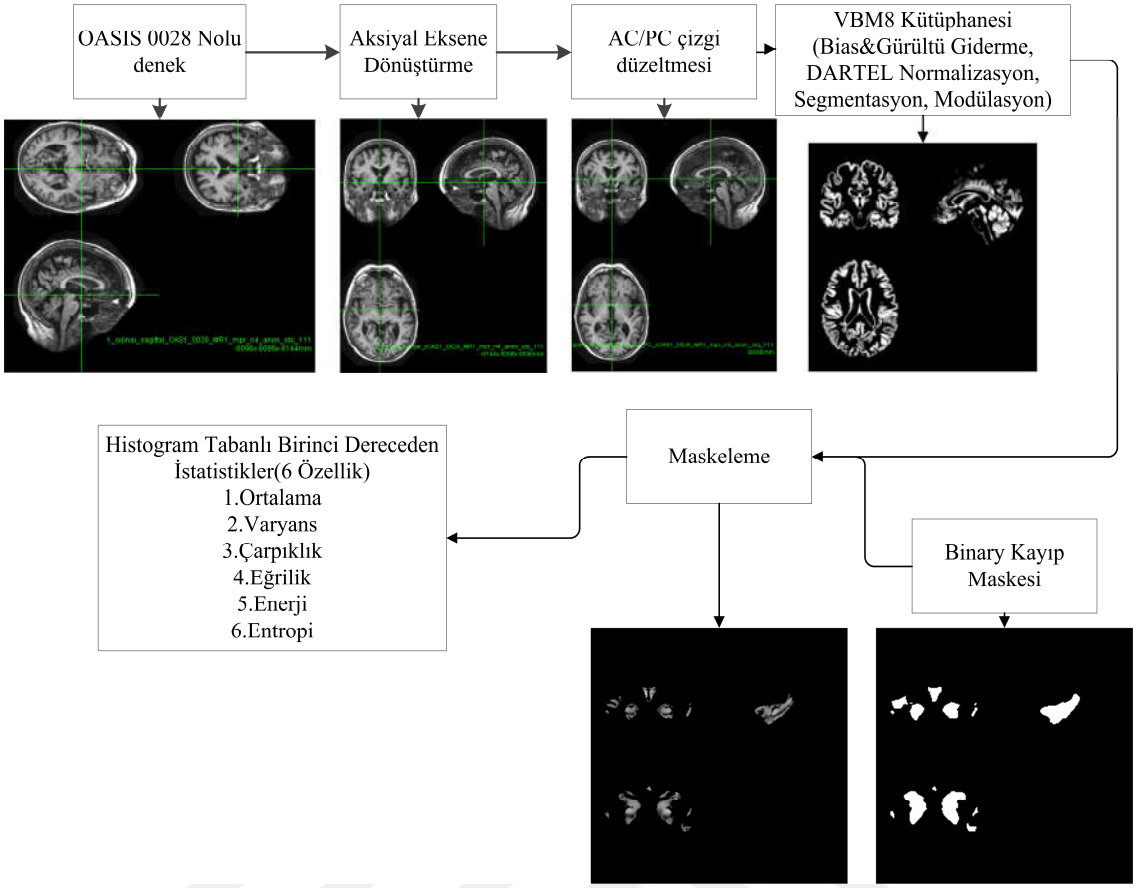
$$\mu_3 = \sigma^{-3} \sum_{i=0}^{G-1} (i-\mu)^3 p(i) \tag{5.18}$$

$$\mu_4 = \sigma^{-4} \sum_{i=0}^{G-1} (i-\mu)^4 p(i) - 3 \tag{5.19}$$

$$Enerji = \sum_{i=0}^{G-1} \left[p(i)\right]^2 \tag{5.20}$$

$$Entropi = -\sum_{i=0}^{G-1} p(i) \log_2 \left[p(i)\right] \tag{5.21}$$

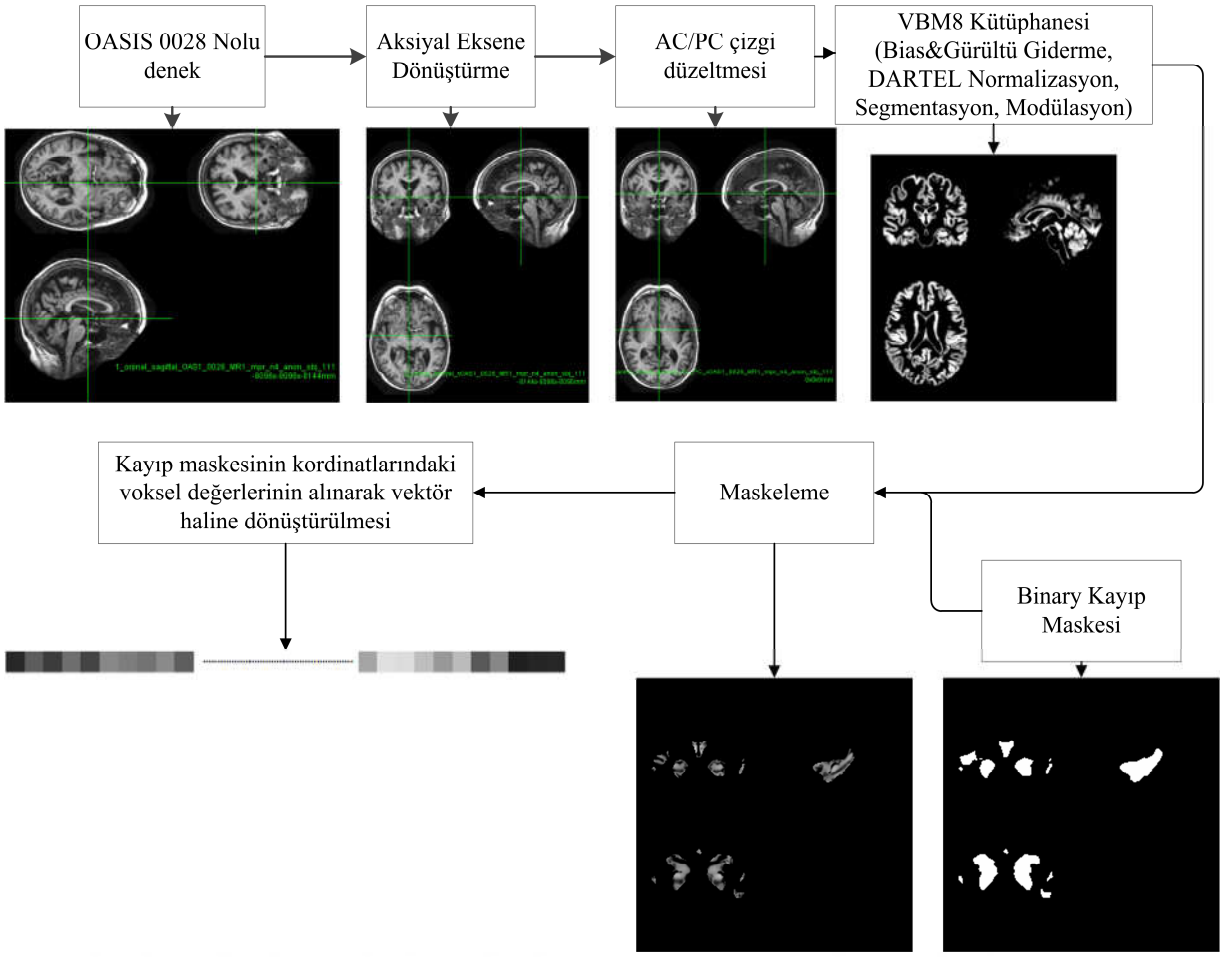
Bu vektörler üzerinden 6 adet özellik sekiz farklı senaryo için elde edilmiştir. Her bir senaryo için 140*6 matris boyutlu özellik vektörü oluşturularak sekiz ayrı veri kümesi türetilmiştir. Şekil 5.20'de HTBDİ için takip edilen model MNS GM için önişlemeleri ile beraber OAS1_0028 nolu görüntüde verilmiştir.



Şekil 5.20. OAS1_0028 nolu görüntüde HTBDİ için önişlemeler ile beraber takip edilen model

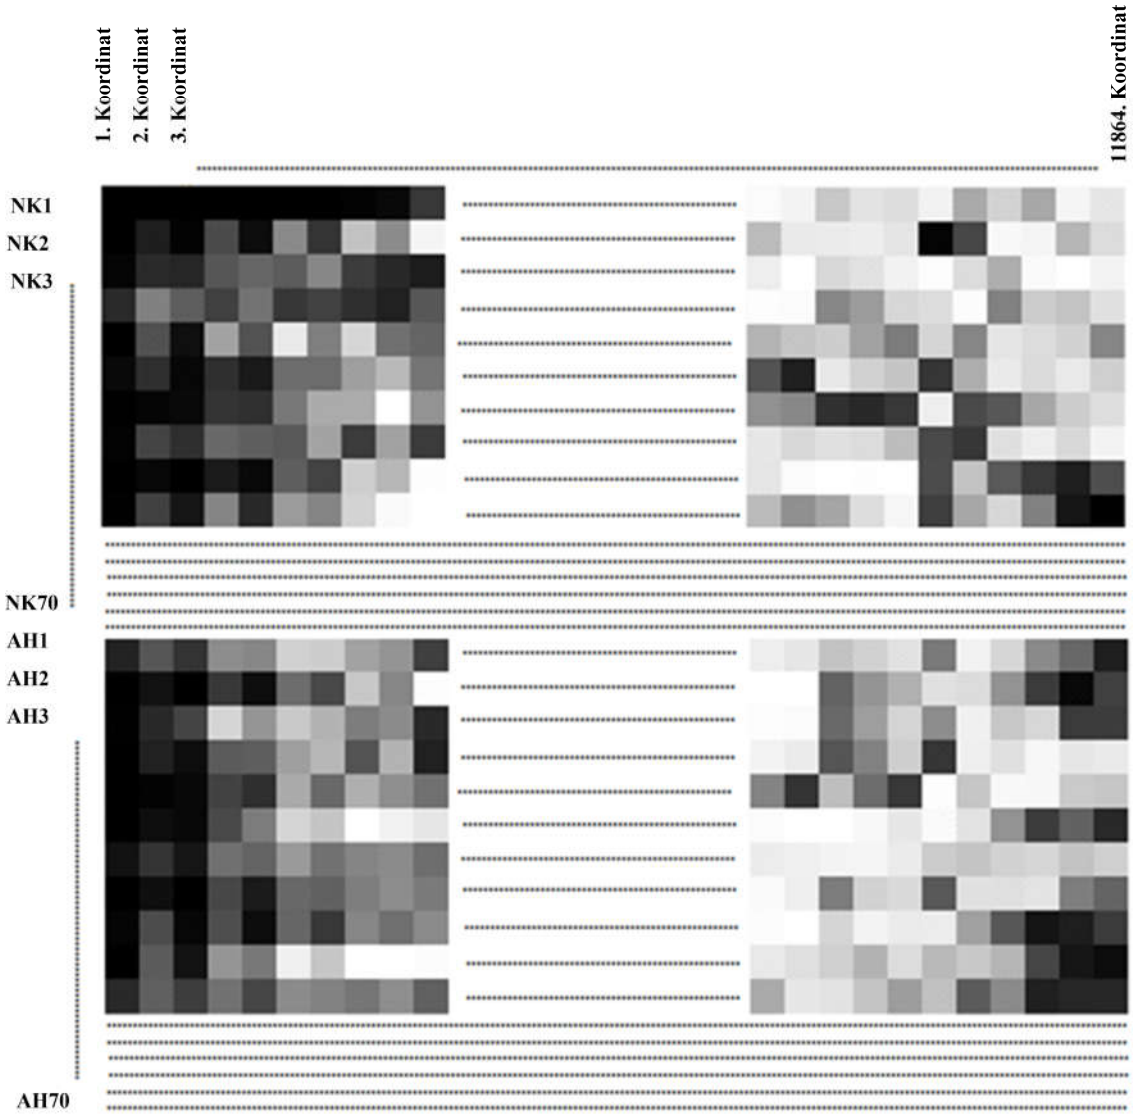
5.5.4. Voksel Değerlerinin Özellik Olarak Kullanımı

AH'de hacimsel kayıp olan bölgelerdeki voksel intensite değerleri hastalık için anlamlı bilgi taşımaktadır. Bu bölgelerin kesin sınırları VTM yöntemi ile belirlendikten sonra voksel değerleri öznitelik olarak kullanılabilir. Ham MR görüntülerinde önişlemeler yapıldıktan sonra sekiz farklı VTM senaryosu için GM ve BM görüntüler segmente edilmiştir. HTBDİ'de olduğu gibi maskelerin aynı koordinatlarına denk gelen voksel değerleri bir vektör haline getirilmiştir. Her görüntüde aynı koordinat değerlerindeki vokseller alt alta gelecek şekilde öznitelik vektörü oluşturulmuştur. Şekil 5.21'de OAS1_0028 nolu denek üzerinden önişlemeler ile beraber voksel değerlerinin öznitelik vektörü olarak elde edilen modeli gösterilmektedir.



Şekil 5.21. OAS1_0028 nolu görüntü üzerinden VTM ile voksel intensite değerlerini öznitelik olarak belirleyen model

Sekiz farklı senaryo için kayıp maskeleri kullanılarak voksel intensite değerlerinden öznitelik vektörleri oluşturulmuştur. 3B binary maske boyutları her bir senaryo için farklı boyutlarda oluştuğundan dolayı veri kümelerinin boyutları da farklıdır. Satır sayıları denek veri seti ile aynı olmakla beraber sütun sayısı senaryolar arası farklılık göstermektedir. Şekil 5.22'de NS GM için elde edilen 140*11864 boyutlu veri kümesi voksel intensite değerlerine göre verilmektedir.



Şekil 5.22. 70 NK ve 70 AH MR görüntülerinde NS GM görüntülerinde VTM maskesi ile elde edilen 140*11864 boyutlu voksel intensite özellik vektörü

5.5.5. 3B Ayrık Dalgacık Dönüşümü

Bir boyutlu sinyaller zamana bağlı fonksiyonlardır. Bu fonksiyonlarda zamanın herhangi bir anındaki büyüklük sinyalin o noktadaki genlik bilgisini vermektedir. Genlik bilgisi sinyalin karakteristiği hakkında sınırlı bilgi vermektedir. Eğer sinyalin içerdiği frekans bileşenleri bulunabilirse sinyal hakkında daha fazla bilgi edinilir. Sinyalin zaman domeninden frekans domenine matematiksel dönüşümü Joseph Fourier tarafından yapılmıştır. Fourier 1B sinyalin onu oluşturan sinüs ve kosinüs sinyallerinin birleşiminden meydana geldiğini tanımlamıştır. Fourier dönüşümü (FD) olarak bilinen bu matematiksel kavram durağan sinyallerde net bir şekilde frekans-genlik bilgisini vermektedir. Bu bilgi her frekanstan ne kadar olduğunu gösterir. Durağan sinyallerdeki

frekans bileşenleri zamanın her anında bulunduğu için zaman bilgisinin önemi yoktur (Anonim, 2017l; 2017k). Ancak biyolojik sinyallerin birçoğu durağan olmayan sinyallerdir. Bu sinyallerde bazı frekans bileşenleri zamanın herhangi bir anında ortaya çıkıp kaybolur. Bu nedenle zaman-frekans problemi ortaya çıkmıştır. Bu amaçla geliştirilen yöntemlerden bir tanesi Kısa Zamanlı Fourier Dönüşümü'dür (KZFD). KZFD sinyali eşit parçalı pencerelere bölerek her bir pencerenin ayrı ayrı FD'sini alır. Ancak bu dönüşümde frekansın göründüğü kesin zaman dilimini verememektedir (Köktürk, 2006). Bu problemi gidermek için Sürekli Dalgacık Dönüşümü (SDD) ileri sürülmüştür (Erdoğmuş ve Pekçakar, 2009).

Dalgacık dönüşümünde sinyal boyunca kaydırılan, ölçeklenebilir ve ortalaması sıfır olan dalgacıklar kullanılmaktadır. Dalgacık kaydırıldıkça o bölgedeki sinyal parçasının spektral davranışı izlenir. KZFD'de eşit zaman aralıklarında işlem yapılırken, SDD'de yüksek frekanslarda küçük zaman aralığı, düşük frekanslarda geniş zaman aralığı kullanılmaktadır. Böylece yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlüğü, düşük frekanslarda düşük zaman çözünürlüğü ve yüksek frekans çözünürlüğü elde edilir. *S* ölçek parametresi, τ kaydırma parametresi olmak üzere $\psi_{s,\tau}(t)$ ana dalgacık fonksiyonu Eşitlik 5.22'de verilmektedir. Ana dalgacık fonksiyonları ölçek ve kaydırma parametreleri ile oluşturulur ve Eşitlik 5.23'te gösterildiği gibi ortalaması veya fonksiyon altında kalan alanı sıfırdır. *f(t)* dönüşümü yapılacak fonksiyon olmak üzere SDD hesabı ana dalgacık fonksiyonu ile Eşitlik 5.24'te gösterildiği gibi *f(t)* fonksiyonun integrali alınarak hesaplanır (Sevindir ve ark., 2015).

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t-\tau}{s}\right) \tag{5.22}$$

$$\int_{-\infty}^{+\infty} \psi_{s,\tau}(t)dt = 0 \tag{5.23}$$

$$SDD(s,\tau) = \frac{1}{\sqrt{s}}\int_{-\infty}^{+\infty} f(t)\psi^*\left(\frac{t-\tau}{s}\right)dt \tag{5.24}$$

Eşitlik 5.24'te s ve τ değeri sürekli değerler almaktadır. Bundan dolayı SDD'de veri yükünün ve işlem sayısının çok fazla olmasından dolayı Ayrık Dalgacık Dönüşümü (ADD) önerilmiştir. SDD'de işlem yükünü arttıran sürekli değerler yerine ADD'de öteleme ve ölçekleme değerleri ikinin katları olmak üzere ayrık değerler alır. ADD için

modellenen dalgacık kümesi *k* öteleme katsayısı *j* ölçekleme katsayısı olmak üzere Eşitlik 5.25'te gösterildiği gibi ifade edilir (Sevindir ve ark., 2015).

$$\psi_{j,k}(x) = 2^{-j/2}\psi(2^{-j}x - k) \qquad j,k \epsilon Z \tag{5.25}$$

Eşitlik 5.25'te verilen dalgacık kümesi ile ADD katsayıları Eşitlik 5.26'da verilen denklem ile hesaplanır.

$$c_{j,k} = 2^{j/2}\int_{-\infty}^{+\infty} f(x)\psi(2^{-j}x - k)dx \tag{5.26}$$

Katsayılardan yola çıkarak f(x) fonksiyonu Eşitlik 5.27 ile bulunur.

$$f(x) = \sum_{j=-\infty}^{\infty}\sum_{k=-\infty}^{\infty} c_{j,k}\psi_{j,k}(x) \tag{5.27}$$

Yapılan ADD dönüşümünde sinyal dalgacık fonksiyonları ($\psi(x)$) ve ölçekleme fonksiyonları ($\varphi(x)$) cinsinden elde edilir. $g(k) = (-1)^k h(1-k)$ olarak tanımlanmak üzere dalgacık fonksiyonu Eşitlik 5.28 ve ölçekleme fonksiyonu Eşitlik 5.29'da gösterildiği gibi tanımlanır (Sevindir ve ark., 2015).

$$\psi(x) = \sqrt{2}\sum_{k} g(k)\varphi(2x - k) \tag{5.28}$$

$$\varphi(x) = \sqrt{2}\sum_{k} h(k)\varphi(2x - k) \tag{5.29}$$

J seviyeli ayrıştırma için *f(x)* fonksiyonu Eşitlik 5.30'da gösterildiği gibi elde edilir.

$$f(x) = \sum_{k} c_{j_0,k}\varphi_{j_0,k}(k) + \sum_{j=j_0}^{J}\sum_{k} d_{j,k}\psi_{j,k}(x) \tag{5.30}$$

ADD ile *j* seviyesinde ($c_{j,k}$) yaklaşım katsayıları ve ($d_{j,k}$) detay katsayıları hesaplanır. Detay katsayıları kullanılan dalgacığa göre yüksek frekans bileşenlerini verirken, yaklaşım katsayıları sinyalin düşük frekans bileşenlerini vermektedir. Yaklaşım katsayıları tekrar alçak ve yüksek geçiren filtreler ile ayrıştırılarak bir alt bandın yaklaşım ve detay katsayıları elde edilir. Bu işlemin tekrar edilmesi ile 1B sinyallerin daha detaylı analizi gerçekleştirilmektedir. Özellikle durağan olmayan EEG ve EKG gibi biyolojik sinyallerin analizinde sıklıkla kullanılmaktadır (Coşkun ve İstanbullu, 2012; Sevindir ve ark., 2015).

İki boyutlu ADD görüntü işlemede sıklıkla kullanılan bir tekniktir. Gürültü giderme, görüntü sıkıştırma ve doku analizi uygulamalarında popüler bir yöntemdir. Özellikle görüntülerdeki dokusal farklılıkların karakteristiklerinin çıkarılmasında etkin

sonuçlar verdiği belirtilmektedir. İki boyutlu ADD görüntünün frekans spektrumunu yaklaşım alt görüntüsü, yatay, dikey ve diyagonal detay görüntüsü olmak üzere dört alt banda bölmektedir. İki boyutlu dalgacık dönüşümü bir boyutlu dalgacık dönüşümündeki adımların takip edilmesi ile yapılır. Bu işlem iki adımdan oluşmaktadır. Birinci adımda 1B dalgacık her bir satır için uygulanır ve sonuçta yeni bir matris ortaya çıkar. İkinci adımda 1B wavelet birinci adımın her sütunu için yapılır. Bu işlemler için bir adet iki boyutlu ölçekleme fonksiyonu φ(x,y) (Eşitlik 5.31) ve üç adet iki boyutlu dalgacık fonksiyonu $\psi^Y(x,y)$ (Eşitlik 5.32), $\psi^D(x,y)$ (Eşitlik 5.33), $\psi^K(x,y)$ (Eşitlik 5.34) türetilmelidir. Bu fonksiyonlar bir boyutlu ölçekleme fonksiyonu ve dalgacık fonksiyonun çarpımından türetilmektedir (Demirhan, 2012).

$$\varphi(x,y) = \varphi(x)\varphi(y) \tag{5.31}$$

$$\psi^Y(x,y) = \psi(x)\varphi(y) \tag{5.32}$$

$$\psi^D(x,y) = \varphi(x)\psi(y) \tag{5.33}$$

$$\psi^K(x,y) = \psi(x)\psi(y) \tag{5.34}$$

İki boyutlu uzayda dalgacık ve ölçekleme temel fonksiyonlarının matematiksel ifadeleri Eşitlik 5.35 ve Eşitlik 5.36'da gösterildiği gibi elde edilir. *(Y: Yatay, D: Dikey, K: Köşegen, i: Dalgacık Yönü)*

$$\psi^i_{j,m,n}(x,y) = 2^{j/2}\psi^i(2^j x - m, 2^j y - n) \qquad i=\{(Y,D,K) \tag{5.35}$$

$$\varphi_{j,m,n}(x,y) = 2^{j/2}\varphi(2^j x - m, 2^j y - n) \tag{5.36}$$

Bu ifadelerden yola çıkarak M*N matris büyüklüğü olan iki boyutlu bir görüntünün j_0 ölçekleme derecesi olmak üzere W_φ yaklaşım katsayıları ve W_ψ yatay, dikey, diyagonal ADD katsayıları ve Eşitlik 5.37 ve 5.38'de verildiği gibi hesaplanır.

$$W_\varphi(j,m,n) = \frac{1}{\sqrt{MN}}\sum_{x=0}^{M-1}\sum_{y=0}^{N-1} f(x,y)\varphi_{j_0,m,n}(x,y) \tag{5.37}$$

$$W^i_\psi(j,m,n) = \frac{1}{\sqrt{MN}}\sum_{x=0}^{M-1}\sum_{y=0}^{N-1} f(x,y)\psi^i_{j,m,n}(x,y) \qquad i=\{(Y,D,K) \tag{5.38}$$

Elde edilen ADD katsayılarından iki boyutlu görüntü ise Eşitlik 5.39'da verildiği gibi ifade edilir (Demirhan, 2012).

$$f(x,y)=\frac{1}{\sqrt{MN}}\sum_{m}\sum_{n}W_{\varphi}(j_0,\mathrm{m},n)\varphi_{j_0,m,n}(x,y) \tag{5.39}$$

$$+\frac{1}{\sqrt{MN}}\sum_{i=Y,D,K}\sum_{j=j_0}^{\infty}\sum_{m}\sum_{n}W_{\psi}^{i}(j,m,n)\psi_{j,m,n}^{i}(x,y)$$

Üç boyutlu ayrık dalgacık dönüşümünün temelinde 1B dalgacık dönüşümünün x,y,z olmak üzere üç yönde uygulanması yatar. 3B ADD, bir üç boyutlu ölçekleme fonksiyonu ve yedi tane üç boyutlu dalgacık fonksiyonlarını kullanır. Her 3B fonksiyon bir boyutlu fonksiyonların kombinasyonlarından oluşur. $\varphi(x,y,z)$ fonksiyonu ölçekleme fonksiyonu olmak üzere Eşitlik 5.40'da , $\omega^{i}(x,y,z)\quad i\in\{1,2,3,4,5,6,7\}$ dalgacık fonksiyonları olmak üzere Eşitlik 5.41-5.47'de verilmektedir.

$$\varphi(x,y,z)=\varphi(x)\varphi(y)\varphi(z) \tag{5.40}$$

$$\omega^{1}(x,y,z)=\omega(x)\varphi(y)\varphi(z) \tag{5.41}$$

$$\omega^{2}(x,y,z)=\varphi(x)\omega(y)\varphi(z) \tag{5.42}$$

$$\omega^{3}(x,y,z)=\omega(x)\omega(y)\varphi(z) \tag{5.43}$$

$$\omega^{4}(x,y,z)=\varphi(x)\varphi(y)\omega(z) \tag{5.44}$$

$$\omega^{5}(x,y,x)=\omega(x)\varphi(y)\omega(z) \tag{5.45}$$

$$\omega^{6}(x,y,z)=\varphi(x)\omega(y)\omega(z) \tag{5.46}$$

$$\omega^{7}(x,y,z)=\omega(x)\omega(y)\omega(z) \tag{5.47}$$

P ayrışma seviyesi (*decomposition level*), *L*M*N* üç boyutlu görüntünün boyutları, *f(x,y,z)* görüntü olmak üzere olmak üzere ölçekleme ve dalgacık temel fonksiyonları sırasıyla Eşitlik 5.48 ve Eşitlik 5.49'da, W_{φ} yaklaşım katsayıları ve W_{ω}^{i} detay katsayıları olmak üzere sırasıyla Eşitlik 5.50 ve 5.51'de, *f(x,y,z)* görüntü fonksiyonunun detay ve yaklaşım katsayıları cinsinden gösterimi matematiksel olarak Eşitlik 5.52'de verilmiştir (Aggarwal ve ark., 2015a).

$$\varphi_{P,l,m,n}(x,y,z)=2^{P/2}\varphi(2^{P}x-l,2^{P}y-m,2^{P}z-n) \tag{5.48}$$

$$\omega_{p,l,m,n}^{i}(x,y,z)=2^{p/2}\omega^{i}(2^{p}x-l,2^{p}y-m,2^{p}z-n),i=\{1,.....7\} \tag{5.49}$$

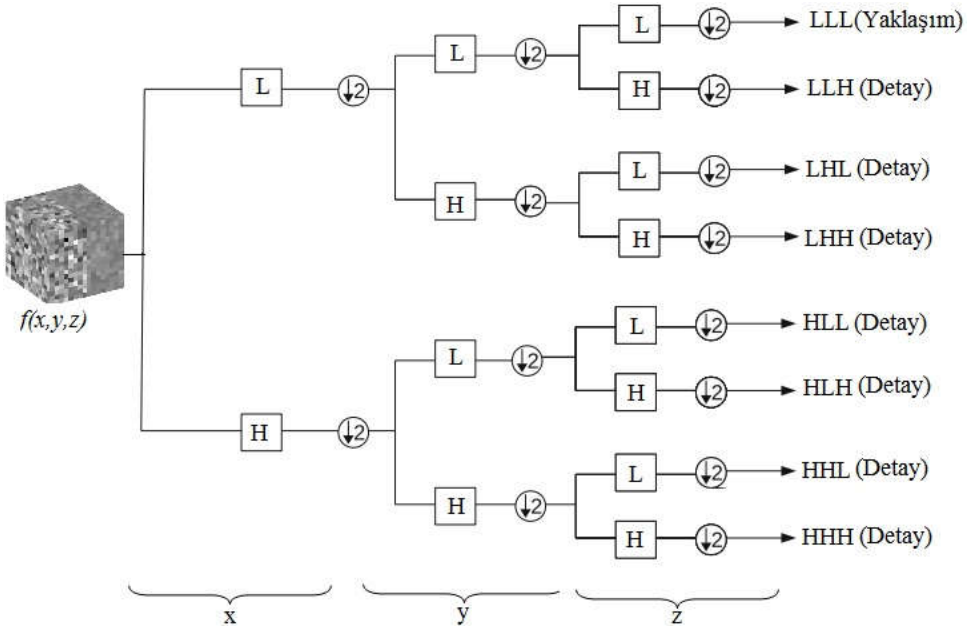
$$W_{\varphi}(P,l,m,n)=\frac{1}{\sqrt{LMN}}\sum_{x=0}^{L-1}\sum_{y=0}^{M-1}\sum_{z=0}^{N-1}f(x,y,z)\varphi_{P,l,m,n}(x,y,z) \tag{5.50}$$

$$W_{\omega}^{i}(p,l,m,n)=\frac{1}{\sqrt{LMN}}\sum_{x=0}^{L-1}\sum_{y=0}^{M-1}\sum_{z=0}^{N-1}f(x,y,z)\omega_{p,l,m,n}^{i}(x,y,z), i=\{1,...,7\} \tag{5.51}$$

$$f(x,y,z)=\frac{1}{\sqrt{LMN}}\sum_{l}\sum_{m}\sum_{n}W_{\varphi}(P,l,m,n)\varphi_{P,l,m,n}(x,y,z) \tag{5.52}$$

$$+\frac{1}{\sqrt{LMN}}\sum_{i=1}^{7}\sum_{p=1}^{P}\sum_{l}\sum_{m}\sum_{n}W_{\omega}^{i}(p,l,m,n)\omega_{p,l,m,n}^{i}(x,y,z)$$

3B ADD üç boyutlu bir görüntüyü detay ve yaklaşım katsayılarına ayrılmaktadır. Görüntü dalgacıklar kullanılarak oluşturulmuş yüksek ve alçak geçiren filtreler ile sekiz alt banda ayrılır. *f(x,y,z)* üç boyutlu bir görüntü olmak üzere görüntü öncelikle *x* yönünde *L(x,y,z)* alçak geçiren ve *H(x,y,z)* yüksek geçiren filtrelere tabi tutulur. Aynı işlem daha sonra sırasıyla *y* ve *z* yönlerine yapılarak işlem tamamlanır. *LLL, LLH, LHL, LHH, HLL, HLH, HHL* ve *HHH* olmak üzere üzere sekiz alt bant oluşmaktadır. Daha fazla ayrışım yapılmak istenirse *LLL* katsayılarından işlem devam ettirilerek daha fazla katsayı elde edilebilir (Özmen ve Özşen, 2017). Şekil 5.23'te *f(x,y,z)* üç boyutlu bir görüntü kullanarak 3B ADD katsayılarını elde eden mimari model gösterilmektedir.



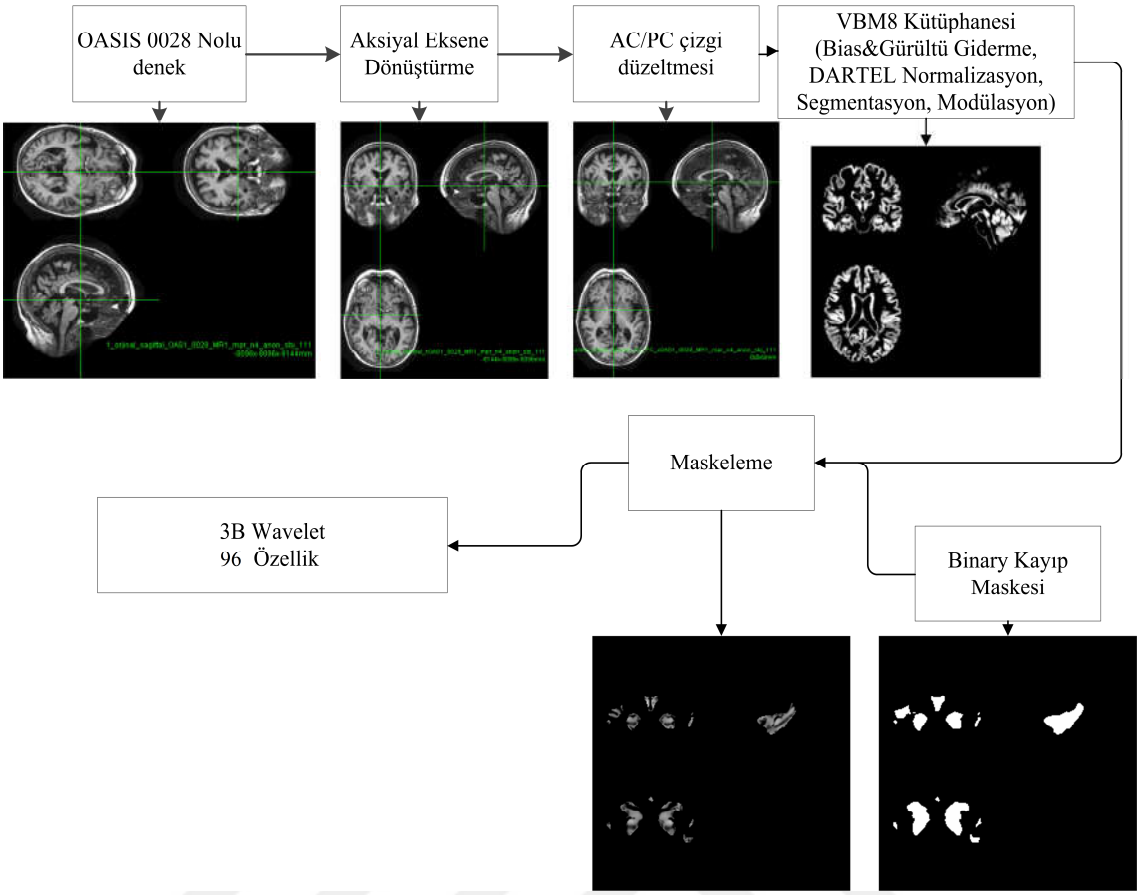
Şekil 5.23. f(x,y,z) üç boyutlu bir görüntünün alçak ve yüksek geçiren filtreler kullanılarak 3B ADD detay ve yaklaşım katsayılarını elde eden mimarisi

3B ADD dönüşümü, tez çalışmasında elde edilen sekiz farklı senaryodaki VOI görüntüler için gerçeklenmiştir. Tüm VOI görüntülerde 37 farklı dalgacık türü kullanılmıştır. Literatürde yapılan bazı çalışmalarda dalgacık türü rastgele seçildiğinden dolayı hangi dalgacığın başarılı sonuç verdiğini belirlemek sınırlı bir bilgi vermektedir. Dolayısıyla tez çalışmasında 37 dalgacık türü denenmiş ve en iyi sonucu veren dalgacık türleri ortaya konmuştur. Çizelge 5.3'de kullanılan dalgacık türleri verilmektedir.

Çizelge 5.3. 3B ADD için kullanılan dalgacık türleri

db1	coif1	sym5	bior2.8
db2	coif2	sym6	bior3.1
db3	coif3	sym7	bior3.3
db4	coif4	sym8	bior3.5
db5	coif5	bior1.3	bior3.7
db6	sym1	bior1.5	bior3.9
db7	sym2	bior2.2	bior4.4
db8	sym3	bior2.4	bior5.5
db9	sym4	bior2.6	bior6.8
haar			

Her bir VOI görüntü Çizelge 5.3'te verilen dalgacık türleri ile iki seviye analiz ile LLL altbandı da dahil edilerek 16 altband elde edilmiştir. Her bir altbant bir vektör haline getirilerek HTBDİ'de kullanılan Eşitlik (5.16-5.21) formülleri ile katsayıların ortalama, varyans, çarpıklık, basıklık, enerji ve entropi değerleri elde edilmiştir. Böylece bir VOI görüntüden 96 adet özellik çıkarılmıştır. Sonuç olarak her bir senaryo için 37 adet 140*96 matris büyüklüğe sahip özellik kümesi ortaya konulmuştur. Şekil 5.24'te 3B ADD için OAS1_0028 nolu görüntüde önişleme ve VOI özellik çıkarma yöntemleri için kullanılan model gösterilmektedir.

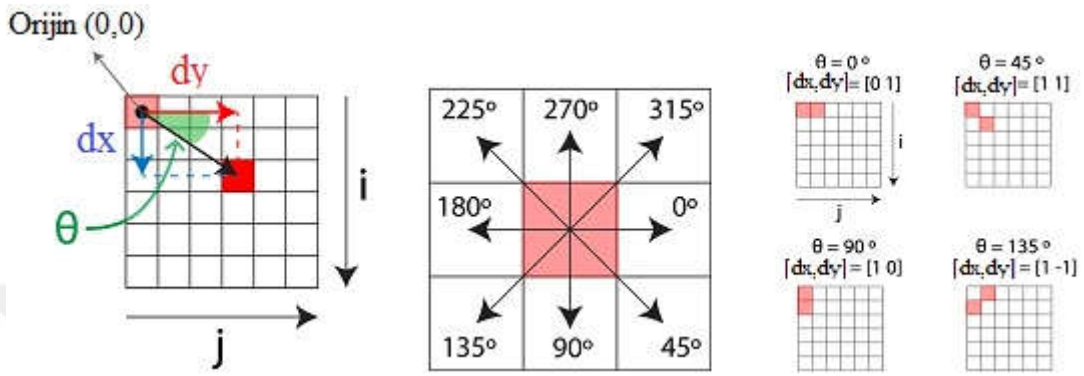


Şekil 5.24. OAS1_0028 nolu görüntüde önişleme ve VOI çıkarımı yöntemleri ile beraber 3B ADD özelliklerinin çıkarımı için kullanılan model

5.5.6. 3B Gri Seviye Eş Oluşum Matrisleri

GSEOM 1973 yılında görüntüler üzerindeki piksel komşuluklarının uzaysal bağımlılığının belirlenebilmesi için bir doku analizi yöntemi olarak Haralick tarafından tanımlanmıştır (Haralick ve Shanmugam, 1973). GSEOM, İki boyutlu bir görüntüdeki her bir pikselin komşu pikseller ile gri seviye dağılım komşuluklarından oluşturulan yeni bir matristen özellik çıkarılmasına dayanmaktadır. Eş oluşum matrisi görüntüdeki gri seviye değeri N ise, $N*N$'lik bir kare matristen oluşur. Eş oluşum matrisindeki dağılım görüntüdeki herhangi bir referans pikselin seçilen komşu bir piksele göre uzaklığı ve açısına göre şekillenir. Pikseller arası uzaklık ve piksellerin birbirine göre açısal yönleri en önemli iki faktördür. Matrisin her bir değeri d uzaklıklı i ve j piksel değerli çiftin tekrarlanma sayısını vermektedir. Piksel çiftleri $P[i,j]$, bir uzaklık ve deplasman vektörü (*displacement vector*) ile temsil edilir. En çok kullanılan açısal yönler ϑ= 0, 45, 90, 135 ve bu açıların simetrik yönleridir. $D=(dx, dy)$ olarak gösterilen deplasman vektöründe dx x ekseninde ne kadar hareket ettiğini, dy y ekseninde ne kadar

hareket ettiğini göstermektedir. Şekil 5.25a'da bir pikselin GSEOM için uzaklık ve açı değerinin gösterilmesi, Şekil 5.25b'de bir pikselin açısal olarak bakılabilecek komşuluk açı değerleri gösterilmekte, Şekil 5.25c'de en çok kullanılan 0,45,90,135 derecede bir pikselin bir uzaklıklı komşulukları renklendirilerek gösterilmiştir (Valentin ve ark., 2016).



(a) (b) (c)

Şekil 5.25. (a) bir pikselin GSEOM için uzaklık ve açı değerinin gösterimi (b) Bir pikselin açısal olarak bakılabilecek komşuluk açı değerleri (c) En çok kullanılan 0,45,90,135 derecede bir pikselin bir uzaklıklı komşulukları renklendirilerek gösterimi (Valentin ve ark., 2016)

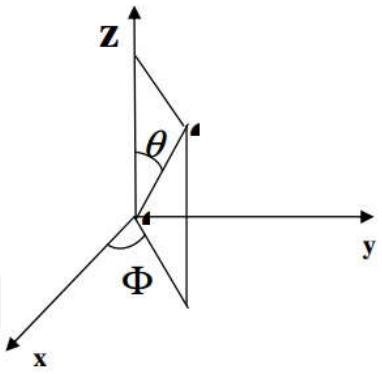
Çizelge 5.4'te 2B GSEOM için en çok kullanılan yön açı değerleri ve onlara karşılık gelen yön tanımlı deplasman vektörü verilmiştir.

Çizelge 5.4. 2B GSEOM için kullanılan açısal yön değerleri ve yön tanımlı deplasman vektörü

Yön	Yön Tanımlı Deplasman Vektörü
0°	(0,D)
45°	(D,D)
90°	(D,0)
135°	(D,-D)

GSEOM özellikleri kullanılarak iki boyutlu görüntülerde özellik çıkarma işlemi literatürde sıklıkla kullanılmaktadır. Ancak özellikle birbirini takip eden üç boyutlu hacimsel görüntülerde kullanımı ile ilgili az sayıda çalışmaya rastlanılmıştır. Kesitlerin her birinde ilgili bölgelerin tek tek 2B olarak GSEOM ile incelenmesi çok fazla veri olmasına ve karmaşaya neden olacaktır. Bundan dolayı 3B görüntülerde 2B olarak tek tek bakmak yerine üç boyutlu bir analizin daha güçlü sonuçlar verdiği belirtilmiştir (Kurani ve ark., 2004). Üç boyutlu işlemler için voksel komşuluklarının gri seviye değerleri kullanılarak üç boyutu temsil eden bir komşuluk matrisi ortaya

çıkarılmaktadır. Geleneksel 2B GSEOM'a ek olarak 3B GSEOM işleminde deplasman vektörüne *z* ekseni eklenir (*d=dx,dy,dz*). *dz z* ekseninde ne kadar gidileceğini belirtmektedir. Üç boyutlu uzayda bir vokselden hangi açıda komşuluk bağımlılığının araştırılacağı θ ve Φ açılarına bağlıdır. Φ açısı xy düzlemindeki hareketi, θ açısı z düzleminden aşağı ve yukarı hareketi tanımlar. Şekil 5.26'da θ ve Φ açılarının x,y,z düzlemlerindeki yönlendirmeleri gösterilmektedir (Othmen ve ark., 2013).

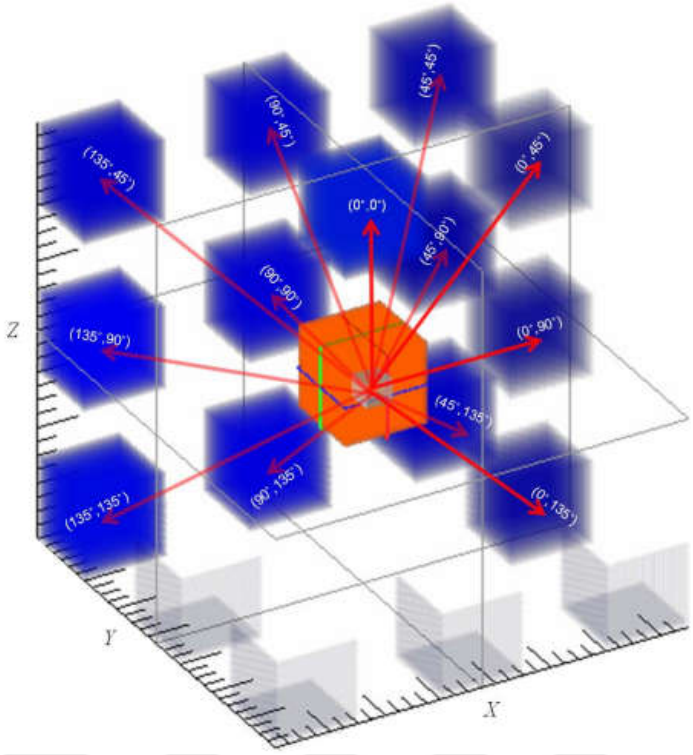


Şekil 5.26. Φ ve Θ açılarının x,y,z düzlemlerindeki yönlendirmelerinin gösterimi (Othmen ve ark., 2013)

Bu açılar ile beraber voksel komşulukları 26 yönde tanımlanabilir. Hacimsel durumlarda bir vokselin 26 komşusu vardır ancak deplasman vektörleri iki yönlü olduğu için veriyi tanımlamaya 13 komşuluk yeterlidir. Çizelge 5.5'te üç boyutlu uzayda 13 yön için açı değerleri ve yön tanımlı deplasman vektörleri verilmiştir. Şekil 5.27'de bir vokselin 1 uzaklık tanımlı açısal komşulukları gösterilmektedir.

Çizelge 5.5 Üç boyutlu uzayda 13 yön için açısal değerler ve açı tanımlı deplasman vektörleri (Othmen ve ark., 2013)

Yön(Φ,Θ)	Deplasman Vektörü
0º,0º	(0,D,0)
45º,0º	(-D, D, 0)
90º,0º	(-D, 0,0)
135º,0º	(-D, -D, 0)
0º,45º	(0, D, -D)
0º,90º	(0, 0, -D)
0º,135º	(0, -D, -D)
90º,45º	(-D, 0, -D)
90º,135º	(D, 0, -D)
45º,45º	(-D, D, -D)
45º,135º	(D, -D, -D)
135º,45º	(-D, -D, -D)
135º,135º	(D, D,- D)



Şekil 5.27. Bir vokselin 1 adım uzaklıkta bulunan 13 açısal yönlendirmenin gösterimi(Liu ve ark., 2010)

MNS GM, BM ve NS GM, BM görüntüler VTM binary maskeler ile segmente edildikten sonra her bir görüntünün 3B GSEOM oluşturulmuştur. Her bir eş oluşum matrisleri ile 12 özellik çıkarılmıştır (Murcia, 2017). *P(i,j)* eş oluşum matrisini göstermek üzere özellik çıkarmada kullanılan enerji, entropi, korelasyon, kontrast, homojenite, varyans, toplam ortalama, inertia, cluster shade, cluster tendency, maksimum olasılık, ters varyans değerlerinin matematiksel ifadeleri sırasıyla Eşitlik 5.53-5.64'te verilmiştir (Philips ve Li, 2017) (Murcia, 2017) .

$$\sum_{i,j}\{P(i,j)\}^2 \tag{5.53}$$

$$-\sum_{i,j}P(i,j)*\log(P(i,j)) \tag{5.54}$$

$$\sum_{i,j}\frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i\sigma_j} \tag{5.55}$$

$$\sum_{i,j}|i-j|^2P(i,j) \tag{5.56}$$

$$\sum_{i,j}\frac{P(i,j)}{1+|i-j|} \tag{5.57}$$

$$\sum_{i,j}(i-\mu_i)^2 P(i,j)+(j-\mu_j)^2 P(i,j) \tag{5.58}$$

$$\frac{1}{2}\sum_{i,j}(iP(i,j))+jP(i,j)) \tag{5.59}$$

$$\sum_{i,j}(i-j)^2 * P(i,j) \tag{5.60}$$

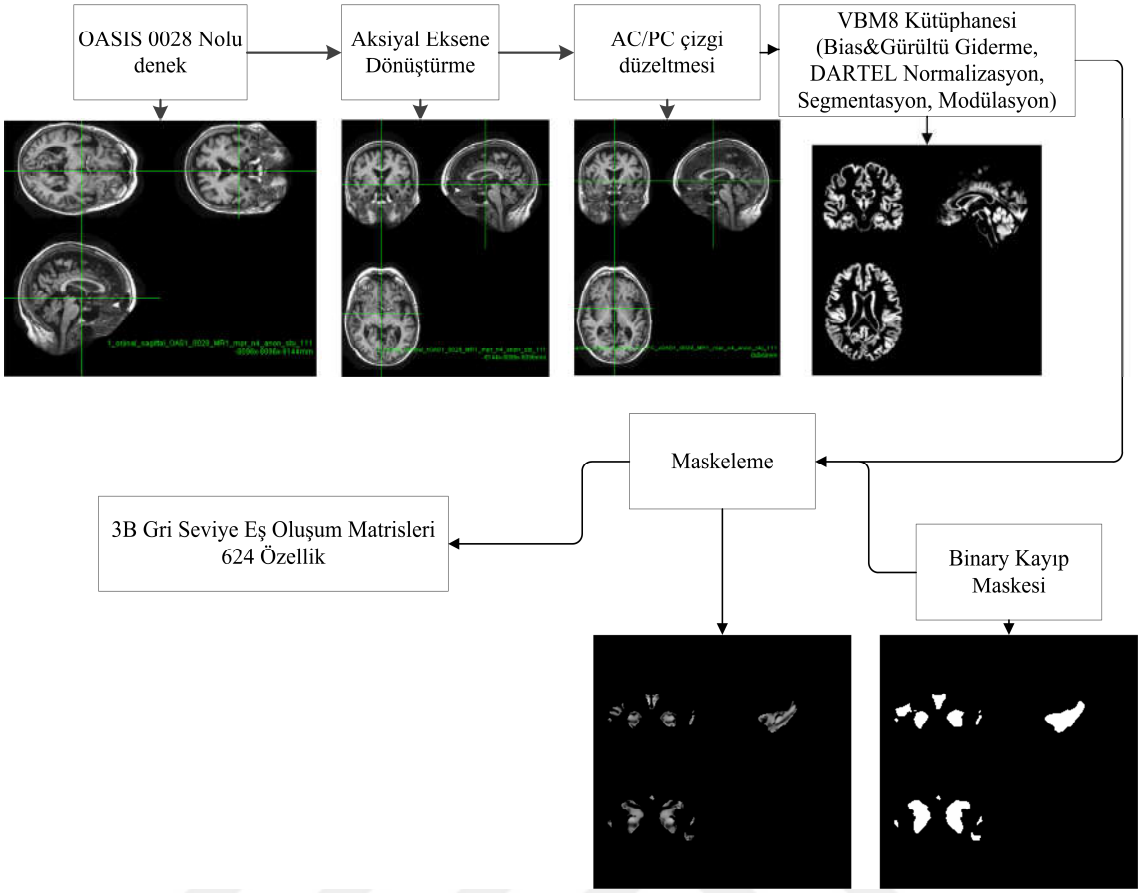
$$\sum_{i,j}(i+j-\mu_x-\mu_y)^3 * P(i,j) \tag{5.61}$$

$$\sum_{i,j}\{i+j-\mu_x-\mu_y\}^4 * P(i,j) \tag{5.62}$$

$$\max(P) \tag{5.63}$$

$$\sum_{i,j}\frac{P(i,j)}{(i-j)^2} \tag{5.64}$$

Daha önce belirtilen sekiz senaryo için Çizelge 5.5'te verilen 13 yönde, 1,2,4,8 uzaklık değerlerinde ve 12 özellik olmak üzere her bir maskelenmiş görüntüde 624 özellik elde edilmiştir (Philips ve Li, 2008; Varjo, 2014). Böylece her bir senaryo için 140*624 özellik kümesi olmak üzere sekiz farklı özellik kümesi oluşturulmuştur. Şekil 5.28'de OAS1_0028 nolu görüntüde MNS GM görüntüsünde VTM ile maskeleme kullanarak 3B GSEOM özeliklerinin çıkarıldığı model gösterilmektedir.



Şekil 5.28. OAS1_0028 nolu MR görüntüsünden 3B GSEOM özelliklerinin çıkarılması için önişleme ve VTM maskeleme ile beraber kullanılan model

5.6. Özellik Seçme

Özellik seçme işlemi bir analiz sonucu ortaya çıkan verilerden sınıflandırıcı için en iyi özelliklerinin belli kriterlere göre belirlenmesi işlemidir. Analiz sonuçlarında veri sayısındaki artış boyutun laneti problemini ortaya çıkarmaktadır. Bu problem sınıflandırıcı performansını düşürdüğü gibi eğitim ve test sürelerinin de artmasına neden olmaktadır. Özellikle gerçek zamanlı uygulamalarda verinin büyük olması sınıflandırma işlemlerini daha da zorlaştırmaktadır. Veri içindeki bazı öznitelikler sınıflandırıcı bilgisini hiç barındırmayabilir. Diğer veriler ise sınıflandırıcı performansını öznitelik kalitesine göre arttırabilir. Bundan dolayı veriye uygun bir özellik seçme yöntemine göre sınıflandırıcı için en iyi özellikleri seçebilecek bir işlem yapmak gerekmektedir (Ünsalan ve Erçil, 1998). Özellik seçme yöntemleri temel olarak filtre metotları (*filter methods*), sarmalı metotlar (*wrapper methods*) ve gömülü metotlar (*embedded methods*) olmak üzere üçe ayrılmaktadır. Filtre metotları herhangi bir sınıflandırıcı modelini

dikkate almadan verinin içinden belli kriterlere göre anlamlı özellik altkümesinin çıkarılmasıdır. Sarmalı metotlar ise verinin muhtemel altkümelerini oluşturarak bu veri kümeciklerinin tek tek sınıflandırıcı ile değerlendirilmesi mantığına dayanır. Gömülü metotlar ise sarmalı metotlar ve filtre metotlarının birleştirilmesi ile tasarlanır. Özellik seçme yöntemleri nörolojik data analizlerinde sıklıkla kullanılmaktadır (Chu ve ark., 2012; Mwangi ve ark., 2014).

Tez çalışmasında filtre metotlarından özellik derecelendirme yöntemi (*feature ranking*) ile özellik seçme işlemi yapılmıştır. Diğer birçok özellik seçme yöntemi denenmesine rağmen tez çalışmasındaki tüm veriler için ortak bir özellik seçme işlemi ve performans analizi bu yöntem ile yapılabilmiştir. WEKA, RapidMiner ve Orange Canvas gibi popüler veri madenciliği programları incelenmiş, ancak bazı veriler çok büyük olduğu için denemeler yapılamamış, programlar zorlanmış ve zaman olarak çok fazla süre beklemek zorunda kalınmıştır. Bu nedenle özellik derecelendirme kriterlerinden t-test, entropi, Bhattacharry, roc ve Wilcoxon olmak üzere beş farklı kritere göre özellik seçme işlemi yapılmıştır (Pourreza ve ark., 2013; Nguyen ve ark., 2015; Anonim, 2017i).

T-testi parametrik bir test olup iki bağımsız değişken arasında anlamlı bir farklılık olup olmadığını belirler. İki ayrık veri setinin örnek büyüklüğü n_1 ve n_2, örnek ortalamaları μ_1 ve μ_2, örnek standart sapma değerleri σ_1 ve σ_2 olmak üzere t-testi Eşitlik 5.65'te verilen matematiksel ifade ile hesaplanır (Nguyen ve ark., 2015).

$$t = \frac{\mu_1 - \mu_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \tag{5.65}$$

Entropi testi, ıraksama olarak ta bilinen bağıl entropi sınıfların normal dağıldığını varsayan bir testtir. Entropinin büyük olması sınıfların daha iyi ayrılabilmesi anlamına gelmektedir. Örnek ortalamaları μ_1 ve μ_2, örnek standart sapma değerleri σ_1 ve σ_2 olmak üzere entropi Eşitlik 5.66'da verilen matematiksel ifade ile hesaplanır (Nguyen ve ark., 2015).

$$e = \frac{1}{2}\left[\left(\frac{\sigma_1^2}{\sigma_2^2} + \frac{\sigma_2^2}{\sigma_1^2} - 2\right) + \left(\frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2}\right)(\mu_1 - \mu_2)^2\right] \tag{5.66}$$

Bhattacharry uzaklık ölçütü iki veri arasındaki istatistiksel büyüklüklerle hesaplanan kritere göre sınıfların ayrıştırılabilirliğini ölçen bir kriterdir. Örnek ortalamaları μ_1 ve μ_2, örnek standart sapma değerleri σ_1 ve σ_2 olmak üzere Bhattacharry uzaklık Eşitlik 5.67'de verilen matematiksel denklem ile hesaplanır (Nguyen ve ark., 2015).

$$BD = \frac{1}{4}\ln\left[\frac{1}{4}\left(\frac{\sigma_1^2}{\sigma_2^2}+\frac{\sigma_2^2}{\sigma_1^2}+2\right)\right]+\frac{1}{4}\left[\frac{(\mu_1-\mu_2)^2}{\sigma_1^2+\sigma_2^2}\right] \tag{5.67}$$

İki popülasyondaki X'in dağılım fonksiyonlarını $F_1(x)$ve $F_2(x)$ olarak temsil edilirse, kuyruk fonksiyonu $T_i(x)=1-F_i(x),\ i=1,2.$ olarak ifade edilir. Bu eşitlikten yola çıkarak eğri altında kalan alan olarak da bilinen ROC Eşitlik 5.68'de verilen ifade ile belirtilir (Nguyen ve ark., 2015).

$$ROC(t) = T_1\left(T_2^{-1}(t)\right), t \in (0,1) \tag{5.68}$$

Wilcoxon testi parametrik olmayan bir testtir ve ölçümler arasında fark olup olmadığı sınanabilir. Mann Whitney U testi olarak adlandırılan bu test bağımsız iki örnek arasındaki anlamlılığı araştırmak için kullanılmıştır. n_1 ve n_2 küme büyüklükleri olmak üzere iki kümedeki veriler birleştirilerek sıraya konulur. Her iki kümedeki sıralamalar nümerik olarak toplanır. R küçük kümedeki sıralamaların toplamı olmak üzere R değeri içiz z hesabı Eşitlik 5.69'daki matematiksel ifade ile hesaplanır. Eğer gözlem sayısı eşit ise herhangi bir kullanılabilir (Özler, 2017). Z değerinin hesaplanması için gerekli olan R'nin ortalaması μ_R Eşitlik 5.70 ile ve varyans değeri σ_R Eşitlik 5.71'de verildiği gibi hesaplanır (Nguyen ve ark., 2015; Vakharia ve ark., 2016).

$$z = \frac{R-\mu_R}{\sigma_R} \tag{5.69}$$

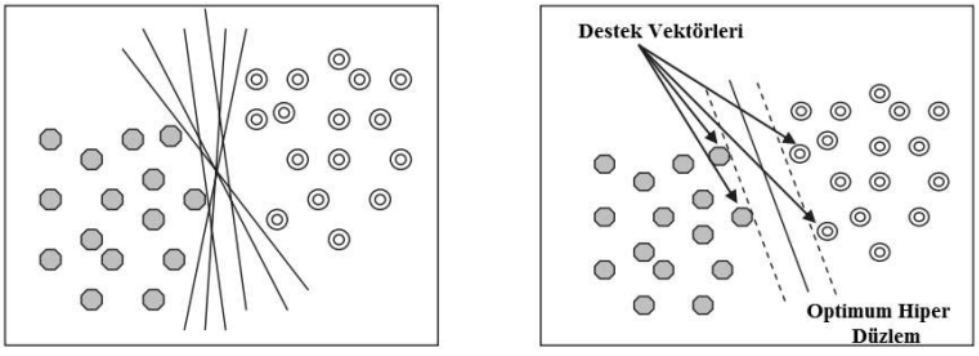
$$\mu_R = \frac{n_1(n_1+n_2+1)}{2} \tag{5.70}$$

$$\sigma_R = \sqrt{\frac{n_1 n_2(n_1+n_2+1)}{12}} \tag{5.71}$$

5.7. Sınıflandırma

Verilerde önişleme işleminden sonra sınıflandırma işlemi Destek Vektör Makinaları (DVM) ile gerçekleştirilmiştir. DVM eğitimli bir sınıflandırma tekniği olup temelinde istatistiksel öğrenme teorisi yatmaktadır. 1995 yılında Cortes ve Vapnik tarafından önerilmiştir (Cortes ve Vapnik, 1995). DVM'nin temel sınıflandırma yaklaşımı iki sınıfa ait verileri birbirinden ayıran en uygun hiper düzlemin belirlenmesidir. Temel yaklaşım doğrusal olarak ayrılabilen iki sınıflı bir veride, iki sınıf arasındaki sınırların maksimum uzaklıkta olduğu düzlemleri bulmaktır. Doğrusal olarak sınıflandırılabilen bir veride iki kümeyi ayıran birçok düzlem vardır. Eğitim ve etiket değerlerine göre eşitlenen veriler ile farklı sınıf verileri için karar fonksiyonları türetilir. Karar fonksiyonu ile türetilen düzlemlerden iki sınıf arasındaki uzaklığı maksimum yapan iki ayırıcı düzlem bulunur. Bu düzleme en yakın öğrenme verileri destek vektörleri olarak tanımlanmaktadır. Destek vektör makinaları verinin lineer olarak ayrılabilme ve lineer olarak ayrılamaması durumuna göre ikiye ayrılmaktadır (Cortes ve Vapnik, 1995; Kavzoğlu ve Çölkesen, 2010).

DVM temel mantığı eğitim verilerinden bir karar fonksiyonu ($g(x)=sign(f(x))$) oluşturarak yeni gelen test verilerini bu karar fonksiyonu üzerinden sınıflandırmaktadır. Doğrusal olarak ayrılabilen verilerde bu verileri iki sınıfa ayırabilen sonsuz sayıda hiper-düzlem bulunmaktadır. Bu düzlemler içinden iki sınıfı birbirinden ayıran karar sınırını destek vektörlerinden maksimum uzaklıkta olacak şekilde ayıran düzlemi bulmak eğitimin hedefidir. Eğitim işleminden sonra karar fonksiyonu ile yeni gelen test verileri sınıflandırılır. Şekil 5.29a'da iki sınıflı veriyi birbirinden doğrusal olarak ayıran birçok hiper-düzlem, Şekil 5.29b'de iki sınıfı birbirinden maksimum uzaklıkta ayıran hiper-düzlem ve destek vektörleri gösterilmektedir (Kavzoğlu ve Çölkesen, 2010).



(a) (b)

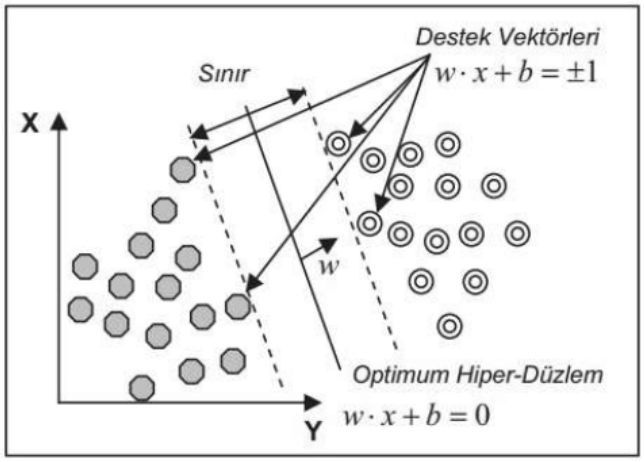
Şekil 5.29. (a) İki sınıflı veriler için muhtemel hiper düzlemler (b) İki sınıfı birbirinden maksimum ayıran optimum hiper düzlem ve destek vektörleri (Kavzoğlu ve Çölkesen, 2010)

İki sınıflı veride veri etiketlerinin *(-1,+1)* olduğu *k* sayıda eğitim verisinin olduğu *{(xi,yi) i=1,2,3……,k}* kabul edilirse, optimum hiper düzleme ait eşitsizlik denklemleri Eşitlik 5.72 ve Eşitlik 5.73'te verildiği gibi olur .

$$w.x_i + b \geq +1 \tag{5.72}$$

$$w.x_i + b \leq -1 \tag{5.73}$$

Bu eşitsizlik denklemlerinde, *x N* boyutlu uzayı, *w* ağırlık vektörü veya hiper-düzlemin normalini, *b* eğilim değerini temsil etmektedir. Uygun hiper düzlemin belirlenebilmesi için şekilde gösterilen iki paralel hiper düzlemin ve destek vektörlerin bulunması gerekmektedir. Paralel hiper düzlemlerin eşitsizlikleri şekilde gösterildiği gibi *w.xi+b=±1* olarak, optimum hiper düzlemin eşitsizliği *w.xi+b=±0* olarak ifade edilir. Şekil 5.30'da doğrusal veriler için bulunan sınırlar, destek vektörleri ve optimum hiper düzlem gösterilmektedir.



Şekil 5.30. Doğrusal veriler için bulunan sınırlar, destek vektörleri ve optimum hiper düzlem(Kavzoğlu ve Çölkesen, 2010)

İki kümeyi birbirinden ayıran optimum hiper-düzlemin bulunabilmesi için $\|w\|$ büyüklüğü minimum olmalıdır. Bu işlemin yapılabilmesi için Eşitlik 5.73'te verilen optimizasyon probleminin minimum çözümünün bulunması gerekmektedir.

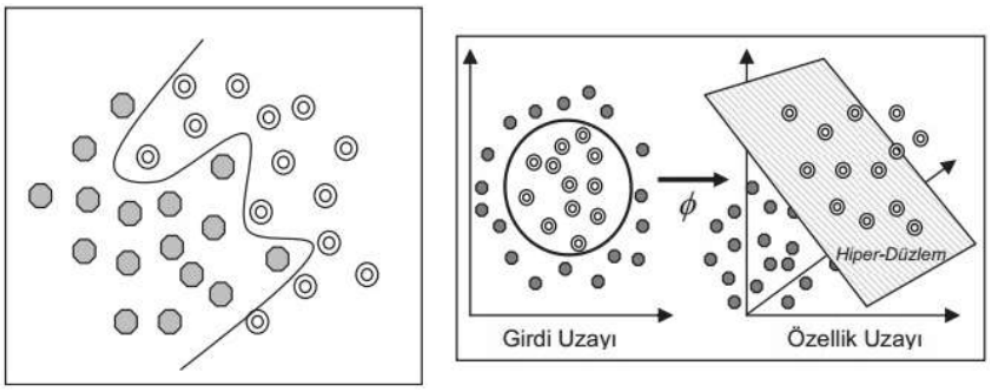
$$\min\left[\frac{1}{2}\|w\|^2\right] \tag{5.73}$$

Bu probleme bağlı sınırlar Eşitlik 5.74'te verilmiştir.

$$y_i(w.x_i + b) - 1, y_i \in \{1, -1\} \tag{5.74}$$

Eşitsizlik ve sınır değerleri verilen bu optimizasyon problemi Lagrange denklemleri ile çözülmektedir. Bu işlem sonunda iki sınıflı lineer veriyi ayıran karar

fonksiyonu ortaya konulur. Ancak birçok sınıflandırma probleminde veriler Şekil 5.31a'da gösterildiği gibi doğrusal olarak ayrılamamaktadır. Optimum hiper düzlemin diğer tarafında kalan test verilerinden kaynaklanan problem bir yapay değişkenin tanımlanması ile çözülür. Yanlış sınıflandırma hatalarını minimum ve destek vektörleri arasındaki sınırın maksimum duruma getirilmesi için denge, bir düzenleme parametresi ile sağlanır. Bu iki parametre ile doğrusal olarak ayrılamayan veriler için optimizasyon problemi tanımlanır. Tanımlanan optimizasyon probleminin çözümü için Şekil 5.31b'de gösterildiği gibi girdi verileri daha yüksek boyutlu bir uzaya aktarılır. Böylece doğrusal olarak ayrılamayan veriler *N* boyutlu uzayda doğrusal olarak ayrılarak optimum hiper düzlemler belirlenebilmektedir.



Şekil 5.31. (a) Doğrusal olmayan veri için hiper düzlem (b) Doğrusal bir şekilde ayrılamayan verilerin yüksek boyutlu uzaya aktarılması ve hiper düzlemin belirlenmesi (Kavzoğlu ve Çölkesen, 2010)

DVM'ler kernel fonksiyonları ile doğrusal olmayan dönüşümler yaparak çok boyutlu uzayda sınıfların doğrusal olarak ayrımına imkan sağlamaktadır. Kernel fonksiyonları ile doğrusal ayrılamayan sınıflarda problemin çözümü için karar fonksiyonları tanımlanır. Sınıflandırma işlemlerinde kernel fonksiyonlarının belirlenmesi ve bu fonksiyona ait optimum parametrelerin bulunması gerekmektedir. Kerneller arasında radyal tabanlı kernel fonksiyonu (rbf) ve lineer kernel fonksiyonu sıklıkla kullanılmaktadır. Bu iki kernel tez çalışmasında kullanılmış ve performans analizleri yapılmıştır (Cortes ve Vapnik, 1995).

5.8. Performans Değerlendirme Kriterleri

Özellik derecelendirme tabanlı DVM-lineer ve DVM-rbf sınıflandırıcı performans değerlendirme kriterleri özgüllük (*specificity*), hassasiyet (*sensitivity*), sınıflandırma doğruluğu (*accuracy*) ve eğri altında kalan alan (*Area Under Curve-AUC*)

ile hesaplanmıştır. Bu değerlerin hesaplanması için sınıflandırıcı çıkışlarına göre Çizelge 5.6'da gösterilen karmaşıklık matrisi (*confusion matrix*) oluşturulmuştur. Bu matris sınıflandırıcı modelin ürettiği değerler ile gerçek değerleri gösteren bir matristir.

Çizelge 5.6. Performans kriterleri için karmaşıklık matrisi

Gerçek Sınıf/Tahmin Edilen	***Negatif***	***Pozitif***
Negatif	*Doğru Negatif(DN)*	*Yanlış Pozitif(YP)*
Pozitif	*Yanlış Negatif (YN)*	*Doğru Pozitif(DP)*

Doğru Pozitif (DP) veri tabanı tarafından NK etiketlenen ve sistem tarafından NK olarak belirlenenlerin sayısı, Doğru Negatif (DN) veri tabanı tarafından AH etiketlenip sistem tarafından AH belirlenenlerin sayısı, Yanlış Pozitif (YP) veri tabanı tarafından AH olarak etiketlenip sistem tarafından NK etiketlenenlerin sayısı, Yanlış Negatif (YN) veri tabanı tarafından NK etiketlenip sistem tarafından AH olarak belirlenenlerin sayısıdır. Bu verilerden yola çıkarak Hassasiyet (HA), Özgüllük (ÖZ), Doğruluk (DO) sırasıyla Eşitlik 5.75, Eşitlik 5.76 ve Eşitlik 5.77 ile hesaplanır. AUC değerlendirme kriteri DP'lerin Y ekseninde, YP'lerin de X ekseninde çizildiği ve ikisi arasındaki ilişkiyi tanımlayan Alıcı İşlem Karakteristiği (*Receiver Operating Curve*) iki boyutlu eğrinin altında kalan alanı tanımlamaktadır. Bu değerin büyük olması sınıflandırıcı performansının iyi olduğunu göstermektedir.

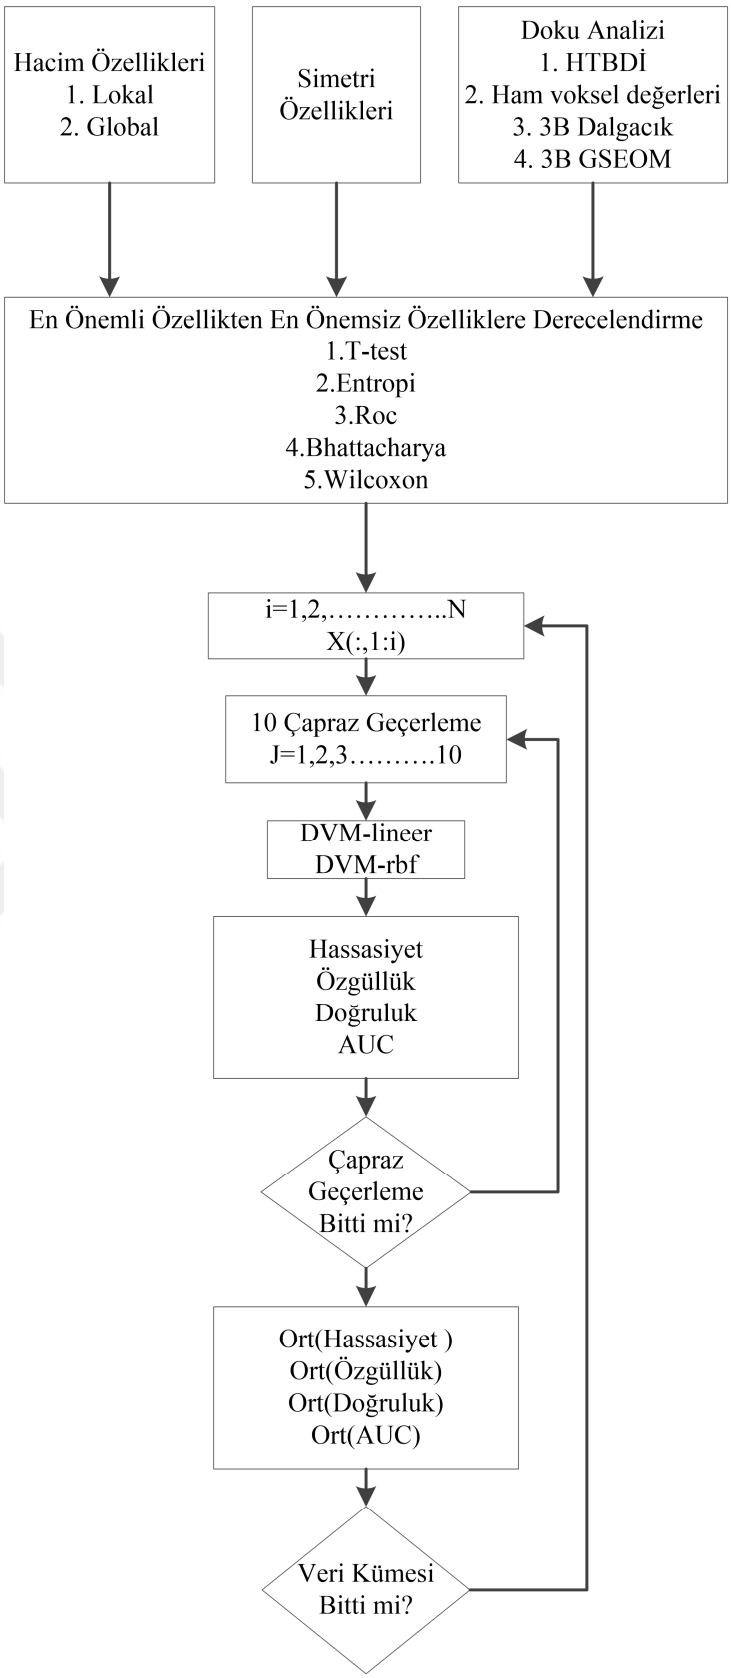
$$HA(\%) = \frac{DP}{(DP + YN)}.100 \tag{5.75}$$

$$\ddot{O}Z(\%) = \frac{DN}{(DN + YP)}.100 \tag{5.76}$$

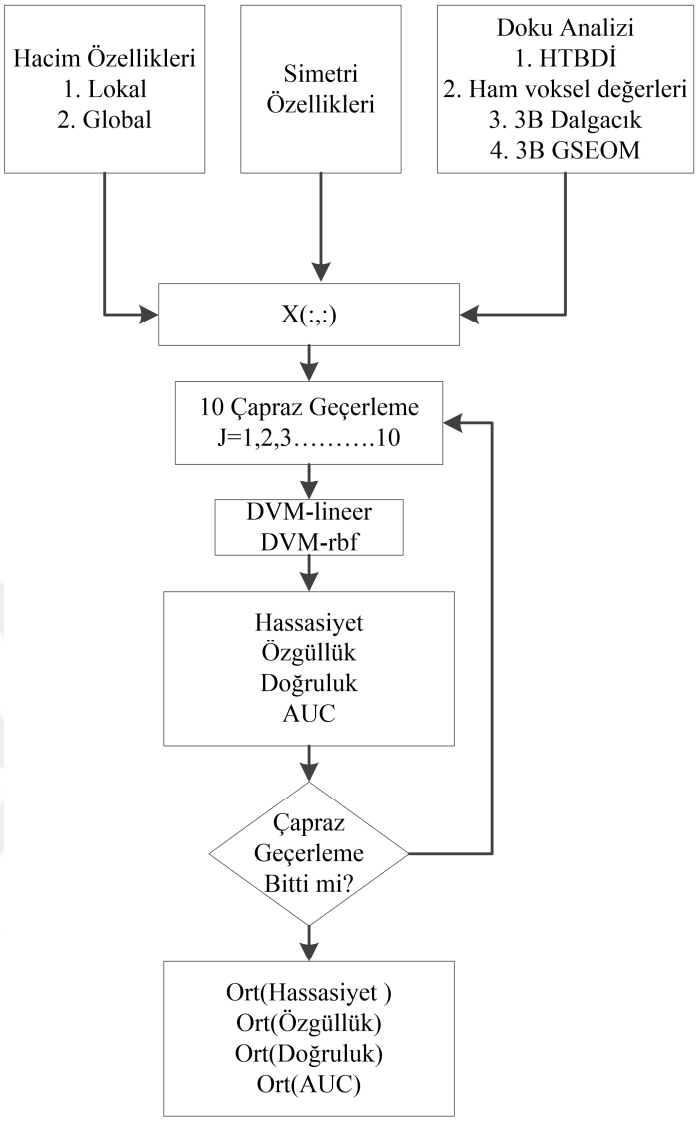
$$DO(\%) = \frac{DP + DN}{DP + DN + YP + YN} \tag{5.77}$$

5.9. Sınıflandırma Mimarisi

Tez çalışmasında özellik seçme tabanlı sınıflandırma ve özellik seçme kullanmadan sınıflandırma olmak üzere iki farklı sınıflandırma mimarisi uygulanmıştır. Sınıflandırma için DVM tabanlı lineer ve rbf kernelleri kullanılmıştır. Özellik seçme tabanlı sınıflandırma mimarisinde voksel özellik kümesi haricinde hacim, simetri ve doku özellikleri elde edildikten sonra 0-1 arasına normalize edilmiş, akabinde veriler beş farklı özellik derecelendirme kriterine göre en iyi özellikten en kötü özelliğe doğru sıralandırılmıştır. Voksel değerleri özellik kümesi ise ham intensite değerlerini verdiği için normalizasyon işlemine tabi tutulmamıştır. Daha sonra en iyi birinci özellikten başlayarak sırasıyla veriler birleştirilmiş ve 10 kat çapraz geçerleme ile sınıflandırıcıya verilmiştir. 10 kat çapraz geçerleme sonunda sınıflandırıcı performans kriterlerinin ortalaması alınarak her bir veri birleşimi için ortalama performans değerleri bir matriste tutulmuştur. Tüm işlemler bittikten sonra en yüksek sınıflandırma doğruluğunu veren küme ve hangi sınıflandırma mimarisinin en iyi sonucu verdiği ortaya konulmuştur. Şekil 5.32'de X veri kümesi, N veri kümesindeki özellik sayısı olmak üzere özellik seçme tabanlı sınıflandırma ve performans analizi akış diyagramı olarak gösterilmektedir. Diğer sınıflandırma mimarisinde özellik derecelendirme işlemi çıkarılmış diğer tüm basamaklar aynı şekilde yapılmıştır. Şekil 5.33'te X veri kümesi olmak üzere özellik derecelendirme yapılmadan gerçeklenen sınıflandırma modeli gösterilmektedir.



Şekil 5.32. Tüm verilerin özellik seçme tabanlı sınıflandırma modeli (Sınıflandırma mimarisine tüm özellikler aynı anda verilmemekte olup her bir özellik kümesi ayrı ayrı verilmiştir.)



Şekil 5.33. Özellik seçme olmadan kullanılan sınıflandırma modeli (Sınıflandırma mimarisine tüm özellikler aynı anda verilmemekte olup her bir özellik kümesi ayrı ayrı verilmiştir.)

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

6.1. Global Beyin Özellikleri Sınıflandırma Sonuçları

AH'de beyinde meydana gelen global hacimsel değişimler 3B MR görüntülerinde ilk göze çarpan özelliklerdir. Özellikle hacimsel dejenerasyondan kaynaklı GM azalması ve bu bölgelerin yerini BOS'un alması beyindeki oransal miktarları değiştirmektedir. GM, BM, BOS, LV, PRNKM, TBH gibi beyindeki temel bölgelerin Şekil 5.3'te tanımlanan model kullanılarak mililitre*(ml)* cinsinden hacim değerleri bulunmuştur. Bu işlemden sonra bu özelliklerin oransal kombinasyonları kullanılarak 26 adet özellik elde edilmiştir. Çizelge 6.1'de global özelliklerden elde edilen kombinasyonların ortalama, standart sapma ve bağımsız örneklem t-testi sonucu p önemlilik değerleri verilmiştir.

Çizelge 6.1. Global özelliklerin kombinasyonu sonucu elde edilen özelliklerin ortalama, standart sapma ve bağımsız örneklem t testi sonuçları

	AH		**NK**		**İstat.**
	Ort.	SS	Ort.	SS	p
BOS/GM	0.598	0.085	0.530	0.072	1E-06
GM/TBH	0.414	0.022	0.430	0.016	2E-06
(BM+BOS)/TBH	0.586	0.022	0.570	0.016	2E-06
(LV+BOS)/TBH	0.280	0.034	0.253	0.033	7E-06
BOS/TBH	0.246	0.025	0.227	0.024	9E-06
PRNKM/TBH	0.754	0.025	0.773	0.024	9E-06
BOS/PRNKM	0.328	0.044	0.295	0.041	1E-05
BOS	336.966	47.974	305.270	40.490	4E-05
LV/GM	0.082	0.032	0.063	0.027	2E-04
BM/BOS	1.400	0.190	1.538	0.231	2E-04
LV/PRNKM	0.045	0.017	0.035	0.015	4E-04
LV/TBH	0.034	0.012	0.027	0.011	6E-04
LV	46.441	19.770	36.012	15.581	7E-04
LV/BM	0.099	0.038	0.078	0.034	9E-04
(GM+LV)/TBH	0.447	0.019	0.456	0.013	0.002
LV/BOS	0.135	0.044	0.115	0.041	0.007
BM/GM	0.824	0.064	0.801	0.051	0.015
GM/PRNKM	0.549	0.019	0.556	0.016	0.018
BM/PRNKM	0.451	0.019	0.444	0.016	0.018
GM	565.925	55.934	577.990	47.354	0.171
(BM+LV)/TBH	0.374	0.018	0.370	0.017	0.235
(GM+BOS)/TBH	0.660	0.017	0.656	0.018	0.255
BM/TBH	0.340	0.017	0.344	0.018	0.255
TBH	1369.067	132.915	1346.483	116.049	0.286
PRNKM	1032.102	104.683	1041.213	96.572	0.593
BM	466.177	55.727	463.223	53.189	0.749

Çizelge 6.1'de görüldüğü gibi AH'de en anlamlı değişen oran BOS/GM iken en anlamsız değişken BM olmuştur. GM kaybından kaynaklı BOS artışı miktarlarının birbirine karşı oranlarının istatistiksel olarak anlamlı çıkması son derece makuldur. Çünkü en göze çarpan ve en dinamik değişikliklerin yaşandığı bölgeler bu kısımlardır. GM azalırken BOS miktarı artmaktadır. Hacimsel değişiklik yaşanan bölgelerin ve kombinasyonlarının TBH'a oranları büyük oranda anlamlı çıkmıştır. Çünkü beyinde hacimsel kayıplar yaşansa da TBH miktarı değişmemektedir. Dolayısıyla AH'de istatistiksel bir anlam oluşturmamaktadır. Ancak TBH'a göre küçük hacimsel değişiklikler istatistiksel olarak anlamlı çıkmaktadır. BM bölgesinde hacimsel kayıplardan literatürde değişimin küçük olduğundan bahsedilse de ne tek başına kendisi ne de TBH oranı anlamlı çıkmıştır. GM değişimleri beyinde dinamik değişiklikler oluştursa da tek başına istatistiksel anlamlılık oluşturmamış, ancak TBH oranı istatistiksel olarak anlamlı çıkmıştır. PRNKM dokusu GM ve BM toplamı olduğu için değişiklik tek başına anlamlı olmamış, ancak TBH oranı anlamlı çıkmıştır. BOS miktarı hem tek başına hem de TBH oranı anlamlı çıkmaktadır. AH'de diğer bir dinamik değişiklik LV'de olduğundan dolayı BM kombinasyonu hariç, kendisi ve diğer kombinasyonları anlamlı sonuçlar vermektedir. Global hacimler ile elde edilen 140*26 matris büyüklüklü kümenin her özelliği kendi içerisinde 0-1 arasına normalize edildikten sonra özellik derecelendirme ile elde edilen sınıflandırma sonuçları Çizelge 6.2'de verilmiştir.

Çizelge 6.2. Global beyin hacim değerlerinin sınıflandırma sonuçları

		Hassasiyet	Özgüllük	Doğruluk	AUC	Özellik Sayısı
DVM-lineer	Bhattacharya	75.7143	64.2857	70.0000	0.7000	3
	Entropi	75.7143	64.2857	70.0000	0.7000	3
	Roc	72.8571	68.5714	70.7143	0.7071	1
	T-test	72.8571	68.5714	70.7143	0.7071	1
	Wilcoxon	82.8571	58.5714	70.7143	0.7071	21
	DVM-lineer	72.8571	61.4286	67.1429	0.6714	26

		Hassasiyet	Özgüllük	Doğruluk	AUC	Özellik Sayısı
DVM-rbf	Bhattacharya	81.4286	54.2857	67.8571	0.6786	2
	Entropi	81.4286	54.2857	67.8571	0.6786	2
	Roc	72.8571	68.5714	70.7143	0.7071	13
	T-test	74.2857	65.7143	70.0000	0.7000	1
	Wilcoxon	85.7143	48.5714	67.1429	0.6714	1
	DVM-rbf	54.2857	67.1429	60.7143	0.6071	26

Çizelge 6.2'de görüldüğü gibi en yüksek doğruluk oranları Roc_DVM-lineer, T- test_

DVM-lineer, Roc_DVM-rbf yöntemlerinde %70.7143 doğruluk oranları ile bulunmuştur. Özellik derecelendirme kullanımı genel olarak doğruluk oranlarını arttırmaktadır. Roc_DVM-rbf yöntemi 13 özellik ile en yüksek doğruluğu verirken diğer yöntemler tek bir özellik ile aynı sonucu vermişlerdir. Bir özellik ile en yüksek sınıflandırma sonucu veren özellik BOS/GM oranıdır. Sınıflandırma için BOS/GM özelliği beklendiği gibi en anlamlı özellik olarak her iki yöntemde de elde edilmektedir. Her ne kadar MR görüntülerinde dinamik değişiklikler manuel bir şekilde net olarak izlenebilse de AH'nin sınıflandırılabilmesi için özellikler veri tabanı için çok iyi bir performans göstermemektedir. Sınıflandırma doğruluk oranları %60.71 ile %70.71 arasında değişmektedir. Özellik derecelendirme işlemi genel olarak doğruluk oranlarını arttırmaktadır. Aynı zamanda kullanılan özellik sayısını azaltmıştır. DVM-lineer sınıflandırıcı DVM-rbf sınıflandırıcıya göre daha yüksek sonuçlar vermiştir. T-test ve roc özellik seçme tabanlı DVM-lineer sınıflandırıcı ile en optimum sonuçlar BOS/GM özelliği ile elde edilmektedir. Bu özellik global değerler içerisinde en anlamlı değişken olarak bulunmuştur. Bir sonraki aşamada hacimsel özellikler ile veri tabanı içerisinde sınıflandırma doğruluk oranlarını arttırabilmek için beyin içerisinde bulunan subkortikal bölgelerin hacimsel özellikleri çıkarılarak hastalığı daha hassas ayırt edebilen lokal hacimsel bölgeler ile veri kümeleri oluşturulmuştur.

6.2. Lokal Hacimler Sınıflandırma Sonuçları

Lokal hacimler AAL ve TD lob atlasları kullanarak Şekil 5.5'te gösterilen model ile hacimsel olarak *ml* cinsinden oluşturulmuştur. AAL ile 116 alt bölge hacmi, TD lob ile 11 lob bölgesi elde edilmiştir. Her insandaki beyin hacmi büyüklüğü farklı olduğu için bu bölgeler arasında yapılacak karşılaştırmalar göreceli olacaktır. Ancak bu lokal hacimleri TBH, GM veya PRNKM gibi global hacimlere bölmek sağlıklı insanlarda oransal olarak yakın çıkacaktır. Dolayısıyla insanlarda beyin büyüklüklerinin farklı olmasından kaynaklı normalizasyon işleminin yapılma zorunluluğu ortaya çıkmıştır. Ancak literatürde hangi beyin oranının kullanılacağı net bir şekilde ortaya konulmamıştır. Bundan dolayı tez çalışmasında ham veriler ve ham verilerin GM, PRNKM ve TBH değerlerine normalizasyonu ayrı ayrı incelenmiştir. Ham verilerin ve belirtilen bölge oranlarının bağımsız örneklem t-testi ile ortaya çıkan istatistiksel anlamlılık p değerleri, ortalama ve standart sapma değerleri Ek5'te verilmiştir. Bağımsız örneklem t- testi sonucunda anlamlı olarak görülen beyin bölgeleri literatür ile

uyumludur. Sınıflandırma işlemi AAL ve AAL+TD lob olarak ayrı ayrı yapılmıştır. Bu işlemin amacı lob değerlerinin daha lokal hacimlerle beraber değerlendirilmesinde sınıflandırma performansının artıp artmadığının incelenmesidir. Dolayısıyla dört adet 140*116 ve dört adet 140*127 özellik matrisi olmak üzere sekiz farklı hacimsel özellik senaryosu türetilmiştir. Her bir özellik kendi içerisinde 0-1 arasına normalize edilmiştir. Özellik seçme tabanlı sekiz farklı senaryonun DVM-lineer sınıflandırma sonuçları Çizelge 6.3'te, DVM-rbf tabanlı sınıflandırma sonuçları Çizelge 6.4'te verilmiştir.

Çizelge 6.3. Lokal hacimlerin sekiz farklı senaryo için DVM-lineer tabanlı sınıflandırma sonuçları

DVM_Lineer							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-Lineer
AAL	Hassasiyet	91.429	94.286	94.286	92.857	91.429	88.571
	Özgüllük	90.000	85.714	87.143	90.000	95.714	85.714
	Doğruluk	90.714	90.000	90.714	91.429	93.571	87.143
	AUC	0.907	0.900	0.907	0.914	0.936	0.871
	ÖzellikSayısı	85	108	47	47	83	116
AAL/GM	Hassasiyet	92.857	94.286	92.857	95.714	95.714	84.286
	Özgüllük	90.000	91.429	88.571	92.857	91.429	84.286
	Doğruluk	91.429	92.857	90.714	94.286	93.571	84.286
	AUC	0.914	0.929	0.907	0.943	0.936	0.843
	ÖzellikSayısı	89	75	91	85	85	116
AAL/PRNKM	Hassasiyet	94.286	95.714	87.143	94.286	91.429	88.571
	Özgüllük	90.000	90.000	95.714	91.429	92.857	87.143
	Doğruluk	92.143	92.857	91.429	92.857	92.143	87.857
	AUC	0.921	0.929	0.914	0.929	0.921	0.879
	ÖzellikSayısı	100	109	35	100	34	116
AAL/TBH	Hassasiyet	94.286	94.286	95.714	94.286	92.857	90.000
	Özgüllük	91.429	91.429	94.286	94.286	92.857	87.143
	Doğruluk	92.857	92.857	95.000	94.286	92.857	88.571
	AUC	0.929	0.929	0.950	0.943	0.929	0.886
	ÖzellikSayısı	93	114	107	110	108	116
Lob+AAL	Hassasiyet	92.857	92.857	90.000	92.857	94.286	87.143
	Özgüllük	87.143	91.429	92.857	94.286	91.429	85.714
	Doğruluk	90.000	92.143	91.429	93.571	92.857	86.429
	AUC	0.900	0.921	0.914	0.936	0.929	0.864
	ÖzellikSayısı	97	121	53	83	99	127
(Lob+AAL)/GM	Hassasiyet	91.429	92.857	91.429	91.429	91.429	82.857
	Özgüllük	94.286	92.857	91.429	94.286	92.857	84.286
	Doğruluk	92.857	92.857	91.429	92.857	92.143	83.571
	AUC	0.929	0.929	0.914	0.929	0.921	0.836
	ÖzellikSayısı	93	88	100	93	100	127
(Lob+AAL) /PRNKM	Hassasiyet	91.429	91.429	92.857	92.857	92.857	88.571
	Özgüllük	92.857	92.857	91.429	94.286	94.286	87.143
	Doğruluk	92.143	92.143	92.143	93.571	93.571	87.857
	AUC	0.921	0.921	0.921	0.936	0.936	0.879
	ÖzellikSayısı	93	93	53	62	100	127
(Lob+AAL)/TBH	Hassasiyet	92.857	92.857	94.286	95.714	92.857	91.429
	Özgüllük	92.857	92.857	95.714	91.429	92.857	87.143
	Doğruluk	92.857	92.857	95.000	93.571	92.857	89.286
	AUC	0.929	0.929	0.950	0.936	0.929	0.893
	ÖzellikSayısı	126	126	110	107	95	127

Çizelge 6.4. Lokal hacimlerin sekiz farklı senaryo için DVM-rbf tabanlı sınıflandırma sonuçları

DVM-rbf							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-rbf
AAL	Hassasiyet	74.286	71.429	71.429	71.429	80.000	18.571
	Özgüllük	82.857	87.143	87.143	87.143	91.429	80.000
	Doğruluk	78.571	79.286	79.286	79.286	85.714	49.286
	AUC	0.786	0.793	0.793	0.793	0.857	0.493
	ÖzellikSayısı	11	6	6	6	7	116
AAL/GM	Hassasiyet	84.286	80.000	80.000	87.143	85.714	88.571
	Özgüllük	85.714	85.714	94.286	87.143	92.857	18.571
	Doğruluk	85.000	82.857	87.143	87.143	89.286	53.571
	AUC	0.850	0.829	0.871	0.871	0.893	0.536
	ÖzellikSayısı	6	9	11	5	9	116
AAL/PRNKM	Hassasiyet	87.143	87.143	72.857	87.143	84.286	80.000
	Özgüllük	78.571	78.571	94.286	78.571	92.857	20.000
	Doğruluk	82.857	82.857	83.571	82.857	88.571	50.000
	AUC	0.829	0.829	0.836	0.829	0.886	0.500
	ÖzellikSayısı	2	2	11	2	8	116
AAL/TBH	Hassasiyet	82.857	72.857	81.429	81.429	87.143	50.000
	Özgüllük	77.143	87.143	80.000	80.000	90.000	55.714
	Doğruluk	80.000	80.000	80.714	80.714	88.571	52.857
	AUC	0.800	0.800	0.807	0.807	0.886	0.529
	ÖzellikSayısı	4	11	6	6	4	116
Lob+AAL	Hassasiyet	74.286	71.429	71.429	71.429	80.000	20.000
	Özgüllük	82.857	87.143	87.143	87.143	91.429	80.000
	Doğruluk	78.571	79.286	79.286	79.286	85.714	50.000
	AUC	0.786	0.793	0.793	0.793	0.857	0.500
	ÖzellikSayısı	11.000	6.000	6.000	6.000	7.000	127.000
(Lob+AAL)/GM	Hassasiyet	82.857	78.571	80.000	88.571	87.143	70.000
	Özgüllük	85.714	87.143	88.571	85.714	87.143	37.143
	Doğruluk	84.286	82.857	84.286	87.143	87.143	53.571
	AUC	0.843	0.829	0.843	0.871	0.871	0.536
	ÖzellikSayısı	8	11	9	6	5	127
(Lob+AAL) /PRNKM	Hassasiyet	87.143	87.143	87.143	87.143	84.286	90.000
	Özgüllük	78.571	78.571	78.571	78.571	92.857	10.000
	Doğruluk	82.857	82.857	82.857	82.857	88.571	50.000
	AUC	0.829	0.829	0.829	0.829	0.886	0.500
	ÖzellikSayısı	2	2	2	2	8	127
(Lob+AAL)/TBH	Hassasiyet	78.571	78.571	82.857	82.857	87.143	68.571
	Özgüllük	87.143	87.143	81.429	81.429	90.000	35.714
	Doğruluk	82.857	82.857	82.143	82.143	88.571	52.143
	AUC	0.829	0.829	0.821	0.821	0.886	0.521
	ÖzellikSayısı	11	11	8	8	4	127

En yüksek sınıflandırma sonuçları %95.000 doğruluk oranı AAL/TBH özellik kümesinin Roc_DVM-lineer ve (Lob+AAL)/TBH özellik kümesinin Roc_DVM-lineer özellik derecelendirme tabanlı sınıflandırma modeli ile bulunmuştur. AAL/TBH 107 özellik ile en yüksek doğruluğu verirken, (Lob+AAL)/TBH 110 özellik ile vermiştir. Genel olarak özellik derecelendirme doğruluk oranlarının artışında etkili rol oynamıştır. DVM-lineer tabanlı modeller DVM-rbf tabanlı sınıflandırma modellerine göre daha yüksek sonuçlar vermiştir. Özellik derecelendirme tabanlı DVM-lineer sınıflandırıcı kullanılarak yapılan sınıflandırmalar %90 üzeri bir doğruluk sonucu vermiştir. Lob bölge hacimlerinin AAL ile birleştirilmesinden elde edilen örüntünün sınıflandırma doğruluğuna etkin bir katkısı olmamıştır. Bu sonuçlarda lokal hacim özelliklerinin veri tabanında hastalığın ayırıcı tanısında daha iyi bir sonuç verdiğini göstermektedir. Veri tabanında global hacim değerleri doğruluk sınıflandırma sonuçlarına göre değerlendirildiği zaman, global hacimler yerine lokal hacimler ile değerlendirmenin ayırıcı tanıda daha hassas sonuçlar verdiği görülmektedir. Lokal bölgelerin GM, PRNKM ve TBH bölge hacimlerine oranları arasında TBH oranı daha yüksek sonuç vermektedir. Lokal bölgelerde hacim azalması ile beraber GM ve PRNKM hacimleri de düşmektedir. Bundan dolayı bu bölgelere hacimsel olarak değişmeyen TBH hacminin lokal bölgelere oranlanması daha anlamlıdır. Bu yaklaşım ile TBH oranı GM ve PRNKM oranına göre daha yüksek sonuçlar vermektedir.

6.3. Simetri Sınıflandırma Sonuçları

Üç boyutlu beyin MR görüntülerinde simetri özellikleri PSNR ve SSIM için Şekil 5.8'deki model ile diğer istatistiksel özellikler ise Şekil 5.9'daki model ile elde edilmiştir. MNS GM, BM ve NS GM, BM görüntüler ile ilgili özellikler çıkarılmış, her bir veri için 11*140 matris boyutlu özellik kümesi oluşturulmuştur. Sınıflandırma işlemine geçmeden önce her bir özellik kendi içinde 0-1 arasına normalize edilmiştir. Simetri özelliklerinin DVM-lineer tabanlı sınıflandırıcı sonuçları Çizelge 6.5'te ve DVM-rbf tabanlı sınıflandırıcı sonuçları Çizelge 6.6'da verilmektedir. Dört farklı veri kümesindeki 11 özellik, özellik derecelendirme ile en iyi değerden en kötü değere doğru sıralanmıştır. Yapılan sınıflandırma sonucunda MNS GM özelliklerin bhattacharya ve entropi özellik derecelendirme tabanlı DVM-lineer sınıflandırıcı ile %100 sınıflandırma başarısı göstermektedir. Her iki özellik derecelendirme modelleri 9 özellik ile en iyi sonucu vermektedir. DVM-lineer sınıflandırıcı DVM-rbf sınıflandırıcıya göre daha

yüksek doğruluk oranları göstermektedir. Özellik derecelendirme tabanlı sınıflandırıcılar özellik derecelendirme kullanmadan yapılan sınıflandırmalara göre daha yüksek sonuçlar vermektedir. GM görüntülerdeki simetri özellikleri BM görüntüdeki simetri özelliklere göre her iki sınıflandırıcı modelinde de daha yüksek sonuçlar vermiştir. Bu sonuçlara göre hacmi korunmuş modülasyonlu GM görüntülerdeki veri tabanı simetri özelliklerinin AH'nin ayrıcı tanısında önemli bir rol oynadığı görülmektedir. BM verilerde ise en yüksek doğruluk oranı, NS BM' de %65.00 ile roc özellik derecelendirme tabanlı DVM-rbf sınıflandırıcıda 5 özellik kullanılarak bulunmaktadır. Özellik derecelendirmenin kullanılması BM verilerde de doğruluk oranlarını arttırmaktadır.

Çizelge 6.5. Simetri özelliklerinin DVM-lineer tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

SINIFLANDIRICI		DVM-Lineer					
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-Liner
MNS GM	Hassasiyet	100.000	100.000	100.000	100.000	100.000	100.000
	Özgüllük	100.000	100.000	98.571	98.571	98.571	98.571
	Doğruluk	100.000	100.000	99.285	99.286	99.285	99.286
	AUC	1.000	1.000	0.993	0.993	0.993	0.993
	ÖzellikSayısı	9	9	5	6	5	11
NS GM	Hassasiyet	75.714	75.714	77.143	77.143	77.143	67.143
	Özgüllük	61.429	61.429	65.714	65.714	65.714	58.571
	Doğruluk	68.571	68.571	71.429	71.429	71.429	62.857
	AUC	0.686	0.686	0.714	0.714	0.714	0.629
	ÖzellikSayısı	2	2	4	4	4	11
MNS BM	Hassasiyet	72.857	72.857	72.857	75.714	71.429	65.714
	Özgüllük	54.286	54.286	51.429	48.571	55.714	55.714
	Doğruluk	63.571	63.571	62.143	62.143	63.571	60.714
	AUC	0.636	0.636	0.621	0.621	0.636	0.607
	ÖzellikSayısı	2	2	4	3	7	11
NS BM	Hassasiyet	74.286	77.143	72.857	74.286	68.571	64.286
	Özgüllük	44.286	42.857	51.429	47.143	51.429	44.286
	Doğruluk	59.286	60.000	62.143	60.714	60.000	54.286
	AUC	0.593	0.600	0.621	0.607	0.600	0.543
	ÖzellikSayısı	6	6	4	10	10	11

Çizelge 6.6. Simetri özelliklerinin DVM-rbf tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MBM: Modülasyonlu Normalize Segmente BM, NBM: Normalize Segmente BM)

SINIFLANDIRICI		DVM-rbf					
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-rbf
MNS GM	Hassasiyet	95.714	97.143	97.143	95.714	97.143	91.429
	Özgüllük	98.571	98.571	98.571	100.000	98.571	97.143
	Doğruluk	97.143	97.857	97.857	97.857	97.857	94.286
	AUC	0.971	0.979	0.979	0.979	0.979	0.943
	ÖzellikSayısı	8	6	8	9	8	11
NS GM	Hassasiyet	81.429	81.429	75.714	81.429	75.714	60.000
	Özgüllük	67.143	67.143	71.429	67.143	71.429	71.429
	Doğruluk	74.286	74.286	73.571	74.286	73.571	65.714
	AUC	0.743	0.743	0.736	0.743	0.736	0.657
	ÖzellikSayısı	2	2	5	2	5	11
MNS BM	Hassasiyet	64.286	64.286	64.286	64.286	64.286	47.143
	Özgüllük	54.286	54.286	54.286	54.286	54.286	45.714
	Doğruluk	59.286	59.286	59.286	59.286	59.286	46.429
	AUC	0.593	0.593	0.593	0.593	0.593	0.464
	ÖzellikSayısı	1	1	3	3	3	11
NS BM	Hassasiyet	74.286	74.286	74.286	74.286	70.000	61.429
	Özgüllük	54.286	54.286	55.714	54.286	54.286	57.143
	Doğruluk	64.286	64.286	65.000	64.286	62.143	59.286
	AUC	0.643	0.643	0.650	0.643	0.621	0.593
	ÖzellikSayısı	6	6	5	6	5	11

6.4. HTBDİ Sınıflandırma Sonuçları

HTBDİ yöntemi için Şekil 5.20'deki model kullanılarak dokusal özellikler elde edilmiştir. VTM ile elde edilen sekiz farklı maske ile elde edilen bölgeler için sekiz farklı 140*6 matris boyutlu özellik matrisleri oluşturulmuştur. Veriler sınıflandırma işleminden önce 0-1 arasına normalize edilmiştir. Oluşturulan veri kümelerinin özellik seçme tabanlı sınıflandırma sonuçları DVM-lineer için Çizelge 6.7'de, DVM-rbf için Çizelge 6.8'de verilmiştir.

Çizelge 6.7. HTBDİ için DVM-lineer tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-Lineer							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-Lineer
MNS GM	Hassasiyet	80.000	80.000	74.286	74.286	80.000	80.000
	Özgüllük	78.571	78.571	84.286	84.286	77.143	78.571
	Doğruluk	79.286	79.286	79.286	79.286	78.571	79.286
	AUC	0.793	0.793	0.793	0.793	0.786	0.793
	ÖzellikSayısı	5	5	1	1	4	6
MNS GM_200	Hassasiyet	80.000	80.000	78.571	78.571	77.143	80.000
	Özgüllük	78.571	78.571	81.429	81.429	81.429	77.143
	Doğruluk	79.286	79.286	80.000	80.000	79.286	78.571
	AUC	0.793	0.793	0.800	0.800	0.793	0.786
	ÖzellikSayısı	6	6	1	1	1	6
NS GM	Hassasiyet	77.143	77.143	77.143	77.143	77.143	80.000
	Özgüllük	85.714	85.714	85.714	85.714	85.714	82.857
	Doğruluk	81.429	81.429	81.429	81.429	81.429	81.429
	AUC	0.814	0.814	0.814	0.814	0.814	0.814
	ÖzellikSayısı	3	3	3	3	3	6
NS GM_200	Hassasiyet	78.571	78.571	78.571	78.571	78.571	80.000
	Özgüllük	81.429	81.429	81.429	81.429	81.429	81.429
	Doğruluk	80.000	80.000	80.000	80.000	80.000	80.714
	AUC	0.800	0.800	0.800	0.800	0.800	0.807
	ÖzellikSayısı	5	5	5	5	5	6
MNS BM	Hassasiyet	71.429	71.429	71.429	71.429	71.429	71.429
	Özgüllük	78.571	78.571	78.571	78.571	78.571	78.571
	Doğruluk	75.000	75.000	75.000	75.000	75.000	75.000
	AUC	0.750	0.750	0.750	0.750	0.750	0.750
	ÖzellikSayısı	6	6	6	6	6	6
MNS BM_200	Hassasiyet	72.857	72.857	72.857	72.857	68.571	68.571
	Özgüllük	75.714	75.714	75.714	75.714	78.571	78.571
	Doğruluk	74.286	74.286	74.286	74.286	73.571	73.571
	AUC	0.743	0.743	0.743	0.743	0.736	0.736
	ÖzellikSayısı	1	1	1	1	6	6
NS BM	Hassasiyet	74.286	77.143	74.286	74.286	74.286	74.286
	Özgüllük	74.286	74.286	74.286	74.286	74.286	74.286
	Doğruluk	74.286	75.714	74.286	74.286	74.286	74.286
	AUC	0.743	0.757	0.743	0.743	0.743	0.743
	ÖzellikSayısı	6	3	6	6	6	6
NS BM_200	Hassasiyet	74.286	74.286	74.286	74.286	74.286	74.286
	Özgüllük	74.286	74.286	74.286	74.286	74.286	74.286
	Doğruluk	74.286	74.286	74.286	74.286	74.286	74.286
	AUC	0.743	0.743	0.743	0.743	0.743	0.743
	ÖzellikSayısı	6	3	6	6	6	6

Çizelge 6.8. HTBDİ için DVM-rbf tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-rbf							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-rbf
MNS GM	Hassasiyet	77.143	77.143	77.143	77.143	77.143	74.286
	Özgüllük	81.429	81.429	81.429	81.429	81.429	77.143
	Doğruluk	79.286	79.286	79.286	79.286	79.286	75.714
	AUC	0.793	0.793	0.793	0.793	0.793	0.757
	ÖzellikSayısı	3	3	3	3	3	6
MNS GM_200	Hassasiyet	77.143	77.143	77.143	77.143	77.143	72.857
	Özgüllük	81.429	81.429	81.429	81.429	81.429	77.143
	Doğruluk	79.286	79.286	79.286	79.286	79.286	75.000
	AUC	0.793	0.793	0.793	0.793	0.793	0.750
	ÖzellikSayısı	3	3	3	2	3	6
NS GM	Hassasiyet	72.857	72.857	72.857	72.857	74.286	71.429
	Özgüllük	85.714	85.714	85.714	85.714	85.714	87.143
	Doğruluk	79.286	79.286	79.286	79.286	80.000	79.286
	AUC	0.793	0.793	0.793	0.793	0.800	0.793
	ÖzellikSayısı	4	4	4	4	4	6
NS GM_200	Hassasiyet	80.000	80.000	74.286	74.286	74.286	75.714
	Özgüllük	78.571	78.571	87.143	87.143	87.143	87.143
	Doğruluk	79.286	79.286	80.714	80.714	80.714	81.429
	AUC	0.793	0.793	0.807	0.807	0.807	0.814
	ÖzellikSayısı	4	4	3	3	3	6
MNS BM	Hassasiyet	70.000	70.000	70.000	70.000	70.000	61.429
	Özgüllük	78.571	78.571	78.571	78.571	78.571	84.286
	Doğruluk	74.286	74.286	74.286	74.286	74.286	72.857
	AUC	0.743	0.743	0.743	0.743	0.743	0.729
	ÖzellikSayısı	2	2	2	2	1	6
MNS BM_200	Hassasiyet	67.143	67.143	67.143	67.143	70.000	62.857
	Özgüllük	78.571	78.571	78.571	78.571	78.571	78.571
	Doğruluk	72.857	72.857	72.857	72.857	74.286	70.714
	AUC	0.729	0.729	0.729	0.729	0.743	0.707
	ÖzellikSayısı	1	1	1	1	1	6
NS BM	Hassasiyet	72.857	72.857	70.000	70.000	70.000	68.571
	Özgüllük	74.286	74.286	77.143	77.143	77.143	74.286
	Doğruluk	73.571	73.571	73.571	73.571	73.571	71.429
	AUC	0.736	0.736	0.736	0.736	0.736	0.714
	ÖzellikSayısı	1	1	1	1	1	6
NS BM_200	Hassasiyet	72.857	72.857	71.429	71.429	71.429	68.571
	Özgüllük	74.286	74.286	77.143	77.143	77.143	74.286
	Doğruluk	73.571	73.571	74.286	74.286	74.286	71.429
	AUC	0.736	0.736	0.743	0.743	0.743	0.714
	ÖzellikSayısı	1	1	2	2	2	6

MNS GM_200 özelliklerde %80 en yüksek doğruluk DVM-lineer tabanlı roc ve t-test derecelendirmelerde elde edilmiş, ancak DVM-rbf tabanlı sınıflandırma modelleri ile arasında çok fazla bir fark görülmemektedir. MNS GM görüntü özelliklerinde en yüksek doğruluk hem DVM-lineer hem de DVM-rbf özellik derecelendirme tabanlı sınıflandırıcılarda %79.286 olarak bulunmuş ve birçok sınıflandırma modeli bu oran üzerinden sonuç üretmiştir. 200 voksel kümesi üzeri anlamlı kabul edilen veriler ile %0.7 civarında bir sınıflandırma performansı artışı görülmektedir. Özellik

derecelendirmenin sınıflandırıcı modelleri üzerinde etkili bir performansı olmamıştır. Hatta bazı verilerde sınıflandırma doğruluk oranları özellik derecelendirme ile düşüş göstermiştir. NS GM görüntü verilerinde en yüksek sınıflandırma doğrulukları %81.429 ile DVM-lineer ile yapılan tüm sınıflandırıcı modelleri ile bulunmuştur. Aynı sonuç DVM-rbf ile yapılan özellik derecelendirmesiz sınıflandırma modelinde bulunmuştur. 200 voksel eşik değeri ile alınan görüntü özellikleri DVM-lineer sınıflandırıcıda doğruluk oranını %1 civarında düşürürken, DVM-rbf tabanlı modelde bazı özellik derecelendirme modellerinde %1 oranında artmıştır. Hem voksel eşik değerinin hem de özellik derecelendirmenin MNS GM görüntüler üzerinde etkili bir doğruluk oranı artışı görülmemektedir.

MNS BM görüntülerde en yüksek doğruluk oranları %75 ile DVM-lineer sınıflandırıcının tüm özellik derecelendirme modellerinde bulunmuştur. Hem 200 voksel üzeri eşik değeri ile alınan MNS BM görüntülerde hem de özellik derecelendirme tabanlı sınıflandırmada doğruluk oranı olarak tatmin edici bir artış edilememiştir. NS BM görüntülerde ise %75.714 doğruluk oranı ile entropi tabanlı özellik derecelendirme sınıflandırma modelinde en yüksek sonuç bulunmuştur. Bu görüntülerde de 200 voksel üzeri eşik değeri ve özellik derecelendirme etkili sonuçlar vermemiştir.

6.5. Voksel Değerleri Sınıflandırma Sonuçları

MNS GM, BM ve NS GM, BM görüntülerden Şekil 5.21'deki model ile VTM ile maskelenmiş görüntüler kullanılarak özellikler elde edilmiştir. Voksel değerleri ile ilgili özellikler her senaryo için farklı büyüklüklerde özellik matrisleri oluşturmaktadır. Bu özellikler özellik seçme tabanlı sınıflandırma modelleri ile değerlendirilmiştir. Sınıflandırıcı işlemi için veriler direkt olarak voksel intensite değerleri olduğundan dolayı normalizasyon işlemi yapılmamıştır. DVM-lineer kullanarak özellik seçme tabanlı sınıflandırma sonuçları Çizelge 6.9'da, DVM-rbf tabanlı sonuçlar Çizelge 6.10'da verilmektedir.

Çizelge 6.9. Anlamlı voksel değerlerinin DVM-lineer tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-Lineer							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-Lineer
MNS GM	Hassasiyet	91.429	92.857	90.000	85.714	87.143	78.571
	Özgüllük	88.571	90.000	88.571	90.000	85.714	74.286
	Doğruluk	90.000	91.429	89.286	87.857	86.429	76.429
	AUC	0.900	0.914	0.893	0.879	0.864	0.764
	ÖzellikSayısı	1713	1713	6427	7340	5689	22091
MNS GM_200	Hassasiyet	91.429	92.857	90.000	85.714	88.571	77.143
	Özgüllük	88.571	87.143	87.143	90.000	84.286	72.857
	Doğruluk	90.000	90.000	88.571	87.857	86.429	75.000
	AUC	0.900	0.900	0.886	0.879	0.864	0.750
	ÖzellikSayısı	3152	2296	6409	8548	14509	21731
NS GM	Hassasiyet	95.714	94.286	88.571	92.857	88.571	84.286
	Özgüllük	85.714	88.571	88.571	92.857	87.143	78.571
	Doğruluk	90.714	91.429	88.571	92.857	87.857	81.429
	AUC	0.907	0.914	0.886	0.929	0.879	0.814
	ÖzellikSayısı	3418	5343	8484	5080	11818	11864
NS GM_200	Hassasiyet	95.714	94.286	90.000	90.000	87.143	82.857
	Özgüllük	85.714	85.714	82.857	91.429	84.286	80.000
	Doğruluk	90.714	90.000	86.429	90.714	85.714	81.429
	AUC	0.907	0.900	0.864	0.907	0.857	0.814
	ÖzellikSayısı	4014	3850	5806	4192	9323	11280
MNS BM	Hassasiyet	64.286	64.286	65.714	77.143	72.857	55.714
	Özgüllük	84.286	84.286	80.000	81.429	71.429	64.286
	Doğruluk	74.286	74.286	72.857	79.286	72.143	60.000
	AUC	0.743	0.743	0.729	0.793	0.721	0.600
	ÖzellikSayısı	146	146	444	19	37	2918
MNS BM_200	Hassasiyet	64.286	64.286	68.571	77.143	72.857	57.143
	Özgüllük	84.286	85.714	74.286	81.429	71.429	62.857
	Doğruluk	74.286	75.000	71.429	79.286	72.143	60.000
	AUC	0.743	0.750	0.714	0.793	0.721	0.600
	ÖzellikSayısı	146	146	418	8	37	2693
NS BM	Hassasiyet	68.571	60.000	67.143	71.429	78.571	68.571
	Özgüllük	80.000	85.714	75.714	78.571	78.571	65.714
	Doğruluk	74.286	72.857	71.429	75.000	78.571	67.143
	AUC	0.743	0.729	0.714	0.750	0.786	0.671
	ÖzellikSayısı	608	254	1858	6	66	1868
NS BM_200	Hassasiyet	60.000	61.429	68.571	72.857	78.571	68.571
	Özgüllük	87.143	88.571	75.714	78.571	78.571	67.143
	Doğruluk	73.571	75.000	72.143	75.714	78.571	67.857
	AUC	0.736	0.750	0.721	0.757	0.786	0.679
	ÖzellikSayısı	254	254	1858	6	66	1865

Çizelge 6.10. Anlamlı voksel değerlerinin DVM-rbf tabanlı sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-rbf							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-rbf
MNS GM	Hassasiyet	72.857	68.571	67.143	82.857	67.143	70.000
	Özgüllük	65.714	71.429	67.143	67.143	82.857	30.000
	Doğruluk	69.286	70.000	67.143	75.000	75.000	50.000
	AUC	0.693	0.700	0.671	0.750	0.750	0.500
	ÖzellikSayısı	104	80	70	3	9	22091
MNS GM_200	Hassasiyet	72.857	68.571	67.143	82.857	67.143	60.000
	Özgüllük	65.714	71.429	67.143	67.143	82.857	40.000
	Doğruluk	69.286	70.000	67.143	75.000	75.000	50.000
	AUC	0.693	0.700	0.671	0.750	0.750	0.500
	ÖzellikSayısı	104	80	70	3	9	21731
NS GM	Hassasiyet	80.000	80.000	100.000	68.571	64.286	60.000
	Özgüllük	87.143	85.714	51.429	87.143	82.857	40.000
	Doğruluk	83.571	82.857	75.714	77.857	73.571	50.000
	AUC	0.836	0.829	0.757	0.779	0.736	0.500
	ÖzellikSayısı	263	256	121	18	16	11864
NS GM_200	Hassasiyet	80.000	80.000	100.000	68.571	64.286	60.000
	Özgüllük	87.143	85.714	51.429	87.143	82.857	40.000
	Doğruluk	83.571	82.857	75.714	77.857	73.571	50.000
	AUC	0.836	0.829	0.757	0.779	0.736	0.500
	ÖzellikSayısı	263	256	121	18	16	11280
MNS BM	Hassasiyet	77.143	75.714	71.429	75.714	87.143	30.000
	Özgüllük	72.857	74.286	72.857	78.571	54.286	70.000
	Doğruluk	75.000	75.000	72.143	77.143	70.714	50.000
	AUC	0.750	0.750	0.721	0.771	0.707	0.500
	ÖzellikSayısı	144	144	104	5	4	2918
MNS BM_200	Hassasiyet	61.429	75.714	71.429	75.714	87.143	20.000
	Özgüllük	88.571	74.286	72.857	78.571	54.286	80.000
	Doğruluk	75.000	75.000	72.143	77.143	70.714	50.000
	AUC	0.750	0.750	0.721	0.771	0.707	0.500
	ÖzellikSayısı	105	144	104	5	4	2693
NS BM	Hassasiyet	62.857	62.857	57.143	82.857	51.429	40.000
	Özgüllük	71.429	71.429	78.571	70.000	85.714	60.000
	Doğruluk	67.143	67.143	67.857	76.429	68.571	50.000
	AUC	0.671	0.671	0.679	0.764	0.686	0.500
	ÖzellikSayısı	179	179	170	8	27	1868
NS BM_200	Hassasiyet	62.857	54.286	61.429	82.857	51.429	40.000
	Özgüllük	74.286	85.714	78.571	70.000	85.714	60.000
	Doğruluk	68.571	70.000	70.000	76.429	68.571	50.000
	AUC	0.686	0.700	0.700	0.764	0.686	0.500
	ÖzellikSayısı	186	187	180	8	27	1865

MNS GM görüntülerde en yüksek sınıflandırma doğruluğu 1713 özellik kullanarak %91.429 doğruluk oranı ile entropi tabanlı özellik derecelendirme DVM-lineer sınıflandırıcıda elde edilmiştir. DVM-lineer tabanlı sınıflandırıcı modelleri DVM-rbf sınıflandırıcılara göre daha yüksek doğruluk oranları verilmiştir. MNS GM görüntüler için özellik derecelendirme işlemi doğruluk oranlarını net bir şekilde arttırmıştır. NS GM özelliklerde en yüksek sınıflandırma doğruluğu 5080 özellik ile t-test özellik derecelendirme tabanlı DVM-lineer sınıflandırıcıda %92.857 doğruluk oranı olarak bulunmuştur. DVM-lineer sınıflandırıcı doğruluk oranları diğer sınıflandırıcı doğruluk oranlarına göre daha yüksek sonuçlar vermiştir. Özellik derecelendirme ile 11864 özellik yerine 5080 özellik t-test ile seçilerek %10 oranında sınıflandırma doğruluğu artmıştır. 200 üzeri eşik ile elde edilen özelliklerden DVM-lineer sınıflandırıcıda daha az doğruluk oranı bulunurken, DVM-rbf ile herhangi bir doğruluk oranı değişikliği olmamıştır.

BM ile elde edilen verilerden MNS BM verilerde t-test özellik derecelendirme tabanlı 19 özellik ile ve MNS BM_200 verilerde t-test özellik derecelendirme tabanlı 8 özellik ile DVM-lineer sınıflandırıcıda %79.286 olmak üzere en yüksek doğruluk oranı bulunmuştur. Özellik derecelendirme ile MNS BM verilerde 2918 özellik 19 özelliğe ve MNS BM_200 verilerde 2693 veriden 8 özelliğe düşürülmüştür. Özellik derecelendirme sınıflandırıcı sonuçlarını net bir şekilde arttırmaktadır. DVM-lineer sınıflandırıcıda MNS BM ve MNS BM_200 veri hemen hemen aynı değerleri göstermektedir. DVM-lineer ve DVM-rbf tabanlı sınıflandırmada özellik derecelendirme ile kullanılan modeller arasında çok fark görülmemekte, özellik derecelendirme olmadan yapılan sınıflandırmada ise %10 oranında sınıflandırma doğruluk oranı farklılığı görülmektedir. NS BM ve BM_200 verilerde en yüksek oranlar 66 özellik ile wilcoxon özellik derecelendirme tabanlı DVM-lineer sınıflandırıcıda %78.571 doğruluk oranı ile elde edilmiştir. Özellik derecelendirme işlemi doğruluk oranını net bir şekilde arttırmıştır. 200 eşik değerinin kullanılması sadece 3 voksel kümesini elemiştir ve sınıflandırma sonuçlarında etkin bir değişime neden olmamıştır. DVM-lineer sınıflandırıcı doğruluk oranları DVM-rbf sınıflandırıcıya göre daha yüksek sonuçlar vermektedir.

6.6. 3B GSEOM Sınıflandırma Sonuçları

VTM ile elde edilen sekiz farklı VOI senaryosunun her birinden Şekil 5.28'deki model kullanılarak 3B GSEOM ile 624 özellik elde edilmiştir. Sınıflandırma işleminden önce her bir özellik kendi içerisinde 0-1 arasına normalizasyon işlemi yapılmıştır. 3B GSEOM ile yapılan DVM-lineer tabanlı sınıflandırma sonuçları Çizelge 6.11'de, DVM-rbf tabanlı sınıflandırma sonuçları Çizelge 6.12'de verilmektedir.

MNS GM görüntülerde en yüksek sınıflandırma doğruluğu %82.85 doğruluk oranı ile wilcoxon tabanlı DVM-rbf sınıflandırıcısında 20 özellik ve 200 voksel eşik değeri ile bulunmuştur. Özellik derecelendirme ve 200 voksel eşik değerinin kullanılması sınıflandırma doğruluklarını arttırmıştır. NS GM görüntülerde en yüksek sınıflandırma doğruluğu t-test tabanlı DVM-lineer sınıflandırıcı ile 614 özellik kullanılarak %86.43 olarak bulunmuştur.

MNS BM görüntülerde %76.43 sınıflandırma doğruluğu ile wilcoxon ve roc tabanlı DVM-rbf sınıflandırıcısında 200 voksel eşik değerli veriler ile bir özellik kullanılarak en yüksek değer bulunmuştur. NS BM görüntülerde ise %76.43 ile roc ve t-test tabanlı DVM-rbf sınıflandırıcıda hem NS BM hem de 200 voksel üzeri eşik değeri için sırasıyla 2 ve 25 özellik kullanarak en yüksek doğruluk oranı bulunmuştur. Özellik derecelendirme genel olarak doğruluk oranlarını arttırmaktadır.

3B GSEOM kullanılarak elde edilen sınıflandırma sonunda NS görüntüler daha yüksek sonuç vermektedir. Dolayısıyla MR görüntülerinin normalizasyon işleminden sonra doku konsantrasyonunu koruyan normalize veriler doku analizi noktasında daha anlamlı bilgi barındırabilmektedir. GM görüntülerde BM'ye göre daha yüksek sınıflandırma doğruluğu vermesi GM'de meydana gelen dokusal kayıpların ayırıcı tanıda daha etkili olduğunu göstermektedir.

Çizelge 6.11. 3B GSEOM özellikleri DVM-lineer sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-Lineer							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-Lineer
MNS GM	Hassasiyet	91.429	91.429	87.143	87.143	85.714	80.000
	Özgüllük	67.143	68.571	72.857	68.571	72.857	75.714
	Doğruluk	79.286	80.000	80.000	77.857	79.286	77.857
	AUC	0.793	0.800	0.800	0.779	0.793	0.779
	ÖzellikSayısı	105	127	105	105	39	624
MNS GM_200	Hassasiyet	90.000	90.000	90.000	90.000	92.857	81.429
	Özgüllük	67.143	67.143	67.143	65.714	67.143	77.143
	Doğruluk	78.571	78.571	78.571	77.857	80.000	79.286
	AUC	0.786	0.786	0.786	0.779	0.800	0.793
	ÖzellikSayısı	125	109	109	109	189	624
NS GM	Hassasiyet	92.857	87.143	88.571	92.857	90.000	81.429
	Özgüllük	78.571	82.857	80.000	80.000	78.571	81.429
	Doğruluk	85.714	85.000	84.286	86.429	84.286	81.429
	AUC	0.857	0.850	0.843	0.864	0.843	0.814
	ÖzellikSayısı	198	165	69	614	115	624
NS GM_200	Hassasiyet	88.571	87.143	87.143	87.143	88.571	72.857
	Özgüllük	77.143	77.143	78.571	80.000	78.571	80.000
	Doğruluk	82.857	82.143	82.857	83.571	83.571	76.429
	AUC	0.829	0.821	0.829	0.836	0.836	0.764
	ÖzellikSayısı	62	62	83	86	84	624
MNS BM	Hassasiyet	70.000	70.000	68.571	70.000	71.429	57.143
	Özgüllük	78.571	78.571	82.857	78.571	77.143	64.286
	Doğruluk	74.286	74.286	75.714	74.286	74.286	60.714
	AUC	0.743	0.743	0.757	0.743	0.743	0.607
	ÖzellikSayısı	2	2	1	2	5	624
MNS BM_200	Hassasiyet	70.000	70.000	71.429	70.000	71.429	57.143
	Özgüllük	78.571	78.571	78.571	78.571	78.571	65.714
	Doğruluk	74.286	74.286	75.000	74.286	75.000	61.429
	AUC	0.743	0.743	0.750	0.743	0.750	0.614
	ÖzellikSayısı	2	6	1	6	1	624
NS BM	Hassasiyet	72.857	75.714	75.714	72.857	77.143	61.429
	Özgüllük	75.714	71.429	75.714	78.571	71.429	72.857
	Doğruluk	74.286	73.571	75.714	75.714	74.286	67.143
	AUC	0.743	0.736	0.757	0.757	0.743	0.671
	ÖzellikSayısı	14	2	2	16	32	624
NS BM_200	Hassasiyet	72.857	72.857	72.857	75.714	82.857	61.429
	Özgüllük	75.714	75.714	78.571	75.714	67.143	74.286
	Doğruluk	74.286	74.286	75.714	75.714	75.000	67.857
	AUC	0.743	0.743	0.757	0.757	0.750	0.679
	ÖzellikSayısı	17	55	12	5	43	624

Çizelge 6.12. 3B GSEOM özellikleri DVM-rbf sınıflandırma sonuçları (MNS GM: Modülasyonlu Normalize Segmente GM, NS GM: Normalize Segmente GM, MNS BM: Modülasyonlu Normalize Segmente BM, NS BM: Normalize Segmente BM)

DVM-rbf							
VERİ TÜRÜ	Kriter	Bhattacharya	Entropi	Roc	T-test	Wilcoxon	DVM-rbf
MNS GM	Hassasiyet	64.286	60.000	64.286	65.714	74.286	18.571
	Özgüllük	90.000	94.286	90.000	88.571	87.143	94.286
	Doğruluk	77.143	77.143	77.143	77.143	80.714	56.429
	AUC	0.771	0.771	0.771	0.771	0.807	0.564
	ÖzellikSayısı	6	29	11	1	17	624
MNS GM_200	Hassasiyet	82.857	82.857	82.857	82.857	77.143	20.000
	Özgüllük	80.000	80.000	80.000	80.000	88.571	88.571
	Doğruluk	81.429	81.429	81.429	81.429	82.857	54.286
	AUC	0.814	0.814	0.814	0.814	0.829	0.543
	ÖzellikSayısı	107	107	107	107	20	624
NS GM	Hassasiyet	75.714	75.714	80.000	84.286	74.286	2.857
	Özgüllük	90.000	90.000	85.714	82.857	92.857	100.000
	Doğruluk	82.857	82.857	82.857	83.571	83.571	51.429
	AUC	0.829	0.829	0.829	0.836	0.836	0.514
	ÖzellikSayısı	148	148	5	13	129	624
NS GM_200	Hassasiyet	78.571	78.571	80.000	78.571	80.000	0.000
	Özgüllük	85.714	85.714	84.286	84.286	84.286	97.143
	Doğruluk	82.143	82.143	82.143	81.429	82.143	48.571
	AUC	0.821	0.821	0.821	0.814	0.821	0.486
	ÖzellikSayısı	37	50	5	5	5	624
MNS BM	Hassasiyet	70.000	74.286	75.714	74.286	70.000	17.143
	Özgüllük	77.143	75.714	75.714	75.714	77.143	81.429
	Doğruluk	73.571	75.000	75.714	75.000	73.571	49.286
	AUC	0.736	0.750	0.757	0.750	0.736	0.493
	ÖzellikSayısı	22	167	167	167	1	624
MNS BM_200	Hassasiyet	71.429	70.000	68.571	70.000	68.571	5.714
	Özgüllük	77.143	78.571	84.286	78.571	84.286	91.429
	Doğruluk	74.286	74.286	76.429	74.286	76.429	48.571
	AUC	0.743	0.743	0.764	0.743	0.764	0.486
	ÖzellikSayısı	26	1	1	1	1	624
NS BM	Hassasiyet	74.286	71.429	74.286	72.857	72.857	5.714
	Özgüllük	75.714	75.714	78.571	80.000	78.571	98.571
	Doğruluk	75.000	73.571	76.429	76.429	75.714	52.143
	AUC	0.750	0.736	0.764	0.764	0.757	0.521
	ÖzellikSayısı	25	4	2	25	23	624
NS BM_200	Hassasiyet	74.286	71.429	74.286	72.857	72.857	5.714
	Özgüllük	75.714	77.143	78.571	80.000	78.571	98.571
	Doğruluk	75.000	74.286	76.429	76.429	75.714	52.143
	AUC	0.750	0.743	0.764	0.764	0.757	0.521
	ÖzellikSayısı	25	19	2	25	23	624

6.7. 3B Ayrık Dalgacık Dönüşümü Sınıflandırma Sonuçları

VTM ile elde edilen sekiz farklı senaryo için VOI bölgelere 37 farklı dalgacık ile Şekil 5.24'teki model kullanılarak özellik çıkarma işlemi yapılmıştır. Her bir senaryo için beş özellik derecelendirme tabanlı sınıflandırma ve bir özellik derecelendirme olmadan sınıflandırma olmak üzere her bir dalgacık için altı farklı sınıflandırma modeli kullanılmıştır. Dolayısıyla her bir VOI senaryosu için DVM-lineer kullanılarak 222 sınıflandırma modeli, DVM-rbf kullanarak 222 sınıflandırma modeli olmak üzere 444 sınıflandırma modeli kullanılmıştır. Sekiz farklı VOI senaryosu için toplamda 3552 sınıflandırma modeli kullanılarak en iyi sonucu veren dalgacık fonksiyonu ve sınıflandırma modeli belirlenmiştir. Veriler sınıflandırma işlemine tabi tutulmadan önce her bir özellik kendi içinde 0-1 arasına normalize edilmiştir. 37 dalgacık için sınıflandırma sonuçları EK7'de sırasıyla DVM-lineer MNS GM, NS GM, MNS BM, NS BM, MNS GM_200, NS GM_200, MNS BM_200, NS BM_200, DVM-rbf MNS GM, NS GM, MNS BM, NS BM, MNS GM_200, NS GM_200, MNS BM_200, NS BM_200 için verilmiştir.

MNS GM VOI verilerde en yüksek sınıflandırma sonucu db3 dalgacık fonksiyonu kullanılarak 23 özellik ile entropi ve roc tabanlı DVM-lineer sınıflandırıcıda %87.1 doğruluk oranı, sym3 dalgacık fonksiyonu kullanarak 23 özellik ile entropi ve roc tabanlı DVM-lineer sınıflandırıcıda %87.1 doğruluk oranı olarak bulunmuştur. Özellik derecelendirme kullanmanın doğruluk oranlarını attırdığı gözlemlenmiştir. DVM-rbf sınıflandırıcıda doğruluk oranları nispeten düşmektedir. 200 eşik değeri uygulanan VOI bölgelerin sınıflandırılmasında eşik uygulanmayan verilere göre çok az doğruluk oranı değişikliği görülmektedir. NS GM VOI verilerde en yüksek sınıflandırma doğruluk oranı 16 özellik kullanarak %90 ile db8 dalgacığında bhattacharya, entropi, roc tabanlı DVM-lineer sınıflandırıcıda bulunmuştur. Özellik derecelendirme doğruluk oranlarını ciddi anlamda arttırmaktadır.

MNS BM görüntülerde en yüksek doğruluk 200 eşik değeri uygulanmış VOI verilerde 17 özellik ile db8 dalgacık kullanılarak entropi tabanlı DVM-rbf sınıflandırıcıda %80 olarak elde edilmiştir. Özellik derecelendirme kullanımı genel olarak doğruluk oranını arttırırken, 200 eşik değeri doğruluk oranının artışını çok az etkilemiştir. NS BM verilerde en yüksek doğruluk oranı %82.1 ile bior1.3 dalgacık fonksiyonu ve 6 özellik kullanımı ile bhattacharya tabanlı DVM-lineer sınıflandırıcıda 200 eşik değeri uygulanmış VOI verilerde bulunmuştur. Doğruluk oranı özellik

derecelendirme ile artarken 200 voksel eşik değeri de doğruluk oranlarının artışında bir miktar etkili olmuştur.

GM VOI bölgelerde elde edilen dalgacık katsayıları ile elde edilen özelliklerin sınıflandırılmasında normalize segmente görüntüler modülasyonlu görüntülere göre daha yüksek sonuçlar vermiştir. BM görüntülerde ise normalize segmente görüntülere 200 voksel eşik değeri kullanılan veriler daha yüksek sonuç vermiştir. Normalize segmente görüntüler doku konsantrasyonu korunduğu için dokusal farklılıkların sınıflandırılmasında daha etkili olduğu görülmüştür. GM'nin BM'ye göre daha yüksek doğruluk vermesi daha ayırıcı özelliklere sahip olduğunu göstermektedir. Ancak BM ile elde edilen sınıflandırma doğruluğu kabul edilebilir seviyede bulunmuş olup literatürde bu çerçeve ile ilk defa tanımlanmıştır.

6.8. OASIS ve Tıp Fakültesi Verileri Sınıflandırma Genel Sonuçları

Selçuk Üniversitesi Tıp Fakültesi Radyoloji ve Nöroloji Anabilim Dallarının ortak çalışması ile 25 adet KDR ile etiketlenmiş MP-RAGE uzantılı 3B yapısal beyin MR görüntüleri tıp fakültesi veri tabanından alınmıştır. Her ne kadar MR çekimleri veri tabanı ile aynı protokollerde istense de cihaz görüntü çekim kabiliyetinin farklı olması, operatör farklılığı, hastane verilerinin veri tabanı protokolü ile farklı alınmasına neden olmuştur. Bu nedenle hastaneden alınan görüntüler ile veri tabanı görüntülerinin birleştirilmesi heterojen bir veri kümesi oluşturmaktadır. Literatürde farklı merkezlerden ve farklı protokoller kullanarak alınan MR verileri ile yapılan çalışmalara çoklu merkez (*multi-center*) çalışmalar denilmektedir. Bu tarz çalışmalarda farklı merkez ve görüntüleme protokollerindeki verilerin tek başına veya birleştirilmesi ile elde edilen sınıflandırma çalışmalarının karşılaştırmaları yer almaktadır. Lebedev ve ark. (2013) yaptıkları çalışmada farklı merkezlerden ve farklı protokol ile alınan AH ve Lewy Cisimcikli Demans (LCD) MR görüntülerinin sınıflandırma performanslarını karşılaştırmışlardır. MR görüntülerinin analizini Freesurfer programı ile yapmışlardır. İki merkez ile yaptıkları çalışmada her merkezden aldıkları veriyi önce kendi içinde daha sonra verileri birleştirerek sınıflandırma işlemi yapmışlardır. Farklı protokollerde aldıkları verilerin karıştırılması ile sınıflandırma doğruluk oranlarının düştüğü ancak kabul edilebilir bir seviyede olduklarını belirtmişlerdir (Lebedev ve ark., 2013). Westman ve ark. (2011) Avrupa merkezli AddNeuromed ve Amerika merkezli ADNI konsorsiyumlarından aynı görüntüleme protokolleri kullanarak sınıflandırma çalışması yapmışlardır. MR görüntülerini Freesurfer ile analiz ederek özellik çıkarma işlemi yapmışlardır. Çapraz geçerleme kullandıkları çalışmada AddNeuromed merkezinden alınan görüntüyü eğitim, ADNI verilerini ise test olarak kullanmışlardır. Diğer aşamada ADNI verilerini eğitim, AddNeuromed verilerini test için kullanmışlardır. Aynı görüntüleme protokolleri ile alınan verilerin sınıflandırılmasında sonuçların yakın değerler gösterdiğini belirtmişlerdir (Westman ve ark., 2011a). Farklı protokol verilerden kaynaklanan problemlerin çözümü için yapılan en kapsamlı çalışmalardan bir tanesi 2014 yılında MICCAI konferansındaki CADDementia yarışmasıdır. 15 takımın katıldığı yarışmada 30 veri eğitim için, farklı protokollerdeki 354 veri ise eğitilmiş sistemin daha önce görmediği verilerle analizi için test olarak kullanılmıştır. Yarışma sonucunda en yüksek %63.00 doğruluk oranı bulunmuş olup bu tarz çalışmaların devam etmesi gerektiği belirtilmiştir (Bron ve ark., 2015). Ancak bu çalışmaların çoğunda

Freesurfer programı ile özellik çıkarma işlemi yapılmaktadır. Freesurfer paket bir program olduğu için içinde çalıştırılan algoritmalara herhangi bir müdahale yapılamamaktadır. Freesurfer programının çıktıları, MR görüntülerinden elde ettikleri özellikleri bir dosya içerisinde vererek kullanıcının kullanımına sunmaktadır. Goto ve ark. (2013) dört farklı merkezden farklı protokol ile alınan MR görüntülerinde DARTEL normalizasyon yöntemi ile atlas tabanlı hacim çalışması yapmışlardır. Çalışma sonucunda DARTEL normalizasyon yönteminin farklı merkez ve protokollerden alınan görüntülerde maksimum çakıştırmayı yaptığını belirterek, farklı görüntüleme protokolleri ile alınan MR görüntüleri arasındaki farklılıkların giderilmesinde etkili olduğunu belirtmişlerdir (Goto ve ark., 2013). Bu bilgiye dayanarak tez çalışmasında farklı protokollerde alınan hastane verileri DARTEL normalizasyon yöntemi kullanılarak normalize edildikten sonra OASIS veri tabanında uygulanan aynı özellik çıkarma modelleri ile özellik kümeleri oluşturulmuştur. Özellik çıkarma işlemleri için OASIS veri tabanında takip edilen modeller aynen kullanılmıştır. OASIS veri tabanı özelliklerinde en az özellik ile en yüksek sınıflandırma doğruluğunu veren özellik derecelendirme tabanlı sınıflandırma modelleri hastane verilerinin validasyon seti olarak kullanılması için belirlenmiştir. Hastane verilerinin 25 adedinden dört tanesi VBM8 kütüphanesi analizinden sonra kovaryans analizlerinde ayrık değerler gösterdiği için çalışmadan çıkarılmıştır. OASIS veri tabanı içerisinde en yüksek doğruluk oranını veren modeller tekrar çalıştırılmıştır. Hastane seti ile elde edilen özellikler, OASIS veri tabanından elde edilen özelliklerin daha önce kendi içinde 0-1 arasına normalize edilmesinden dolayı lineer regresyon analizi ile normalizasyon işlemi yapılmıştır. OASIS veri tabanından daha önce normalize edilen verilerden lineer regresyon analizi ile *'y=ax+b'* şeklinde birinci dereceden bir denklem elde edilir. Hastane verilerinden gelen özellikler tek tek *x* değişkenine verilerek OASIS normalize uzayda o değerin hangi aralığa denk geldiği bulunur. Normalize edilmiş özelliklere, OASIS veri tabanı özellikleri için elde edilen önemlilik sıralaması aynen hastane validasyon setine uygulanmıştır. 10 çapraz geçerleme ile OASIS özellikleri ile eğitilen sisteme çapraz geçerlemeden gelen 14 veri tabanı verisi yerine 21 adet hastane verisi verilmiştir. Her bir çapraz geçerlemede test edilen hastane verilerinin doğruluk oranlarının çapraz geçerleme sonucunda ortalaması alınmıştır. Tıp fakültesi verilerinin hepsi hasta verisi olduğu için hassasiyet ve AUC değerleri doğru pozitif değerinin hesaplanamamasından dolayı elde edilememiştir. Değerlendirmeler doğruluk oranı ve

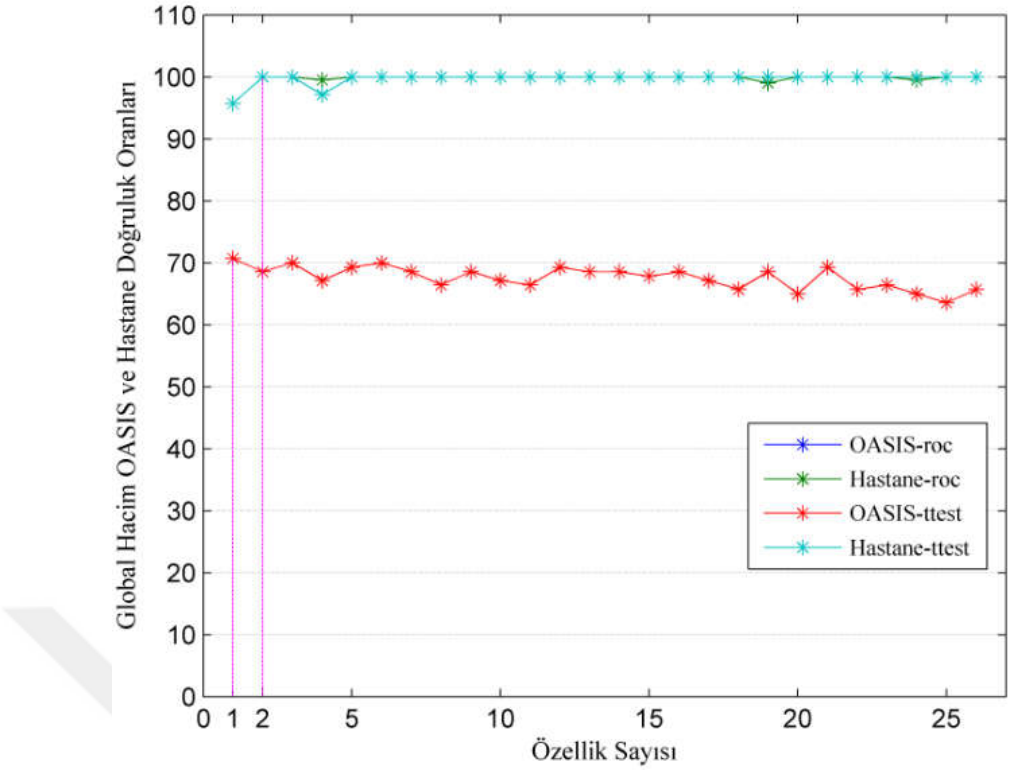
özgüllük üzerinden yapılmıştır. OASIS verileri ile sınıflandırma modelinin eğitilmesi ve hastane verilerinin validasyonu her bir özellik için ayrı ayrı değerlendirilmiştir.

Çizelge 6.13'te global ve lokal hacimler için OASIS veri tabanının verdiği en iyi sınıflandırma doğruluğu ve hastane verilerinin validasyonu sonucu elde edilen özellik sayısına göre en yüksek sınıflandırma doğrulukları verilmiştir. Global hacimlerde OASIS veri tabanı bir özellik ile %70.71 doğruluk oranı verirken, hastane validasyon setinde ilk iki özellik ile %100 doğruluk oranı elde edilmiştir. İkinci özellik her iki özellik derecelendirme modelinde de GM/TBH olarak bulunmuştur. Bu özellik GM hacimsel kaybının beyinde en fazla değişen bölge olmasından dolayı TBH oranının daha fazla anlamlı çıkması son derece makuldür. Lokal hacimlerde OASIS veritabanı AAL/TBH özellik kümesi kullanılarak 107 özellik ile %95.00 en yüksek doğruluk oranını verirken, hastane validasyon seti aynı özellik setinin ilk 39 özelliği ile %98.57 en yüksek doğruluk oranını vermiştir. (ÖS: Özellik Sayısı, DL: DVM-lineer, DR: DVM-rbf, HA: Hassasiyet, ÖZ: Özgüllük, DO: Doğruluk)

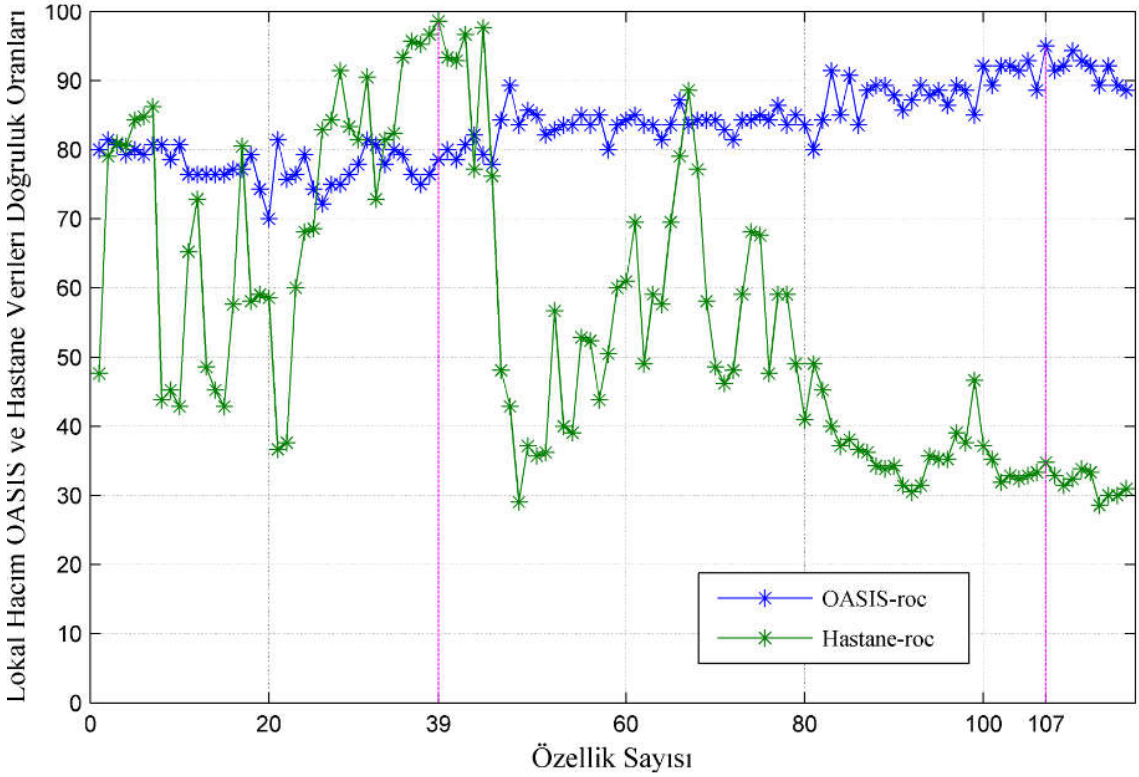
Çizelge 6.13. Hacimsel özelliklerin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

					ÖS	HA	ÖZ	DO	AUC
OASIS	Gobal Hacim	MNS	Roc t-test	DL	1	72.86%	68.57%	70.71%	0.71
HASTANE	Gobal Hacim	MNS	Roc t-test	DL	2	--------	100%	100%	---------
OASIS	Lokal Hacim	MNS GM (AAL/TBH)	roc	DL	107	95.75%	94.29%	95.00%	0.95
HASTANE	Lokal Hacim	MNS GM(AAL/TBH)	roc	DL	39	--------	98.57%	98.57%	---------

Şekil 6.1'de Global Hacimlerin roc ve t-test özellik derecelendirme modellerinde özellik sayısına göre doğruluk oranlarının değişimi, Şekil 6.2'de Lokal Hacimlerin roc özellik derecelendirme modellerinde özellik sayısına göre doğruluk oranlarının değişimi verilmiştir.



Şekil 6.1. Global Hacimler için OASIS ve hastane validasyon setinin özellik sayısına göre doğruluk oranları



Şekil 6.2. Lokal Hacimler için OASIS ve hastane validasyon setinin özellik sayısına göre doğruluk oranları

Şekil 6.1'de görüldüğü gibi global hacimler için hastane verilerinde ikiden fazla verilerde de %100 sınıflandırma doğruluk oranı görülmektedir. Ancak en az özellik ile en fazla doğruluk oranını ilk iki özellik vermektedir. Şekil 6.2'de grafikte görüldüğü gibi lokal hacimlerde veri tabanının en yüksek doğruluğu verdiği 107 özelliğin ilk 39 özelliği ile %98.57 sınıflandırma doğruluğu elde edilmektedir. Her iki grafikte görüldüğü gibi özellik sayısının değişimi ile doğruluk oranları veri kümesi için değişmektedir. Çizelge 6.14'te OASIS veri tabanı için lokal hacimlerde en yüksek sınıflandırma doğruluğunu veren 107 subkortikal beyin bölgesi verilmiştir. Bu subkortikal bölgelerin ilk 39 verisi ile hastane validasyon verileri en yüksek doğruluk oranını vermiştir.

Çizelge 6.14. Lokal hacimlerin AAL/TBH için roc özellik derecelendirme ile en iyi ayırıcı özellikten itibaren 107 özelliğinin sıralanması

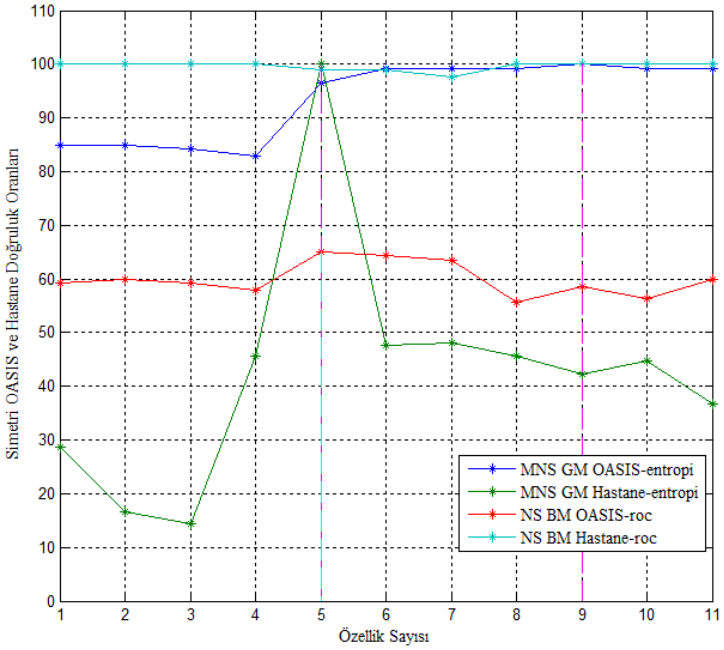
AAL/TBH							
1	Hippocampus_R	28	Cingulum_Ant_L	55	Frontal_Sup_Orb_R	82	Paracentral_Lobule_R
2	Hippocampus_L	29	Precuneus_R	56	Occipital_Mid_L	83	Caudate_L
3	Amygdala_R	30	Heschl_R	57	SupraMarginal_R	84	Putamen_L
4	ParaHippocampal_R	31	Insula_L	58	Postcentral_R	85	Caudate_R
5	Amygdala_L	32	Cingulum_Post_L	59	Frontal_Med_Orb_R	86	Cerebelum_9_R
6	ParaHippocampal_L	33	Frontal_Med_Orb_L	60	Vermis_4_5	87	Occipital_Sup_L
7	Temporal_Pole_Sup_L	34	Precuneus_L	61	Rolandic_Oper_L	88	Cerebelum_3_L
8	Temporal_Mid_L	35	Temporal_Sup_R	62	Frontal_Sup_R	89	Occipital_Inf_R
9	Temporal_Inf_L	36	Occipital_Inf_L	63	Parietal_Sup_L	90	Putamen_R
10	Temporal_Mid_R	37	Insula_R	64	Vermis_6	91	Supp_Motor_Area_L
11	Thalamus_L	38	Cingulum_Mid_L	65	Frontal_Mid_Orb_L	92	Supp_Motor_Area_R
12	Fusiform_L	39	Temporal_Pole_Mid_R	66	Frontal_Sup_Medial_L	93	Cerebelum_9_L
13	Rectus_L	40	Pallidum_L	67	Frontal_Sup_Orb_L	94	Vermis_9
14	Thalamus_R	41	Frontal_Sup_Medial_R	68	Pallidum_R	95	Frontal_Sup_L
15	Temporal_Pole_Sup_R	42	SupraMarginal_L	69	Cerebelum_4_5_L	96	Cerebelum_8_L
16	Fusiform_R	43	Occipital_Mid_R	70	Occipital_Sup_R	97	Precentral_R
17	Temporal_Sup_L	44	Parietal_Inf_R	71	Parietal_Sup_R	98	Paracentral_Lobule_L
18	Heschl_L	45	Frontal_Inf_Tri_L	72	Frontal_Inf_Oper_R	99	Vermis_7
19	Cingulum_Mid_R	46	Cerebelum_3_R	73	Frontal_Inf_Tri_R	100	Cerebelum_10_L
20	Rectus_R	47	Frontal_Inf_Orb_L	74	Frontal_Mid_R	101	Vermis_3
21	Angular_L	48	Lingual_R	75	Frontal_Mid_Orb_R	102	Cerebelum_Crus2_L
22	Temporal_Pole_Mid_L	49	Vermis_10	76	Frontal_Inf_Oper_L	103	Cerebelum_6_L
23	Cingulum_Post_R	50	Frontal_Inf_Orb_R	77	Precentral_L	104	Calcarine_L
24	Olfactory_L	51	Cingulum_Ant_R	78	Rolandic_Oper_R	105	Cuneus_L
25	Olfactory_R	52	Angular_R	79	Lingual_L	106	Cerebelum_Crus2_R
26	Temporal_Inf_R	53	Postcentral_L	80	Cerebelum_4_5_R	107	Cerebelum_8_R
27	Parietal_Inf_L	54	Frontal_Mid_L	81	Cuneus_R		

Çizelge 6.15'te simetri özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları verilmektedir. MNS GM görüntülerde entropi tabanlı derecelendirmede 9 özellik OASIS veri tabanı ile %100 sınıflandırma doğruluğu bulunan özellikler hastane validasyon setinde 5 özellik ile %100 doğruluk oranı olarak bulunmuştur. NS BM verilerde simetri özellikleri OASIS veri tabanı ile beş özellik kullanarak %65.00 doğruluk oranı bulurken, hastane validasyon seti aynı özellik kümesi ile %100 doğruluk oranı vermiştir. MNS GM veriler DVM-lineer sınıflandırıcı ile en yüksek sonucu verirken NS BM veriler DVM-rbf sınıflandırıcı ile en yüksek sonucu vermiştir.

Çizelge 6.15. Simetri özelliklerin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

					ÖS	HA	ÖZ	DO	AUC
OASIS	GM	MNS	Entropi	DL	9	100.00%	100.00%	100.00%	1
HASTANE	GM	MNS	Entropi	DL	5	--------	100.00%	100.00%	---------
VERİTABANI	BM	NS	roc	DR	5	74.28%	55.71%	65.00%	0.65
HASTANE	BM	NS	roc	DR	1	----------	100.00%	100.00%	---------

Şekil 6.3'te MNS GM için OASIS ve hastane validasyon setlerinde simetri özellik sayısına göre doğruluk oranları, NS BM için OASIS ve hastane validasyon setlerinde özellik sayısına göre doğruluk oranları grafik olarak verilmiştir.



Şekil 6.3. GM ve BM'de simetri özellikleri için özellik sayısına göre sınıflandırma doğruluk oranları

Şekil 6.3'te görüldüğü gibi hastane validasyon setinde MNS GM entropi tabanlı özellik derecelendirmede OASIS veri tabanı 9 özellik ile %100 sınıflandırma doğruluğu verirken, hastane validasyon seti 9 özelliğin ilk 5 özelliği ile %100 doğruluk oranı vermiştir. NS BM verilerde roc tabanlı özellik derecelendirmede OASIS veri tabanı için ilk 5 özellik en yüksek %65 doğruluk oranı verirken, hastane validasyon seti 5 özelliğin ilk 1 özelliği ile % 100 sonuç vermiştir. Çizelge 6.15'te simetri özellikleri için MNS GM ve NS BM için hastane ve validasyon setlerinden en yüksek sınıflandırma doğruluğunu veren özellikler verilmiştir.

Çizelge 6.15. Simetri özellikleri için MNS GM ve NS BM için hastane ve validasyon setlerinden en yüksek sınıflandırma doğruluğunu veren özellikler

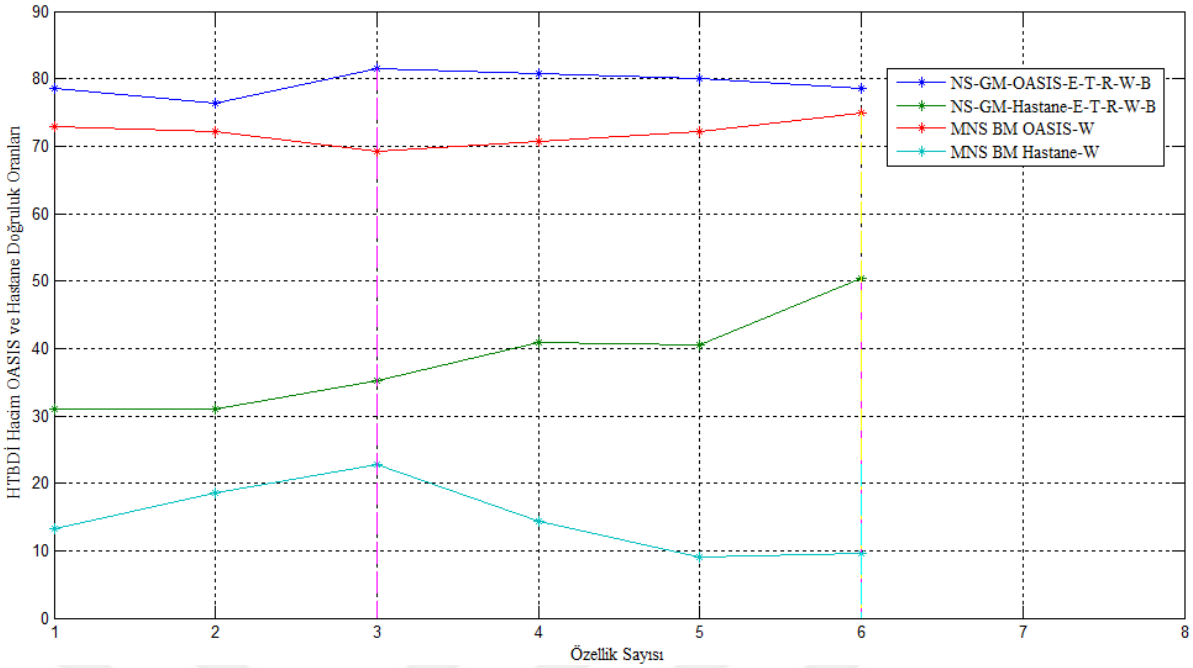
	MNS GM	NS BM
	Bhattacharya	Roc
1	SSIM	City block
2	Korelasyon	Hamming
3	PSNR	Öklit
4	Kare Öklit	Minkowski
5	Hamming	Korelasyon
6	Spearman	
7	Kosine	
8	Chebyshev	
9	Öklit	

Çizelge 6.16'da HTBDİ özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları verilmektedir. OASIS verilerde NS GM verilerde 3 özellik ile bhattacharya, entropi, roc, t-test, wilcoxon tabanlı özellik derecelendirme de %81.43 doğruluk oranı bulunurken, hastane validasyon setinde aynı derecelendirme ile 6 özellik kullanarak % 50.47 doğruluk oranı bulunmuştur. OASIS verilerde MNS BM verilerde 6 özellik ile bhattacharya, entropi, roc, t-test, wilcoxon tabanlı özellik derecelendirme de %75.00 doğruluk oranı bulunurken, hastane validasyon setinde wilcoxon derecelendirme ile ilk 3 özellik ile % 22.88 doğruluk oranı bulunmuştur.

Çizelge 6.16. Hacimsel özelliklerin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

						ÖS	HA	ÖZ	DO	AUC
OASIS	HTBDİ	GM	NS	Bhattacharya	DL	3	77.14%	85.71%	81.43%	0.814
HASTANE	HTBDİ	GM	NS	Bhattacharya	DL	6	----------	50.47%	50.47%	---------
OASIS	HTBDİ	GM	NS	Entropi	DL	3	77.14%	85.71%	81.43%	0.814
HASTANE	HTBDİ	GM	NS	Entropi	DL	6	----------	50.47%	50.47%	---------
OASIS	HTBDİ	GM	NS	Roc	DL	3	77.14%	85.71%	81.43%	0.814
HASTANE	HTBDİ	GM	NS	Roc	DL	6	----------	50.47%	50.47%	---------
OASIS	HTBDİ	GM	NS	T-test	DL	3	77.14%	85.71%	81.43%	0.814
HASTANE	HTBDİ	GM	NS	T-test	DL	6	----------	50.47%	50.47%	---------
OASIS	HTBDİ	GM	NS	Wilcoxon	DL	3	77.14%	85.71%	81.43%	0.814
HASTANE	HTBDİ	GM	NS	Wilcoxon	DL	6	----------	50.47%	50.47%	---------
OASIS	HTBDİ	BM	MNS	Bhattacharya	DL	6	71.43%	78.57%	75.00%	0.75
HASTANE	HTBDİ	BM	MNS	Bhattacharya	DL	1	----------	15.71%	15.71%	---------
OASIS	HTBDİ	BM	MNS	Entropi	DL	6	71.43%	78.57%	75.00%	0.75
HASTANE	HTBDİ	BM	MNS	Entropi	DL	1	----------	15.71%	15.71%	---------
OASIS	HTBDİ	BM	MNS	Roc	DL	6	71.43%	78.57%	75.00%	0.75
HASTANE	HTBDİ	BM	MNS	Roc	DL	1	----------	15.71%	15.71%	---------
OASIS	HTBDİ	BM	MNS	T-test	DL	6	71.43%	78.57%	75.00%	0.75
HASTANE	HTBDİ	BM	MNS	T-test	DL	1	----------	15.71%	15.71%	---------
OASIS	HTBDİ	BM	MNS	Wilcoxon	DL	6	71.43%	78.57%	75.00%	0.75
HASTANE	HTBDİ	BM	MNS	Wilcoxon	DL	3	----------	22.85%	22.85%	---------

Şekil 6.4'te NS GM için OASIS ve hastane validasyon setlerinde HTBDİ özellik sayısına göre doğruluk oranları, MNS BM için OASIS ve hastane validasyon setlerinde özellik sayısına göre doğruluk oranları grafik olarak verilmiştir.



Şekil 6.4. NS GM ve MNS BM için OASIS ve hastane validasyon setlerinde HTBDİ özellik sayısına göre doğruluk oranlarının çizimi

Şekil 6.4'te görüldüğü gibi hastane validasyon seti hem GM'de hem BM'de OASIS veri tabanına göre daha düşük sonuç vermiştir. OASIS setinde NS GM bhattacharya, entropi, roc, t-test, wilcoxon tabanlı özellik derecelendirmede OASIS veri tabanı 3 özellik ile %81.43 sınıflandırma doğruluğu verirken, hastane validasyon seti tüm 6 özellik ile %50.47 doğruluk oranı vermiştir. MNS BM verilerde wilcoxon tabanlı özellik derecelendirmede OASIS veri tabanı için 6 özellik en yüksek %75 doğruluk oranı verirken, hastane validasyon seti 6 özelliğin ilk 3 özelliği ile % 22.85 en yüksek doğruluk oranını vermiştir. Çizelge 6.17'de HTBDİ özellikleri için NS GM ve MNS BM için hastane ve validasyon setlerinden en yüksek sınıflandırma doğruluğunu veren özellikler verilmiştir.

Çizelge 6.17. HTBDİ özellikleri için NS GM ve MNS BM için hastane ve validasyon setlerinden en yüksek sınıflandırma doğruluğunu veren özellikler

NS GM	MNS BM
B-T-E-W-R	W
Ortalama	Basıklık
Çarpıklık	Varyans
Basıklık	Enerji
Varyans	Ortalama
Entropi	Entropi
Enerji	Çarpıklık

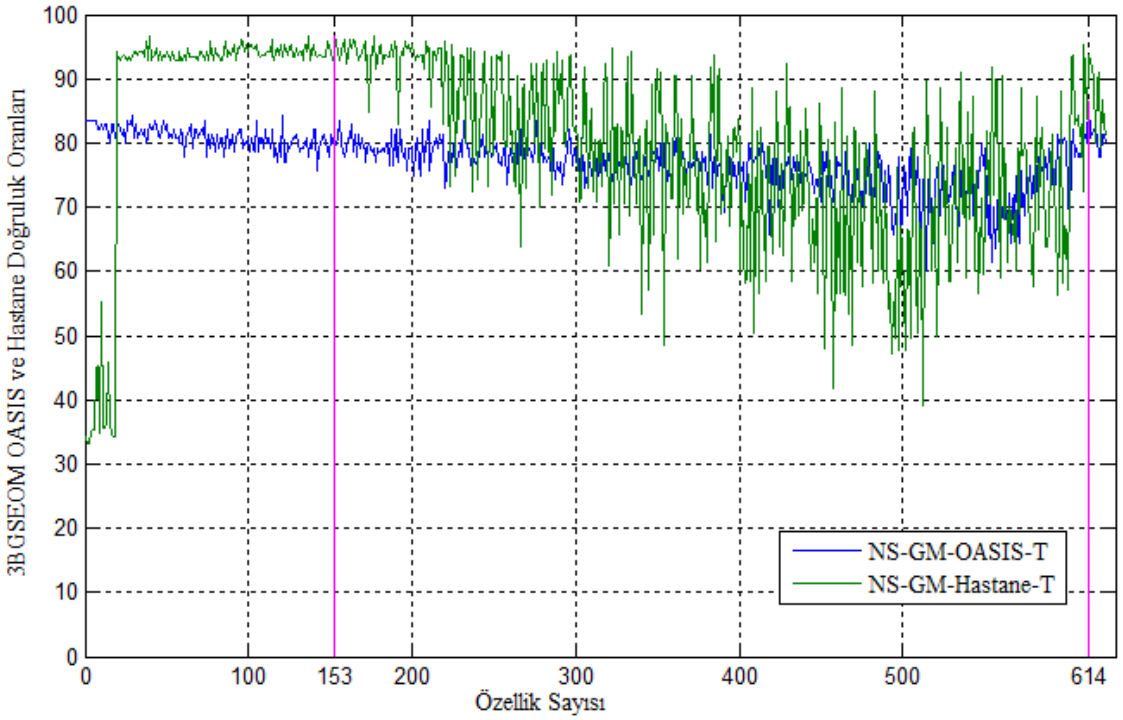
Çizelge 6.18'de GSEOM özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları verilmektedir. OASIS verilerde NS GM verilerde 614 özellik ile t-test tabanlı özellik derecelendirme de %86.43 doğruluk oranı bulunurken, hastane validasyon setinde aynı derecelendirme ile ilk 153 özellik kullanılarak % 96.66 doğruluk oranı bulunmuştur. OASIS verilerde MNS_200 BM verilerde 1 özellik ile roc tabanlı özellik derecelendirme de %76.42 doğruluk oranı bulunurken, hastane validasyon setinde roc derecelendirmede ilk 283 özellik ile % 100 doğruluk oranı bulunmuştur.

Çizelge 6.18. GSEOM özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

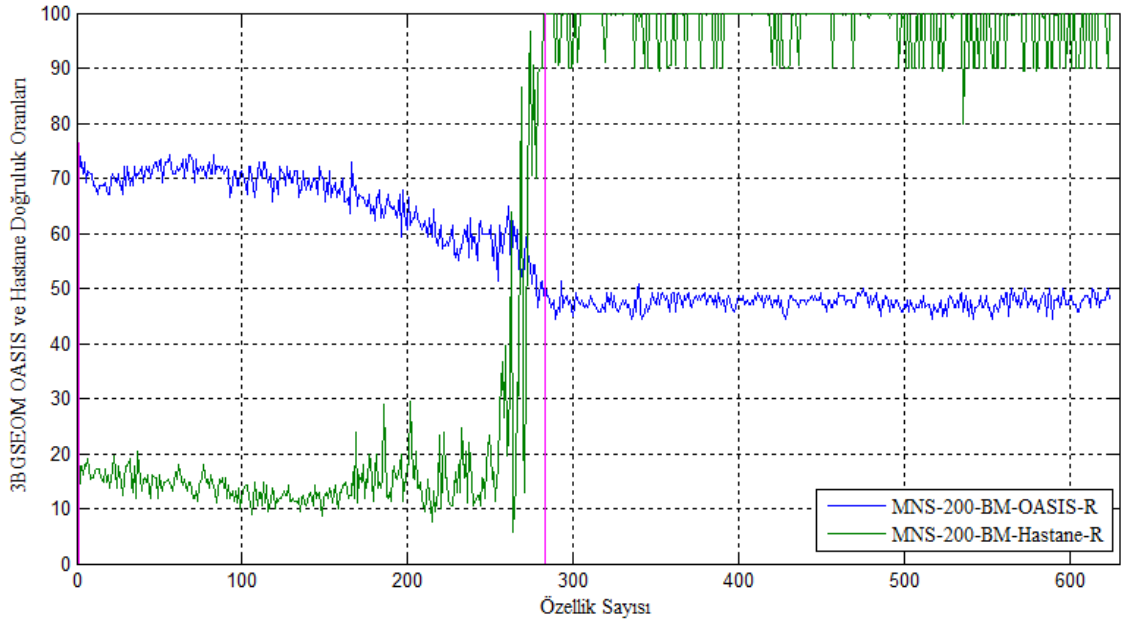
						ÖS	HA	ÖZ	DO	AUC
OASIS	3BGSEOM	NS	GM	T-test	DL	614	92.86%	80.00%	86.43%	0.864
HASTANE	3BGSEOM	NS	GM	T-test	DL	153	--------	96.66%	96.66%	---------
OASIS	3BGSEOM	MNS_200	BM	Roc	DR	1	68.71%	84.28%	76.42%	0.74
HASTANE	3BGSEOM	MNS_200	BM	Roc	DR	283	--------	%100	%100	---------

Şekil 6.5'te NS GM için OASIS ve hastane validasyon setlerinde 3B GSEOM özellik sayısına göre doğruluk oranları, Şekil 6.6'da MNS_200 BM için OASIS ve hastane validasyon setlerinde özellik sayısına göre doğruluk oranları grafik olarak verilmiştir.

EK-6 'da 3B GSEOM'de NS GM'de en yüksek sınıflandırma doğruluğunu veren 614 özellik, MNS_200 BM'de en yüksek sınıflandırma doğruluğunu veren 283 özellik verilmiştir.



Şekil 6.5. NS GM için OASIS ve hastane validasyon setlerinde 3B GSEOM özellik sayısına göre doğruluk oranları



Şekil 6.6. MNS_200 BM için OASIS ve hastane validasyon setlerinde özellik sayısına göre doğruluk oranları

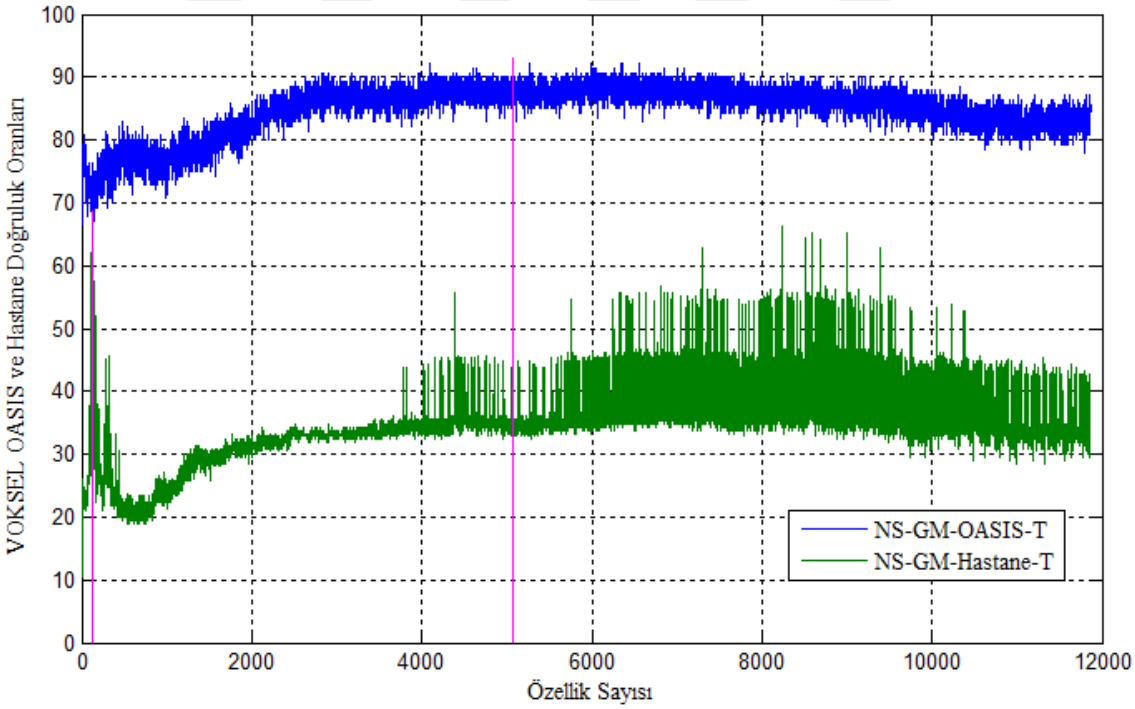
Çizelge 6.19'da voksel özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları verilmektedir. OASIS verilerde NS GM verilerde 5080 özellik ile t-test tabanlı özellik derecelendirme de

%92.86 doğruluk oranı bulunurken, hastane validasyon setinde aynı derecelendirme ile ilk 132 özellik kullanılarak % 68.57 doğruluk oranı bulunmuştur. OASIS verilerde MNS BM verilerde 19 özellik ile t-test tabanlı özellik derecelendirme de %79.29 doğruluk oranı bulunurken, hastane validasyon setinde t-test derecelendimede ilk 157 özellik ile % 70.47 doğruluk oranı bulunmuştur.

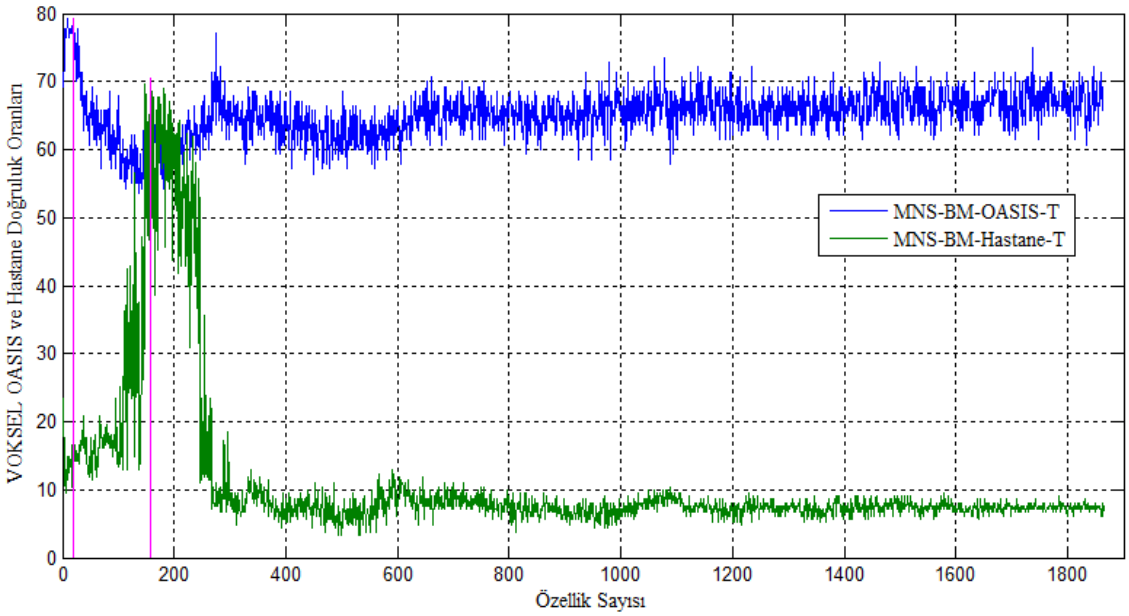
Çizelge 6.19. Voksel özelliklerinin OASIS veritabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

						ÖS	HA	ÖZ	DO	AUC
OASIS	Voksel	NS	GM	T-test	DL	5080	92.86%	92.86%	92.86%	0.929
HASTANE	Voksel	NS	GM	T-test	DL	132	--------	68.57%	68.57%	---------
OASIS	Voksel	MNS	BM	T-test	DL	19	77.14%	81.43%	79.29%	0.793
HASTANE	Voksel	MNS	BM	T-test	DL	157	--------	70.47%	70.47%	---------

Şekil 6.7'de NS GM için OASIS ve hastane validasyon setlerinde Voksel özellik sayısına göre doğruluk oranları, Şekil 6.8'de MNS BM için OASIS ve hastane validasyon setlerinde özellik sayısına göre doğruluk oranları grafik olarak verilmiştir.



Şekil 6.7. NS GM için OASIS ve hastane validasyon setlerinde voksel özellik sayısına göre doğruluk oranları



Şekil 6.8. MNS BM için OASIS ve hastane validasyon setlerinde voksel özellik sayısına göre doğruluk oranları

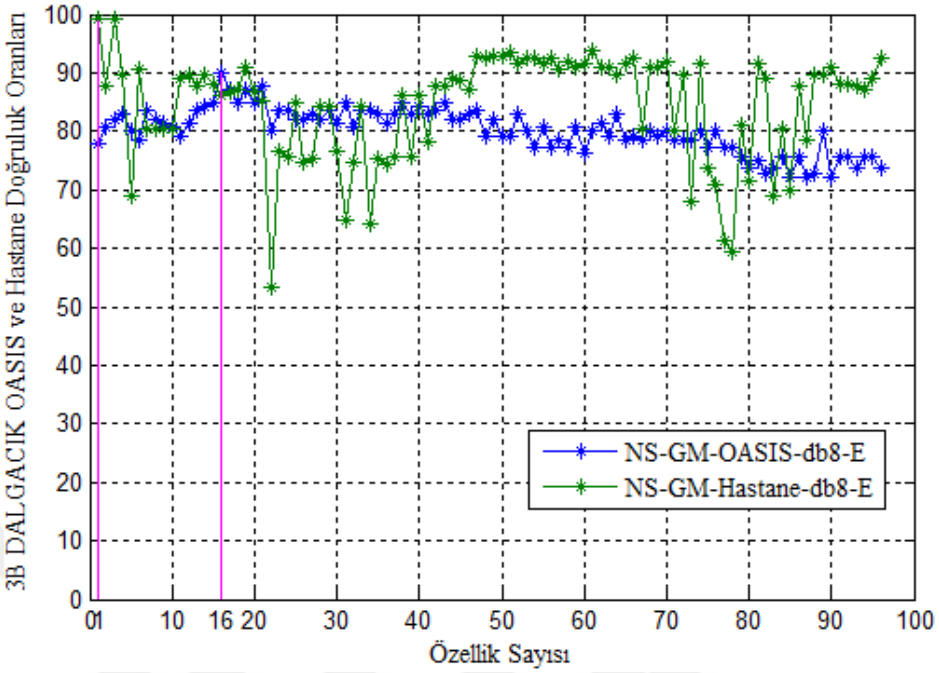
Çizelge 6.20'de 3B Ayrık Dalgacık Dönüşümü özelliklerinin OASIS veri tabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları verilmektedir. OASIS verilerde NS GM verilerde db8 dalgacık ve 16 özellik ile entropi tabanlı özellik derecelendirme de %90.00 doğruluk oranı bulunurken, hastane validasyon setinde aynı derecelendirme ile birinci özellik kullanılarak % 99.04 doğruluk oranı bulunmuştur. OASIS verilerde NS_200 BM verilerde bior1.3 dalgacık ve 6 özellik ile bhattacharrya tabanlı özellik derecelendirme de %82.10 doğruluk oranı bulunurken, hastane validasyon setinde ile bhattacharrya derecelendimede ilk 74 özellik ile % 75.71 doğruluk oranı bulunmuştur.

Çizelge 6.20. 3B Dalgacık özelliklerinin OASIS veritabanı ile en iyi sınıflandırma modelleri ve hastane validasyon seti için doğruluk oranları

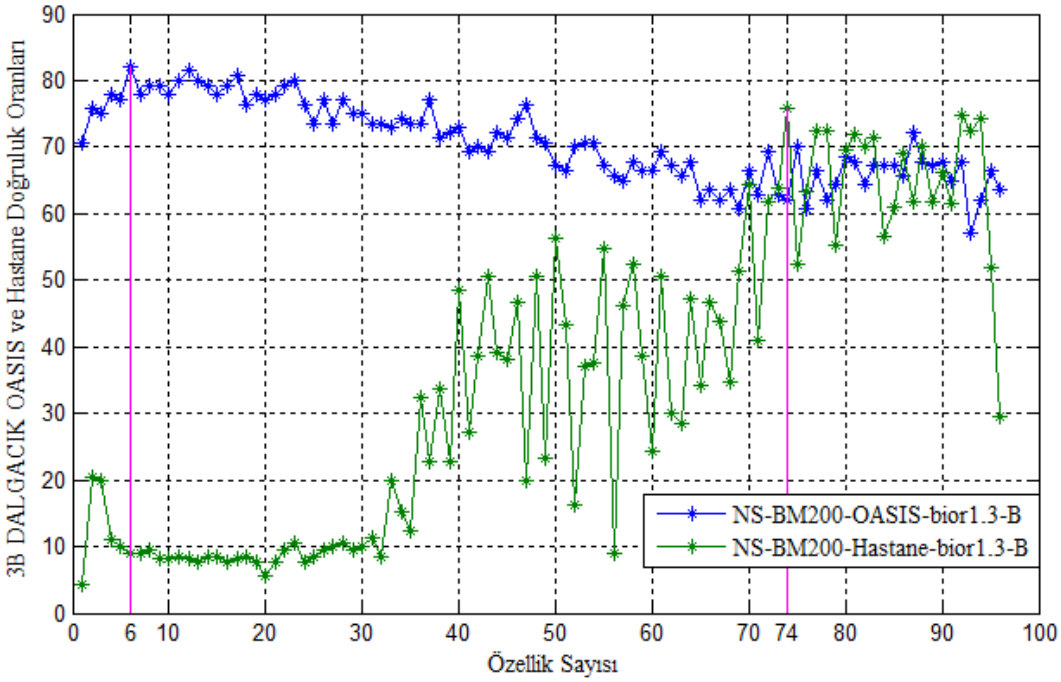
							ÖS	HA	ÖZ	DO	AUC
OASIS	3B Dalgacık	NS	NS GM	db8	bhattacharya	DL	16	92.90%	87.10%	90.00%	0.9
HASTANE	3B Dalgacık	NS	NS GM	db8	bhattacharya	DL	47	--------	93.33%	93.33%	---------
OASIS	3B Dalgacık	NS	NS GM	db8	entropi	DL	16	92.90%	87.10%	90.00%	0.864
HASTANE	3B Dalgacık	NS	NS GM	db8	entropi	DL	1	--------	99.04%	99.04%	---------
OASIS	3B Dalgacık	NS	NS GM	db8	roc	DL	16	92.90%	87.10%	90.00%	0.864
HASTANE	3B Dalgacık	NS	NS GM	db8	roc	DL	9	--------	94.28%	94.28%	---------
OASIS	3B Dalgacık	NS	BM_200	bior1.3	bhattacharya	DL	6	81.40%	82.90%	82.10%	0.82
HASTANE	3B Dalgacık	NS	BM_200	bior1.3	bhattacharya	DL	74	--------	75.71%	75.71%	---------

Şekil 6.9'da NS GM için OASIS ve hastane validasyon setlerinde db8 dalgacık özellik sayısına göre doğruluk oranları, Şekil 6.10'da NS BM_200 için OASIS ve

hastane validasyon setlerinde bior1.3 özellik sayısına göre doğruluk oranları grafik olarak verilmiştir.



Şekil 6.9. NS GM için OASIS ve hastane validasyon setlerinde db8 dalgacık özellik sayısına göre doğruluk oranları



Şekil 6.10. NS BM_200 için OASIS ve hastane validasyon setlerinde bior1.3 özellik sayısına göre doğruluk oranları

Çizelge 6.21'de 3B Ayrık Dalgacık Dönüşümü özellikleri için en yüksek doğruluk oranlarını veren özellikler hem GM hem de BM için sıralanmıştır.

Çizelge 6.21. 3B Dalgacık özellikleri için en yüksek doğruluk oranlarını veren özellikler

GM		BM					
1	LHH_Varyans	1	LHL2_Basıklık	26	HHL_Basıklık	51	LHH2_Basıklık
2	LLL_Basıklık	2	LHL2_Ortalama	27	LLL_Entropi	52	LHL2_Enerji
3	LLL_Çarpıklık	3	LHL2_Çarpıklık	28	LHH2_Varyans	53	LLL2_Entropi
4	LLL2_Ortalama	4	HHH_Enerji	29	LHL_Enerji	54	LHL2_Entropi
5	HHL_Basıklık	5	HHH_Entropi	30	LHL2_Varyans	55	HHH2_Entropi
6	LLL2_Basıklık	6	LLH_Varyans	31	HHH2_Basıklık	56	LHH2_Çarpıklık
7	LLL_Ortalama	7	HHL2_Varyans	32	LHL_Entropi	57	LLL2_Enerji
8	LLL2_Varyans	8	HLH_Enerji	33	LHH_Varyans	58	HHL_Çarpıklık
9	HLH_Varyans	9	LLH_Enerji	34	HLH2_Basıklık	59	HHH2_Enerji
10	LLL_Varyans	10	HHH_Çarpıklık	35	LLL_Basıklık	60	HLH_Basıklık
11	HHH_Varyans	11	HLH_Entropi	36	LHH2_Ortalama	61	HLH2_Varyans
12	LHL2_Basıklık	12	LHH_Enerji	37	LLL_Çarpıklık	62	LLL2_Çarpıklık
13	HHL_Varyans	13	LLL2_Varyans	38	HHL_Varyans	63	LHH2_Entropi
14	LLH2_Varyans	14	LLL2_Ortalama	39	LLH2_Varyans	64	LHH2_Enerji
15	LLL2_Çarpıklık	15	LLH_Entropi	40	HHH_Varyans	65	HHH_Basıklık
16	LLH_Varyans	16	LLL_Ortalama	41	HLL2_Basıklık	66	LLH_Basıklık
		17	LLL_Varyans	42	LLL2_Basıklık	67	HLL_Varyans
		18	LHH_Entropi	43	LLH2_Basıklık	68	HLH2_Entropi
		19	HHL_Enerji	44	HLL2_Varyans	69	HHH2_Varyans
		20	LHH_Basıklık	45	HHL2_Enerji	70	LHL_Basıklık
		21	HLL_Enerji	46	HHL2_Entropi	71	HLH2_Enerji
		22	HHL_Entropi	47	HLH_Varyans	72	HHH_Ortalama
		23	HLL_Entropi	48	HLL_Basıklık	73	LLH2_Entropi
		24	LHL_Varyans	49	HLL2_Enerji	74	LLH2_Enerji
		25	LLL_Enerji	50	HLL2_Entropi		

Sonuçlar genel olarak değerlendirildiğinde OASIS verilerinin çapraz geçerleme ile yapmış olduğu en yüksek doğruluktaki eğitimde hastane validasyon seti farklı bir doğruluk oranı göstermektedir. Aynı zamanda OASIS veri tabanı ile en yüksek sınıflandırma doğruluğunu veren veri kümesi özellikleri ile hastane verilerinin validasyonunda aynı veri kümesinin farklı özellik sayısının, en yüksek sınıflandırma doğruluğunu verdiği görülmektedir. Bu sonuçlar OASIS veri tabanı özelliklerinin eğitiminde elde edilen özelliklerin hastane validasyon seti özelliklerini kapsadığı ancak farklı özellik sayısı ile hastalığı karakterize ettiğini göstermektedir. Literatürde genel olarak yapılan MR sınıflandırma çalışmalarında aynı veri kümesi içerisinde eğitim ve test işlemleri gerçekleştirilmekte, farklı protokol ile alınmış verilerin validasyon seti ile sistemin daha önce görmediği verileri sınıflandırma performansları göz ardı edilmektedir (Savio ve Graña, 2013b; Aggarwal ve ark., 2015a; Beheshti ve ark., 2016a; Beheshti ve ark., 2016b; Beheshti ve ark., 2017). MR görüntülerinin sınıflandırılması harici diğer örüntü sınıflandırma çalışmalarında ise kendi içerisinde homojen özellikli veri kümesi eğitim, test ve validasyon seti olarak üçe ayrılmaktadır (Anonim, 2017i). Böylece homojen veri kümesindeki validasyon işlemi aynı veri setindeki homojen dağılımdan dolayı kabul edilebilir seviyelerde doğruluk oranı vermektedir. Literatürdeki bu bilgiler ışığında kendi içerisindeki homojen veri kümesi ile eğitim işlemi gerçekleştirip, farklı protokollerde ve farklı evrelerde alınan veri kümesi ile validasyon işlemi sonuçlarının değerlendirilmesi halen araştırılması gereken bir konudur. Bu problemin sonuçlarını yapısal MR görüntülerinde değerlendirmek için ise literatürde yapılan tek çalışma MICCAI 2014 konferansı altında gerçekleştirilen CADDemantia yarışmasıdır. Farklı merkezlerden farklı protokoller ile alınmış verilerin eğitim ve test işlemleri standart veri kümeleri üzerinden değerlendirilmiştir. Bu yarışma sonucunda en yüksek doğruluk oranı %63.0 olarak kabul edilebilir seviye de bulunmamış, çalışmaların devam etmesi gerektiği belirtilmiştir (Bron ve ark., 2015).Tez çalışmasında farklı merkezlerden farklı protokol ile alınan verilerin sınıflandırılmasına farklı bir açıdan yaklaşılmıştır. Uluslararası güvenilirliği kabul edilmiş OASIS veri tabanı ile kendi içerisinde yapılan özellik çıkarma modellerindeki veri kümeleri ile özellik derecelendirme işlemi yapıldıktan sonra çapraz geçerleme kullanarak sınıflandırma işlemi yapılmıştır. OASIS veri tabanında en iyi özellik çıkarma ve sınıflandırma modelleri bulunarak çapraz geçerlemedeki eğitim kısmı sabit tutulmuş ve hastane validasyon seti test verisi olarak sisteme verilmiştir. Böylece eğitim kısmı sabit tutulan OASIS veri tabanı test kümesi ile hastane validasyon setinin kaç özellikle ne kadar

sınıflandırma doğruluğu verdiği belirlenmiştir. Bu şekilde özellik sayısına göre test doğruluk sonuçlarının ve validasyon doğruluk sonuçlarının davranışı izlenmiştir. Sonuç olarak özellik sayısına göre test ve validasyon doğruluk oranları aynı özellik sayısında farklı doğruluk oranları gösterdiği görülmektedir. Bu sonuçlar veri tabanında hastalığı karakterize eden özelliklerin hastane validasyon setinde farklı bir özellik sayısında hastalığı tahmin ettiğini göstermektedir. OASIS veri tabanı hasta verilerinin KDR ortalama değeri 0.69 iken hastane verilerinin ortalama KDR değeri 2.1'dir. OASIS verilerinin ortalama KDR değeri Hafif Bilişsel Bozulma ile Hafif Evre AH arasında iken, hastane verilerinin ortalama KDR değeri Orta Evre AH ile Ağır Evre arasındadır. Dolayısıyla evre ortalamalarının farklı olduğu veri kümelerinde sınıflandırma doğruluk oranlarının aynı özellik sayısında aynı olmasını beklemek anlamsızdır. Hafif bilişsel bozulma ile hafif evre arasında elde edilen özelliklerin orta ve ağır evre arasındaki değişimleri yüksek doğrulukta sınıflandırabildiği bu tezin ortaya koyduğu yeni çıktılarından biridir.

OASIS ve hastane validasyon setlerinin doğruluk oranlarının karşılaştırılmasında genel sonuçlar şu şekildedir:

1)Global hacim veri kümesi için OASIS veri tabanı AH ve NK sınıflandırmasında %70.71 doğruluk oranını bir özellik ile verirken, aynı eğitim setinde hastane validasyon seti 2 özellik ile %100 sınıflandırma doğruluğu vermektedir. Hastane verilerinin evre ortalaması orta ve ağır evre arasında olduğu için dejenerasyon OASIS veri tabanındaki verilerden daha fazladır. Dolayısıyla hastane validasyon seti global hacim dejenerasyonu daha az olan OASIS veri tabanına göre daha yüksek doğruluk oranı vermektedir.

2)Lokal hacim veri kümesi için OASIS veri tabanı AH ve NK sınıflandırmasında %95 doğruluk oranını AAL/TBH veri kümesinde 107 özellik ile verirken, aynı eğitim setinde hastane validasyon seti ilk 39 özellik ile %98.57 sınıflandırma doğruluğu vermektedir. Hastane verilerinde evre ortalamalarının ağır evreye yakın olmasından dolayı lokal hacimlerdeki kayıplar daha fazladır. Dolayısıyla OASIS veri tabanı ile eğitilen sistem, hastane validasyon setinde daha az özellik ile daha yüksek sınıflandırma doğruluğu vermektedir.

3)Tez çalışmasında ilk defa önerilen simetri analizi ile, OASIS veritabanı ile yapılan GM simetri sınıflandırmada ilk 9 özellik %100 sonuç verirken, aynı eğitim setinde hastane validasyon seti ilk 5 özellik ile %100 sınıflandırma doğruluğu vermektedir. BM simetri sınıflandırmada ilk 5 özellik %65 sonuç verirken, aynı eğitim

setinde hastane validasyon seti ilk 1 özellik ile %100 sınıflandırma doğruluğu vermektedir. AH'nin ilerlemesinde en dikkat çeken biyoişaretçilerden bir tanesi simetri bozulmasıdır. Bu bozulmayı katsayılar ile tanımlayan simetri özellikleri hastane validasyon seti için yüksek sonuçlar vermiştir. Bu sonuçlarda hastalığın başlangıcından itibaren ilerlemesinde GM'de meydana gelen simetri bozulmasının etkili bir biyoişaretçi olduğunu göstermektedir. BM'de simetri katsayılarının hastalığın başlangıcında ayırıcı tanı için yeterli olmadığı, ancak ileri evrelerde ayırıcı tanı için sınıflandırmada çok iyi sonuç verdiği görülmektedir.

4)HTBDİ verileri için NS GM VOI bölgede OASIS verileri için %81.43 sınıflandırma doğruluğu elde edilirken, hastane validasyon setinde %50.47sınıflandırma doğruluğu elde edilmektedir. MNS BM verilerde ise OASIS verileri %75 doğruluk oranı gösterirken, hastane validasyon seti en yüksek %22.85 doğruluk oranı göstermiştir. Hem GM hem BM'de hastane validasyon seti düşük değerler vermiştir. OASIS veri tabanının hem GM'de hem BM'de tez çalışmasında kullanılan diğer doku analizi tekniklerine göre daha düşük doğruluk oranları vermiştir. Dolayısıyla HTBDİ özellikleri hastalığın ayırt edici tanısına etkin rol oynamadığı görülmektedir.

5)Voksel özellikleri için NS GM VOI bölgelerde OASIS verileri için %92.86 sınıflandırma doğruluğu elde edilirken, hastane validasyon setinde %68.57 sınıflandırma doğruluğu elde edilmektedir. MNS BM verilerde ise OASIS verileri %79.29 doğruluk oranı gösterirken, hastane validasyon seti en yüksek %70.47 doğruluk oranı göstermiştir. Hem GM hem BM'de hastane validasyon seti düşük değerler vermiştir. OASIS veri tabanında GM sınıflandırmada voksel özellikleri erken evrenin normalden ayrılmasında etkili sonuç verirken, KDR ortalaması orta evre ile ağır evre arasında olan hastane validasyon seti için iyi sonuç vermemektedir.

6)3B GSEOM özellikleri için NS GM VOI bölgelerde OASIS verileri için %86.43 sınıflandırma doğruluğu elde edilirken, hastane validasyon setinde %96.66 sınıflandırma doğruluğu elde edilmektedir. MNS_200 BM verilerde ise OASIS verileri %76.42 doğruluk oranı gösterirken, hastane validasyon seti en yüksek %100 doğruluk oranı göstermiştir. Hem GM'de hem de BM görüntülerde hastane validasyon verileri yüksek doğruluk oranları vermiştir.

7)3B dalgacık özellikleri için NS GM VOI bölgelerde db8 dalgacık OASIS verileri için %90.00 sınıflandırma doğruluğu elde edilirken, hastane validasyon setinde %99.04 sınıflandırma doğruluğu elde edilmektedir. NS_200 BM verilerde ise OASIS verileri %82.10 doğruluk oranı gösterirken, hastane validasyon seti en yüksek %75.71

doğruluk oranı göstermiştir. GM görüntülerde hastane validasyon seti yüksek sonuç verirken BM verilerde düşük sonuç vermiştir.

8)Özellik derecelendirme yöntemi genel olarak tüm sınıflandırma çerçevelerinde sınıflandırma doğruluğunu arttıran bir etken olmuştur. Ancak her kümesinin kendi içerisine veri dağılım karakteristiğinin farklı olmasından dolayı farklı özellik derecelendirme kriterleri yüksek doğruluk oranları vermiştir.

9)DVM-lineer sınıflandırıcı, DVM-rbf sınıflandırıcıya göre BM 3BGSEOM ve BM Simetri özellikleri dışında daha iyi sonuç vermiştir. Bu sonuçlarda DVM-lineer sınıflandırıcının nörolojik data analizlerinde verileri daha yüksek doğrulukla ayırdığını göstermektedir.

7. SONUÇLAR VE ÖNERİLER

7.1. Sonuçlar

Bu tez çalışmasında 3B beyin MR görüntülerinden elde edilen çok değişkenli özellikler kullanılarak AH ve NK gruplarının sınıflandırılmasında yeni yaklaşımlar önerilmiştir. Önerilen çerçeveler ile OASIS veri kümesinde en yüksek doğruluk oranlarını veren yaklaşımlar belirlenerek farklı protokol ve evre ortalaması ile alınan hastane validasyon setinde tahmin yapılmıştır.

3B yapısal beyin MR görüntülerinin analizi tıbbi görüntüler içerisinde son derece zor olan bir görüntüdür. MR görüntülerinin hastane ortamında analizleri ve yorumlamaları manuel bir şekilde yapılmakta olup sayısal kaynakların kullanımı son derece azdır. Sayısal yöntemlerin kullanımında ise kafa büyüklüğünden kaynaklı görüntü büyüklüklerinin farklılıkları, gürültü, beyin dışı yapılar, çekim protokollerinin farklılığı, kesit kalınlığı, kesit boyutu, çekim esnasında hasta hareketi, normalizasyon, segmentasyon, görüntüde artefaktlar gibi birçok problemi barındırmaktadır. Tez çalışmasında öncelikle bu problemlerin aşılabilmesi için detaylı bir literatür taraması yapılmıştır. Literatürde kullanılan Freesurfer, FSL, MRIcro ve SPM gibi popüler programlarda analizlerin nasıl yapıldığı, hangi önişleme yöntemlerinin hangi araçlarla nasıl kullanıldığı detaylı bir şekilde incelenmiştir. Freesurfer programında bir MR görüntüsünün analiz için çok süre alması ve FSL programının sadece 15 subkortikal bölgenin segmentasyonunu yapması dezavantaj oluşturduğu için tercih edilmemiştir. MRIcro ve SPM programının araçları ile eksen dönüştürme, görüntü reoryantasyonu, gürültü giderme normalizasyon, segmentasyon, modülasyon, beyin dışı yapıların atılması, yumuşatma, birlikte çakıştırma gibi önişlemeler yapılmıştır.

Veri kümesi 70 AH ve 70 NK olmak üzere OASIS veri tabanından ve validasyon seti olarak 21 AH Selçuk Üniversitesi Tıp Fakültesi veri tabanından elde edilmiştir. OASIS verilerinde önişlemelerden sonra SPM programı altında çalışan VBM8 kütüphanesi ile hem modülasyonlu normalize hem de modülasyonsuz normalize görüntüler olmak üzere GM, BM ve BOS görüntüleri elde edilmiştir. Bu işlemden sonra VBM8 kütüphanesi altında bulunan kovaryans analizi ile görüntülerdeki segmentasyon işleminin kalite kontrolü yapılmıştır. Yanlış segmentasyon işleminden dolayı aykırı değer gösteren veriler çalışmadan çıkarılmıştır. 65 yaş AH için bir risk faktörü olup bu yaş ve üzerindeki veriler OASIS veri tabanından alınarak toplam yaş dağılımının

normal dağılıma uyup uymadığı test edilmiştir. Aynı zamanda iki grup arasındaki yaş dağılımında anlamlı bir fark olup olmadığı bağımsız örneklem t-testi ile analiz edilmiştir. Hem kalite kontrol aracı sonrası hem de yaş analizlerinden sonra OASIS veri tabanından 70 AH ve 70 NK veri kümesi oluşturulmuştur. Validasyon seti olarak hastane verilerinin kullanılması için Selçuk Üniversitesi Tıp Fakültesi Etik Kurulu'na başvuru yapılmıştır. Nöroloji Anabilim Dalına gelen AH'ler diğer demans nedenleri dışlandıktan sonra Washington Üniversitesi tarafından hazırlanan Türkçe Klinik Demans Derecelendirme nöropsikolojik testi ile hangi evrede oldukları skorlanmıştır. Evre skoru alan hastalar MR çekimi için Radyoloji Anabilim Dalına yönlendirilmiştir. Tıp Fakültesi'nde rutin alınan MR verileri 5mm-6.5mm arasında olup kesit aralarında 1mm-2mm arasında boşluk bırakılarak çekilmektedir. Aynı zamanda ihtiyaca göre belli kesitler alınarak tüm beyin görüntüsü alınmamaktadır. Bunun sebebi çekim için çok fazla sırada bekleyen hasta olmasından kaynaklı zaman problemi ve en az kesit sayısı ile yeterli raporlamanın sağlanması için süreden kazanımdır. Ancak bu veriler sayısal yöntemlerin ve programların kullanımı için yeterli değildir. Tıp Fakültesi Radyoloji bölümünden OASIS veri tabanı protokolleri ile aynı olacak şekilde ince kesitli ve tüm beyni kapsayan 3B volümetrik MP-RAGE uzantılı görüntüler istenmiştir. Ancak hastane MR cihaz kabiliyeti ve modelinin farklı olması, radyoloji teknikerlerinin daha önce bu tarz çekimler yapmamış olması, görüntülerin MP-RAGE uzantılı, ince kesit, boşluksuz, tüm beyni kapsayan, volümetrik görüntüler olmasına rağmen diğer çekim protokolleri farklı değerlerde alınmıştır. Dolayısıyla OASIS veri tabanı ile hastane verilerinin birtakım parametreleri farklı şekilde alınmış olup heterojen bir veri yapısı meydana gelmiştir. Literatürde bu tarz çalışmalara çoklu merkez (*multi-center*) çalışmalar denilmektedir. Bu tarz çalışmalardaki yaklaşımlar literatürde az miktarda olup tez kapsamında hangi yöntemlerin nasıl kullanıldığı detaylı bir şekilde incelenmiştir.

OASIS veri tabanından alınan görüntüler gerekli önişlemeler ve segmentasyon yapıldıktan sonra AH'de temel öznitelikler olarak belirlenen hacim, simetri ve doku analizi başlıkları altında yeni yaklaşımlar ortaya konulmuştur. Hacim analizleri lokal ve global olmak üzere iki başlık altında incelenmiştir. Global hacimler GM, BM, BOS, TBH, PRNKM, LV hacmi olmak üzere altı bölgeden oluşmakta olup, bu bölgelerin farklı kombinasyonlarının oranlanması ile 26 metrik elde edilmiştir. Lokal Hacimler için MATLAB tabanlı WFU Pick Atlas ile AAL ve TD Lob maskeleri kullanılmış olup beyinde 127 bölgenin bölgenin hacmi *ml* cinsinden hesaplanmıştır. AAL ile 116 bölge

ve TD lob ile 11 bölgenin hacmi hesaplanarak bu bölgelerin, GM, PRNKM ve TBH oranları ile sekiz farklı senaryoda özellik kümeleri oluşturulmuştur. Simetri analizi için normalize görüntülerde orta sagittal düzlem bulunarak görüntüler tam ortadan ikiye ayrılmıştır. İkiye bölünen görüntüden sağ yarımküre sol yarımküreye aynalanarak siyah bölgeler atılmıştır. Sağ ve sol yarım kürelerin PSNR ve SSIM katsayıları bir MR görüntüsü için tüm kesitlerde hesaplanarak ortalaması alınmıştır. Simetri analizinde diğer bir yaklaşım aynalanan görüntülerin bir vektör haline dönüştürülerek istatistiksel uzaklık ve yakınlık katsayılarının bulunmasıdır. Bir MR görüntüsünde her bir kesit için istatistiksel özellikler elde edilerek tüm kesitler için ortalama alınmıştır. Dolayısıyla her bir MR görüntüsü için 11 adet simetri katsayısı bulunmuştur. Doku analizi için HTBDİ, voksel örüntüleri, 3B Dalgacık ve 3B GSEOM kullanılmıştır. MR görüntüleri üç boyutlu olduğu ve çok fazla veri olduğu için tüm bir yığına bu yöntemler uygulanmamıştır. Üç boyutlu MR görüntülerinde gruplar arası hacimsel kayıpları haritalayan Voksel Tabanlı Morfometri işlemi ile hastalığın etkilediği bölgeler bulunmuştur. Bu bölgeler bir binary maske haline getirilerek ilgili görüntülerde maskeleme işlemi yapılmıştır. Böylece tüm görüntü ile uğraşmak yerine sadece hastalığın etkilediği bölgelerde doku analizi işlemi yapılmıştır. Voksel Tabanlı Morfometri yöntemi modülasyonlu GM, BM görüntülerde ve modülasyon yapılmamış konsantrasyonu korunmuş GM, BM görüntülerde ayrı ayrı yapılmıştır. Literatürde VTM ile yapılan analizlerde kaç voksel değerinin anlamlı olarak alınacağına dair eşik değeri farklı bir şekilde alınmaktadır. Eşik değeri almanın sonuca etkisini araştırmak için 200 voksel üzeri kümeleri anlamlı kabul eden maskeler modülasyonlu ve modülasyonsuz görüntüler için alınmıştır. Böylece sekiz farklı senaryoda maskeler üretilmiştir. Bu senaryoların amacı modülasyonlu görüntüler mi yoksa konsantrasyonu koruyan modülasyonsuz görüntülerin mi daha iyi sonuç verdiğinin araştırılmasıdır. Aynı zamanda 200 voksel eşik değerinin sınıflandırma sonuçlarına etkisi analiz edilmiştir. Sekiz farklı maskeler ile elde edilen segmente edilmiş görüntülerden sırasıyla HTBDİ, voksel değerleri, 3B GSEOM, 3B ADD ile özellikler çıkarılmıştır. Özellikler, özellik derecelendirme yöntemi ile bhattacharya, roc, wilcoxon, t-test, entropi kriterlerine göre en iyi özellikten en kötü özelliğe doğru sıralanmıştır. Sıralanan özellikler sırayla birleştirilerek DVM-lineer ve DVM-rbf sınıflandırıcıya on kat çapraz geçerleme yapılarak verilmiştir. Her bir veri kümesinden on kat çaprazlama sonucu elde edilen doğruluk, özgüllük, hassasiyet ve AUC performans kriterlerinin ortalaması alınmıştır. Tüm bu denemeler sonucunda hacimsel, simetri ve doku analizi değerlendirmelerinden

hangi modellerin en yüksek sonuçları verdiği belirlenmiştir. Hastane verilerinin validasyon seti olarak kullanılması için aynı yöntemler ile özellik kümeleri belirlenmiştir. Bu kümeler OASIS veri tabanı ile aynı özellik derecelendirme sıralamasına göre sıralandırılmıştır. Hastane verilerinin normalizasyona gerekli olduğu durumlarda OASIS ile elde edilen özelliklerin lineer regresyon ile analizleri yapılarak birinci dereceden bir denklem elde edilmiş olup bu denklem ile hastane verilerinin hangi aralığa denk geldiği bulunmuştur. Bu işlemden sonra OASIS veri tabanının sınıflandırılmasında en yüksek doğruluk sonucunu veren sınıflandırma modelleri tekrar çalıştırılarak hastane validasyon setleri on çapraz geçerlemenin yapıldığı test verisi olarak sisteme verilmiştir. Böylece OASIS veri tabanının en yüksek sınıflandırma doğruluğunu verdiği eğitimden hastane validasyon setlerinin sınıfları tahmin edilmiştir.

Hacimsel özelliklerin sınıflandırma çalışmalarında kullanımı validasyon setlerinde yüksek doğruluk oranı vermektedir. OASIS verilerinin evre ortalamalarının hastalığın başlangıcında olması elde edilen lokal hacimsel özelliklerin erken evre tahminde etkin rol oynadığı görülmektedir. Ancak global hacimlerin erken evre tahminde yeterli olmadığı ve lokal değişimlerin daha ayırıcı özellikler olduğu belirlenmiştir. Burada elde edilen özelliklerin eğitim sınıflandırma modellerinde orta evre üzeri ortalaması olan ve sistemin daha önce görmediği farklı protokol ile alınmış hastane validasyon setinde yüksek sınıflandırma tahmini yapıldığı görülmektedir. DARTEL normalizasyon ile protokolden kaynaklı farklılığın normalize uzayda düzeltilmesi ve sınıflandırma sisteminin daha önce görmediği validasyon seti ile sınıflandırma sonuçlarının değerlendirilmesi yeni bir yaklaşım olarak incelenmiştir.

3B yapısal MR görüntülerinin simetri bozulmalarının sayısal yöntemler ile modellenmesinin problemli olduğu ve bu alanda çalışmaların devam etmesi gerektiği belirtilmektedir. Tez çalışmasında simetri bozulmasının modellenmesi için yeni bir teknik önerilmiştir. GM simetri bozulmasını temsil eden özellikler hem OASIS verisinde hem de hastane validasyon setinde %100 doğruluk oranı vermektedir. BM görüntülerde ise OASIS verilerinde %65 doğruluk oranı elde edilirken hastane validasyon setinde %100 doğruluk oranı vermektedir. Bu sonuçlar GM bölgesinde erken evrelerde başlayan simetri bozulmaları ayırıcı tanıya yardımcı olduğu gibi hastalığın ileri evrelerinde de ayırıcı tanıya yardımcı olduğunu göstermektedir. BM görüntülerde başlangıç evrelerinde ayırıcı tanı için yeterli doğruluk oranları vermezken ileri evreler için yüksek doğruluk oranı vermiştir. Bu tanımlama ve sınıflandırmalar ile

3B yapısal beyin MR görüntülerinde tez kapsamında önerilen yöntem ile simetri değişiminin modellenmesi ve sınıflandırılması literatürde ilk defa sunulmaktadır.

AH ve NK verilerde VTM yöntemi ile hacimsel kayıpların bulunup maskelerle ilgili bölge analizi yapan çalışma sayısı çok azdır. Maske altında kalan bölgelerden istatistiksel özellikler ve ham voksel değerlerinin sınıflandırılması literatürde yapılan iki çalışma türüdür. Ancak ilgili bölgelerden HTBDİ ile yapılan çalışma olmadığı gibi voksel değerlerinin direkt olarak sınıflandırılması ile alakalı GM modülasyonlu normalize görüntüleri kullanan çalışmalar bulunmaktadır. Tez çalışmasında hem konsantrasyonu korunmuş normalize GM, NS hem de hacmi korunmuş modülasyonlu normalize GM, BM görüntüler için ayrı ayrı hacim kayıp maskeleri oluşturulmuştur. Aynı zamanda lokalizasyon işlemlerinde sıklıkla kullanılan eşik değeri maske oluşturmada 200 voksel kümesi eşik değerleri ile deneme yapılarak dört maske daha oluşturulmuştur. Bu maskeler ile ilgili bölgeler kesilerek sekiz farklı küme elde edilmiştir. MNS GM, BM ve NS GM, BM veriler ve bunların 200 eşik değeri alınmış kümeleri sınıflandırma için kullanılarak hangi modalitenin daha iyi sonuç vereceği gözlemlenmiştir. HTBDİ ve voksel değerlerinin direkt olarak sınıflandırılmasında hastane validasyon setleri düşük sonuçlar vermektedir. Hastane setlerinde de OASIS verileri için elde edilen hacim kayıp maskeleri kullanılmıştır. HTBDİ için maske altında kalan voksel değerlerinin histogram tabanlı istatistiksel özellikleri, voksel değerleri için ise kayıp maskesi altında kalan voksellerin koordinatsal değerleri özellik olarak alınmaktadır. Hastane validasyon setleri KDR evre ortalaması orta ve ağır evre arasında olduğu için hacim kayıplarının olduğu bölgelerin OASIS veri tabanından elde edilen maskelerden daha geniş olacağı aşikardır. Dolayısıyla voksel komşuluk özelliklerinin dikkate alınmadığı bu iki özellik kümesi için OASIS veri tabanı ile oluşturulan maskelerin yeterli olmadığı görülmektedir. 3B Dalgacık ve 3B GSEOM için maske altında kalan bölgelerde voksel komşuluklarına bakılarak analiz yapılmaktadır. Her iki yöntemin GM özelliklerinde hastane validasyon seti doğruluk oranları net bir şekilde artmış, BM özelliklerde 3B GSEOM yüksek sonuç verirken 3B dalgacık düşük sonuç vermektedir. VTM maskeleri ile dokunun değiştiği bölgelerin keskin sınırları belirlenerek bu bölgelerden 3B GSEOM ve 3B Dalgacık özellik kümesi ile sınıflandırma denemeleri yapan literatürde herhangi bir çalışma bulunmamaktadır. Bu iki yöntem de voksel komşuluklarından yola çıkarak özellik oluşturmaktadır. Bu bakımdan maske altında kalan bölgelerdeki değişimi üç boyutlu olarak karakterize edebilmektedir.

AH görüntülerde GM sınıflandırma çalışmaları literatürde varken BM görüntülerde sınıflandırma çalışmaları son derece azdır. AH'de GM bölgesinde hacimsel kayıplar olduğu gibi BM bölgesinde de hacimsel kayıpların olduğu belirtilmektedir. Bu bilgilere dayanarak BM bölgelerde de simetri ve doku analizi yöntemleri ile sınıflandırma çalışmaları yapılmıştır. BM sınıflandırılmasında simetri yöntemi ile literatürde ilk defa sınıflandırma çalışması yapılmıştır. VTM yöntemi ile BM bölgelerdeki hacimsel kayıpları haritaladıktan sonra maske olarak kullanımı literatürde bu tezde ilk defa yapılmıştır. Bu maskelerin altında kalan bölgelerden doku analizi yöntemi ile özeliklerin çıkarılıp sınıflandırılması etkin sonuçlar vermektedir. Dolayısıyla BM'de meydana gelen dejenerasyon GM kadar olmasa da AH'nin ayırıcı tanısında etkili olduğu görülmüştür.

Tez çalışmasında araştırılan diğer bir konu ise simetri ve doku analizi yöntemlerinde normalizasyondan sonra modülasyonlu görüntünün mü yoksa doku konsantrasyonunu koruyan görüntülerin mi daha iyi sınıflandırma sonucu verdiğinin belirlenmesidir. Bazı makalelerde gruplar arası hacimsel kayıpların modülasyonlu görüntülerde daha iyi lokalize olduğu iddia edilirken bazı yayınlarda konsantrasyonu koruyan görüntünün daha iyi sonuç verdiği belirtilmektedir. Bundan dolayı tez çalışmasında MNS ve NS görüntüler simetri ve doku analizi yöntemlerinde ayrı ayrı incelenmiştir. Doku analizi ile özellik çıkaran yöntemlerde GM görüntüler NS'lerde daha iyi sonuç verirken, BM görüntüler daha çok MNS görüntülerde iyi sonuç vermiştir. Simetri analizlerinde ise GM görüntüler MNS ile en iyi sonucu verirken BM görüntülerde NS daha iyi sınıflandırma doğruluğu vermiştir.

7.2. Öneriler

AH basit unutkanlıklarla başlayıp ileri evrelerde ise unutkanlığın şiddeti artan ve geri dönüşü olmayan bir beyin hastalığıdır. Beyinde hafıza bölgelerinde başlayan dejenerasyon zamanla diğer bölgelere de yayılarak başka fonksiyonel merkezlerin bozulmasına neden olmakta hastanın günlük sıradan işlerini dahi yapmasına mani olmaktadır. Dolayısıyla hasta ancak bir refakatçi eşliğinde hayatını idame ettirebilir. Türkiye'de 600 bin aile Alzheimer ile mücadele etmektedir. Dünyada yaşlı nüfusun artması ile beraber AH oranı hızlı bir şekilde artmaktadır. Türkiye İstatistik Kurumunun verilerine göre 2023 yılında Türkiye'nin yaşlı nüfusu toplam nüfusun %10'u kadar olacaktır. Dolayısıyla AH ileri dönemlerde bakım, tedavi masrafları ve sosyolojik

çıktıları bakımından Türkiye için büyük bir problem olacağı düşünülmektedir. Her ne kadar ülkemizde farkındalık oluşturmak için Ulusal Alzheimer Kongresi ve Türkiye Alzheimer Derneği çalışmalarını sürdürse de, dünyada yürütülen çalışmalara göre ülkemiz yetersiz düzeydedir. Türkiye'de tüm bölgeleri kapsayan ciddi anlamda bir insidans ve prevelans çalışması yapılmamıştır. Yapılan çalışmalar belli bölgelere ait olup bu bölgelerdeki sonuçlardan yola çıkarak tüm ülkedeki istatistiksel oranlar tahmin edilmeye çalışılmaktadır. Bu eksikliklerden dolayı ülkemizde AH ve benzeri demanslar için acil bir eylem planı bulunmamakta, ileriyi dönük sosyolojik ve psikolojik çıktıları göz ardı edilmektedir. AH ve benzeri demanslar ile mücadele etmek, risk faktörlerini azaltmak için halkı bilinçlendirmek, tedavi ve tanı bakımından hızlı çözümler sunabilmek için ülkemizde merkezler kurulmalıdır. Dünyadaki en önemli örneklerinden bir tanesi ADNI merkezidir. ABD hükümetinin ciddi fonlarla desteklediği bu merkez belli kriterlere göre veriler alarak araştırmalarını sürdürmektedir. ADNI veri alım ve araştırma protokollerine göre diğer birçok dünya ülkelerinde merkezler açarak global anlamda çalışmalar da yapmaktadır. ABD'deki bir diğer önemli çalışma ise Alzheimer's Association tarafından her sene ortaya konulan *Alzheimer's Disease Facts and Figures* isimli çalışmadır. Bu çalışma ile ABD ve eyaletlerindeki insidans, prevelans, morbite, mortalite, tedavi, bakım, masraflar gibi temel araştırma konuları yıllık olarak detaylı bir şekilde incelemektedirler. Türkiye'de de bu iki çalışmayı yapan kurumlara entegre olunarak benzer çalışmalar yapılmalıdır.

Tez çalışmasında karşılaşılan bir diğer problem ise veri toplama da yaşanılan sıkıntıdır. Unutkanlık şikayeti ile gelen hastanın unutkanlığın derecesinin belirlenmesi için nöropsikolojik bir test uygulanır. Ülkemizde en çok kullanılan test ise mini mental durum testidir. Bu test ile hafıza gibi bazı fonksiyonel kabiliyetlerin performansı ölçülerek hastaya bir skor verilir. Bu skorlama işleminden sonra tanı eylemleri gerçekleştirilmektedir ve hastadan ihtiyaca göre tıbbi görüntüler alınmaktadır. Tanımlanmış yüz demans nedeni içerisinden bir tanesi AH'dir. Dolayısıyla AH'nin başlangıç evreleri diğer demans nedenleri ile karıştırılabilmektedir. Karar destek sistemleri için MR görüntülerinin hastalığın çeşidine ve evresine göre etiketlenmesi gerekmektedir. KDR nöropsikolojik testi ile etiketleme AH ve evreleri için daha net bir skorlama sağlamaktadır. Ancak bu test ülkemizde nadiren kullanılmaktadır. Hasta ve hasta yakınlarının nöropsikolojik test soruları esnasında sıkılmaları, doktorların farklı skorlama testleri konusunda yeterli tecrübelerinin olmaması, MR görüntü alımında çok fazla sıranın olması veri alımını son derece zorlaştırmaktadır. Bu zorlukların üstesinden

gelmek ve ülkemiz için daha sağlıklı demans araştırmalarının yapılabilmesi için sadece demanslar ile ilgilenen merkezler açılarak halihazırda hastalardan alınan verilerin yanında araştırmalara dönük verilerin alınması daha detaylı bilimsel çalışmaların yapılması için faydalı olacaktır. Türkiye'de belli bölgelere kurulacak merkezler ile toplanan ortak belirlenmiş görüntüleme ve nöropsikolojik test protokolleri ile alınan datalar bir konsorsiyum altında toplanarak araştırmacıların kullanım imkanına sunulabilir. Tez çalışmasında araştırılan Freesurfer, FSL ve SPM gibi programlar ile data analizi, VTM ile grup analizleri, elde edilen özellikler ile karar destek sistemleri sadece AH için değil, beyinden kaynaklı demans nedenlerini birbirinden ayırmak için de toplanan bu datalar üzerinden değerlendirilebilir. Tez çalışmasında önerilen modeller ile MR görüntüsü alındıktan hemen sonra bu analizler otomatik bir şekilde yapılarak, görüntüde izlenen kayıplar ve karar destek sistemi ile tahmin edilen demans nedeni ön bir bilgi olarak teşhise yardımcı olması açısından doktor önüne otomatik olarak getirilebilir. Modellerin daha yüksek düzeyde geliştirilmesi ile MR çekimi ile beraber otomatik tanımlama yapan yazılımlar MR cihazı içine gömülebilir. Türkiye'de tıbbi görüntüler ile doktorların yaptığı bilimsel çalışmalar genellikle manuel ve tecrübeye dayalı bir yorumlama ile yapılmaktadır. Ancak literatürde kullanılan sayısal yöntemler ve paket programlar ile yapılacak analizler hem bilimsel çalışma kalitesinin artması açısından hem de analiz süresi ve sonuçların görselleştirilmesi açısından önemlidir. Bu eksikliği gidermek için ülkemizde tıbbi görüntülerin sayısal analizlerini öğreten kurslar düzenlenebilir ve topluluklar kurulabilir. Ülkemizde üç boyutlu beyin MR görüntülerinin sayısal yöntemlerle analizini yapan ve karar destek sistemleri tasarlayan çok fazla çalışma olmamasından dolayı bu tez çalışması gelecek çalışmalar için iyi bir kaynak olacaktır.

KAYNAKLAR

Aggarwal, N., Rana, B. ve Agrawal, R., 2013, Detection of Alzheimer's Disease via Statistical Features from Brain Slices, *The Twenty-Sixth International FLAIRS Conference*.

Aggarwal, N., Rana, B. ve Agrawal, R., 2015a, 3d discrete wavelet transform for computer aided diagnosis of Alzheimer's disease using t1-weighted brain MRI, *International Journal of Imaging Systems and Technology*, 25 (2), 179-190.

Aggarwal, N., Rana, B., Agrawal, R. ve Kumaran, S., 2015b, A combination of dual-tree discrete wavelet transform and minimum redundancy maximum relevance method for diagnosis of Alzheimer's disease, *International journal of bioinformatics research and applications*, 11 (5), 433-461.

Aguilar, C., Westman, E., Muehlboeck, J.-S., Mecocci, P., Vellas, B., Tsolaki, M., Kloszewska, I., Soininen, H., Lovestone, S. ve Spenger, C., 2013, Different multivariate techniques for automated classification of MRI data in Alzheimer's disease and mild cognitive impairment, *Psychiatry Research: Neuroimaging*, 212 (2), 89-98.

Ahmed, M. N., Yamany, S. M., Mohamed, N., Farag, A. A. ve Moriarty, T., 2002, A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data, *IEEE transactions on medical imaging*, 21 (3), 193-199.

Alpar, R., 2011, Çok Değişkenli İstatistiksel Yöntemler, *Ankara*, Detay Yayıncılık, p.

Anonim, 2017a, Talairach Coordinates, https://en.0wikipedia.org/index.php?q=aHR0cHM6Ly9lbi53aWtpcGVkaWEub3JnL3dpa2kvVGFsYWlyYWNoX2Nvb3JkaW5hdGVz: [Ziyaret Tarihi: 20.07.2017].

Anonim, 2017b, MRIcro, http://www.cabiatl.com/mricro/mricro/mricro.html: [Ziyaret Tarihi: 05.09.2017].

Anonim, 2017c, Türkiye'de Yaşlı Nüfus Oranı 2023'te yüzde 10'u Geçecek http://www.hurriyet.com.tr/turkiyede-yasli-nufus-orani-2023te-yuzde-10u-gececek-28486270: [Ziyaret Tarihi: 27.08.2017].

Anonim, 2017d, Türkiye'de 600bin aile Alzheimer Hastalığı ile Mücadele Ediyor, http://www.alzheimerdernegi.org.tr/haber/turkiyede-600-bin-aile-alzheimer-hastaligi-ile-mucadele-ediyor/:

Anonim, 2017e, pdist, MathWorks https://www.mathworks.com/help/stats/pdist.html: [Ziyaret Tarihi: 09.10.2017].

Anonim, 2017f, http://www0.cs.ucl.ac.uk/staff/g.ridgway/vbm/get_totals.m: [Ziyaret Tarihi: 11.09.2017].

Anonim, 2017g, How to calculate grey/white matter volume from segmented images.

Anonim, 2017h, Alzheimer's Disease: Causes, Symptoms, Treatments and Preventative Options, http://wikybrew.com/alzheimers-disease-causes-symptoms-treatments-and-preventative-options/: [Ziyaret Tarihi: 27.08.2017].

Anonim, 2017i, What is the difference between validation set and test set?, https://www.researchgate.net/post/what_is_the_difference_between_validation_set_and_test_set: [Ziyaret Tarihi: [31.10.2017]].

Anonim, 2017j, x, y, z axes, http://martinos.org/mne/stable/_images/HeadCS.png: [Ziyaret Tarihi: 20.07.2017].

Anonim, 2017k, Jean-Baptiste Joseph Fourier, https://tr.0wikipedia.org/index.php?q=aHR0cHM6Ly90ci53aWtpcGVkaWEub3JnL3dpa2kvSmVhbi1CYXB0aXN0ZV9Kb3NlcGhfRm91cmllcg: [Ziyaret Tarihi: 15.09.2017].

Anonim, 2017l, Fourier Analizi, https://tr.0wikipedia.org/index.php?q=aHR0cHM6Ly90ci53aWtpcGVkaWEub3JnL3dpa2kvRm91cmllcl9hbmFsaXpp: [Ziyaret Tarihi: 15.09.2017].

Anonim, 2017 The MNI Brain and The Talairach Atlas http://www.nil.wustl.edu/labs/kevin/man/answers/mnispace.html: [Ziyaret Tarihi: 20.07.2017].

Arunadevia, B. ve Deepa, S. N., 2013, Texture analysis for 3D classification of brain tumor tissues, *Przegląd Elektrotechniczny*, 342-348.

Ashburner, J., Barnes, G., Chen, C.-C., Daunizeau, J., Flandin, G., Friston, K., Glauche, V., Henson, R., Hutton, C. ve Kiebel, S., 1994, Statistical parametric mapping.

Ashburner, J. ve Friston, K. J., 2000, Voxel-based morphometry—the methods, *Neuroimage*, 11 (6), 805-821.

Ashburner, J. ve Friston, K. J., 2005, Unified segmentation, *Neuroimage*, 26 (3), 839-851.

Ashburner, J., 2007, A fast diffeomorphic image registration algorithm, *Neuroimage*, 38 (1), 95-113.

Ashburner, J., Barnes, G., Chen, C., Daunizeau, J., Flandin, G., Friston, K., Gitelman, D., Kiebel, S., Kilner, J. ve Litvak, V., 2008, SPM8 manual, *Functional Imaging Laboratory, Institute of Neurology*, 41.

Association, A. P., 2013a, Diagnostic and statistical manual of mental disorders (DSM-5®), American Psychiatric Pub, p.

Association, A. s., 2013b, 2013 Alzheimer's disease facts and figures, *Alzheimer's & dementia*, 9 (2), 208-245.

Baron, J., Chetelat, G., Desgranges, B., Perchey, G., Landeau, B., De La Sayette, V. ve Eustache, F., 2001, In vivo mapping of gray matter loss with voxel-based morphometry in mild Alzheimer's disease, *Neuroimage*, 14 (2), 298-309.

Beheshti, I., Demirel, H. ve Initiative, A. s. D. N., 2015, Probability distribution function-based classification of structural MRI for the detection of Alzheimer's disease, *Computers in biology and medicine*, 64, 208-216.

Beheshti, I., Demirel, H., Farokhian, F., Yang, C., Matsuda, H. ve Initiative, A. s. D. N., 2016a, Structural MRI-based detection of Alzheimer's disease using feature ranking and classification error, *Computer methods and programs in biomedicine*, 137, 177-193.

Beheshti, I., Demirel, H. ve Initiative, A. s. D. N., 2016b, Feature-ranking-based Alzheimer's disease classification from structural MRI, *Magnetic resonance imaging*, 34 (3), 252-263.

Beheshti, I., Demirel, H., Matsuda, H. ve Initiative, A. s. D. N., 2017, Classification of Alzheimer's disease and prediction of mild cognitive impairment-to-Alzheimer's conversion from structural magnetic resource imaging using feature ranking and a genetic algorithm, *Computers in Biology and Medicine*, 83, 109-119.

Bıyıklı, A. E. ve Şanlıer, N., 2014, Alzheimer hastalığı ve beslenme, *Genel Tıp Dergisi*, 62-65.

Boztoprak, H., 2016, KENAR GEÇİŞLERİ KULLANILARAK GÖRÜNTÜDEKİ BULANIKLIĞIN GİDERİLMESİ, *SDU International Journal of Technological Science*, 8 (2).

Brett, M., Johnsrude, I. S. ve Owen, A. M., 2002, OPINION: The problem of functional localization in the human brain, *Nature reviews. Neuroscience*, 3 (3), 243.

Bron, E. E., Smits, M., Van Der Flier, W. M., Vrenken, H., Barkhof, F., Scheltens, P., Papma, J. M., Steketee, R. M., Orellana, C. M. ve Meijboom, R., 2015, Standardized evaluation of algorithms for computer-aided diagnosis of dementia based on structural MRI: the CADDementia challenge, *NeuroImage*, 111, 562-579.

Busatto, G. F., Garrido, G. E., Almeida, O. P., Castro, C. C., Camargo, C. H., Cid, C. G., Buchpiguel, C. A., Furuie, S. ve Bottino, C. M., 2003, A voxel-based

morphometry study of temporal lobe gray matter reductions in Alzheimer's disease, *Neurobiology of aging*, 24 (2), 221-231.

Celsis, P., 2000, Age-related cognitive decline, mild cognitive impairment or preclinical Alzheimer's disease?, *Annals of Medicine*, 32 (1), 6-14.

Chaddad, A., Desrosiers, C. ve Toews, M., 2016, Local discriminative characterization of MRI for Alzheimer's disease, *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on*, 1-5.

Cheng, B. ve Jie, B., 2013, Ensemble Sparse Feature Selection for Classification of Alzheimer's Disease, *International Journal of Digital Content Technology and its Applications*, 7 (5), 255.

Chu, C., Hsu, A.-L., Chou, K.-H., Bandettini, P., Lin, C. ve Initiative, A. s. D. N., 2012, Does feature selection improve classification accuracy? Impact of sample size and feature selection on classification using anatomical magnetic resonance images, *Neuroimage*, 60 (1), 59-70.

Chyzhyk, D. ve Savio, A., 2010, Feature extraction from structural MRI images based on VBM: data from OASIS database, *University of the Basque Country, Internal research publication*.

Cortes, C. ve Vapnik, V., 1995, Support-vector networks, *Machine learning*, 20 (3), 273-297.

Coşkun, M. ve İstanbullu, A., 2012, EEG İşaretlerinin FFT ve dalgacık dönüşümü ile analizi, *Akademik Bilişim'12-XIV. Akademik Bilişim Konferansı*, 323-328.

Cuingnet, R., Gerardin, E., Tessieras, J., Auzias, G., Lehéricy, S., Habert, M.-O., Chupin, M., Benali, H., Colliot, O. ve Initiative, A. s. D. N., 2011, Automatic classification of patients with Alzheimer's disease from structural MRI: a comparison of ten methods using the ADNI database, *Neuroimage*, 56 (2), 766-781.

Dağdeviren, Z. A., 2012, Hastaların Yapısal MR Görüntülerinin MNI görüntü Uzayına Kayıtlanması, *Ege Üniversitesi Fen Bilimleri Enstitüsü*, İzmir.

Davis, E. ve Loh, E., 2011, Methods for Dummies: Coregistration and Spatial Normalization, http://www.fil.ion.ucl.ac.uk/mfd_archive/2011/page1/mfd2011_coregistration.pptx: [Ziyaret Tarihi: 20.07.2017].

De Oliveira, M., Balthazar, M., D'abreu, A., Yasuda, C., Damasceno, B., Cendes, F. ve Castellano, G., 2011, MR imaging texture analysis of the corpus callosum and thalamus in amnestic mild cognitive impairment and mild Alzheimer disease, *American Journal of Neuroradiology*, 32 (1), 60-66.

Demirhan, A., 2012, Beyin Mr Görüntülerinin Dalgacık Dönüşümü ve Özörgütlemeli Harita Ağları Kullanılarak Bölütlenmesi, *Gazi Üniversitesi*, Bilişim Enstitüsü, 34-35.

Derflinger, S., Sorg, C., Gaser, C., Myers, N., Arsic, M., Kurz, A., Zimmer, C., Wohlschläger, A. ve Mühlau, M., 2011, Grey-matter atrophy in Alzheimer's disease is asymmetric but not lateralized, *Journal of Alzheimer's Disease*, 25 (2), 347-357.

Ding, Y., Zhang, C., Lan, T., Qin, Z., Zhang, X. ve Wang, W., 2015, Classification of Alzheimer's disease based on the combination of morphometric feature and texture feature, *2015 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 409-412.

Erdoğmuş, P. ve Pekçakar, A., 2009, Dalgacık dönüşümü ile ekg sinyallerinin özellik çıkarımı ve yapay sinir ağları ile sınıflandırılması, *Uluslararası İleri Teknolojiler Sempozyumu*, 13-15.

Evans, A. C., Collins, D. L. ve Milner, B., 1992, An MRI-based stereotactic atlas from 250 young normal subjects, *Soc. neurosci. abstr*, 408.

Evans, A. C., Collins, D. L., Mills, S., Brown, E., Kelly, R. ve Peters, T. M., 1993, 3D statistical neuroanatomical models from 305 MRI volumes, *Nuclear Science Symposium and Medical Imaging Conference, 1993., 1993 IEEE Conference Record.*, 1813-1817.

Fan, Y., Batmanghelich, N., Clark, C. M., Davatzikos, C. ve Initiative, A. s. D. N., 2008, Spatial patterns of brain atrophy in MCI patients, identified via high-dimensional pattern classification, predict subsequent cognitive decline, *Neuroimage*, 39 (4), 1731-1743.

Ferri, C. P., Prince, M., Brayne, C., Brodaty, H., Fratiglioni, L., Ganguli, M., Hall, K., Hasegawa, K., Hendrie, H. ve Huang, Y., 2006, Global prevalence of dementia: a Delphi consensus study, *The lancet*, 366 (9503), 2112-2117.

Fischl, B., 2012, FreeSurfer, *Neuroimage*, 62 (2), 774-781.

Goto, M., Abe, O., Aoki, S., Hayashi, N., Miyati, T., Takao, H., Iwatsubo, T., Yamashita, F., Matsuda, H. ve Mori, H., 2013, Diffeomorphic Anatomical Registration Through Exponentiated Lie Algebra provides reduced effect of scanner for cortex volumetry with atlas-based method in healthy subjects, *Neuroradiology*, 55 (7), 869-875.

Gudbjartsson, H. ve Patz, S., 1995, The Rician distribution of noisy MRI data, *Magnetic resonance in medicine*, 34 (6), 910-914.

Gurvit, H., Emre, M., Tinaz, S., Bilgic, B., Hanagasi, H., Sahin, H., Gurol, E., Kvaloy, J. ve Harmanci, H., 2008, The prevalence of dementia in an urban Turkish population, *American Journal of Alzheimer's Disease & Other Dementias®*, 23 (1), 67-76.

Güriş, S. ve Astar, M., 2014, Bilimsel araştırmalarda SPSS ile istatistik, Der yayınları.

Gürvit, H. ve Baran, B., 2007, kognitif bozukluklarda ölçekler, *Nöropiskiyatri Arşivi*, 44, 58-65.

Haralick, R. M. ve Shanmugam, K., 1973, Textural features for image classification, *IEEE Transactions on systems, man, and cybernetics* (6), 610-621.

Heckemann, R. A., Keihaninejad, S., Aljabar, P., Gray, K. R., Nielsen, C., Rueckert, D., Hajnal, J. V., Hammers, A. ve Initiative, A. s. D. N., 2011, Automatic morphometry in Alzheimer's disease and mild cognitive impairment, *Neuroimage*, 56 (4), 2024-2037.

Hemanth, D. J. ve Anitha, J., 2012, Image Pre-processing and Feature Extraction Techniques for Magnetic Resonance Brain Image Analysis, In: Computer Applications for Communication, Networking, and Digital Contents, Eds: Springer, p. 349-356.

Herek, D. ve Karabulut, N., 2010, Manyetik Rezonans Görüntüleme, *TTD Toraks Cerrahisi Bülteni*, 1 (3).

Hopkins, W. D., Taglialatela, J. P., Meguerditchian, A., Nir, T., Schenker, N. M. ve Sherwood, C. C., 2008, Gray matter asymmetries in chimpanzees as revealed by voxel-based morphometry, *Neuroimage*, 42 (2), 491-497.

Hore, A. ve Ziou, D., 2010, Image quality metrics: PSNR vs. SSIM, *Pattern recognition (icpr), 2010 20th international conference on*, 2366-2369.

Jack, C. R., Bernstein, M. A., Fox, N. C., Thompson, P., Alexander, G., Harvey, D., Borowski, B., Britson, P. J., L Whitwell, J. ve Ward, C., 2008, The Alzheimer's disease neuroimaging initiative (ADNI): MRI methods, *Journal of magnetic resonance imaging*, 27 (4), 685-691.

Jenkinson, M., Beckmann, C. F., Behrens, T. E., Woolrich, M. W. ve Smith, S. M., 2012, Fsl, *Neuroimage*, 62 (2), 782-790.

Jha, D., Kim, J.-I. ve Kwon, G.-R., 2017, Diagnosis of Alzheimer's Disease Using Dual-Tree Complex Wavelet Transform, PCA, and Feed-Forward Neural Network, *Journal of Healthcare Engineering*, 2017.

Kavzoğlu, T. ve Çölkesen, İ., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, 144 (7), 73-82.

Kempton, M. J., Underwood, T. S., Brunton, S., Stylios, F., Schmechtig, A., Ettinger, U., Smith, M. S., Lovestone, S., Crum, W. R. ve Frangou, S., 2011, A comprehensive testing protocol for MRI neuroanatomical segmentation techniques: evaluation of a novel lateral ventricle segmentation method, *Neuroimage*, 58 (4), 1051-1059.

Khedher, L., Ramírez, J., Górriz, J. M. ve Brahim, A., 2015a, Automatic classification of segmented MRI data combining Independent Component Analysis and Support Vector Machines, *Innovation in Medicine and Healthcare 2014*, 207, 271.

Khedher, L., Ramírez, J., Górriz, J. M., Brahim, A., Segovia, F. ve Initiative, A. s. D. N., 2015b, Early diagnosis of Alzheimer′ s disease based on partial least squares, principal component analysis and support vector machine using segmented MRI images, *Neurocomputing*, 151, 139-150.

Klein, A., Andersson, J., Ardekani, B. A., Ashburner, J., Avants, B., Chiang, M.-C., Christensen, G. E., Collins, D. L., Gee, J. ve Hellier, P., 2009, Evaluation of 14 nonlinear deformation algorithms applied to human brain MRI registration, *Neuroimage*, 46 (3), 786-802.

Klöppel, S., Stonnington, C. M., Chu, C., Draganski, B., Scahill, R. I., Rohrer, J. D., Fox, N. C., Jack Jr, C. R., Ashburner, J. ve Frackowiak, R. S., 2008, Automatic classification of MR scans in Alzheimer's disease, *Brain*, 131 (3), 681-689.

Koikkalainen, J., Pölönen, H., Mattila, J., Van Gils, M., Soininen, H., Lötjönen, J. ve Initiative, A. s. D. N., 2012, Improved classification of Alzheimer's disease data via removal of nuisance variability, *PloS one*, 7 (2), e31112.

Kopřivová, J., Horáček, J., Tintěra, J., Praško, J., Raszka, M., Ibrahim, I. ve Höschl, C., 2009, Medial frontal and dorsal cortical morphometric abnormalities are related to obsessive-compulsive disorder, *Neuroscience letters*, 464 (1), 62-66.

Köktürk, G., 2006, kısa zamanlı fourier dönüşümü için başarım karşılaştırma, *DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 8 (3), 11-18.

Kuijf, H. J., Leemans, A., Viergever, M. A. ve Vincken, K. L., 2013, Assessment of methods to extract the mid-sagittal plane from brain MR images, *SPIE Medical Imaging*, 86731K-86731K-86737.

Kurani, A. S., Xu, D.-H., Furst, J. ve Raicu, D. S., 2004, Co-occurrence matrices for volumetric data, *7th IASTED International Conference on Computer Graphics and Imaging, Kauai, USA*, 447-452.

Kurth, F., Luders, E. ve Gaser, C., 2010, VBM8 toolbox manual, *Jena: University of Jena*.

Kurth, F., Gaser, C. ve Luders, E., 2015, A 12-step user guide for analyzing voxel-wise gray matter asymmetries in statistical parametric mapping (SPM), *Nature Protocols*, 10 (2), 293-304.

Lancaster, J. L. ve Fox, P. T., 2000, Talairach space as a tool for intersubject standardization in the brain, *Handbook of medical imaging*, 555-567.

Lancaster, J. L., Woldorff, M. G., Parsons, L. M., Liotti, M., Freitas, C. S., Rainey, L., Kochunov, P. V., Nickerson, D., Mikiten, S. A. ve Fox, P. T., 2000, Automated Talairach atlas labels for functional brain mapping, *Human brain mapping*, 10 (3), 120-131.

Lebedev, A. V., Westman, E., Beyer, M., Kramberger, M., Aguilar, C., Pirtosek, Z. ve Aarsland, D., 2013, Multivariate classification of patients with Alzheimer's and dementia with Lewy bodies using high-dimensional cortical thickness measurements: an MRI surface-based morphometric study, *Journal of neurology*, 260 (4), 1104-1115.

Liu, S., Cai, W., Wen, L., Eberl, S., Fulham, M. J. ve Feng, D., 2010, A robust volumetric feature extraction approach for 3D neuroimaging retrieval, *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*, 5657-5660.

Liu, S. X., 2009, Symmetry and asymmetry analysis and its implications to computer-aided diagnosis: A review of the literature, *Journal of Biomedical Informatics*, 42 (6), 1056-1064.

Liu, Y., Collins, R. T. ve Rothfus, W. E., 1998, Automatic bilateral symmetry (midsagittal) plane extraction from pathological 3D neuroradiological images, *Medical Imaging'98*, 1528-1539.

Liu, Y., Collins, R. T. ve Rothfus, W. E., 2001, Robust midsagittal plane extraction from normal and pathological 3-D neuroradiology images, *IEEE transactions on medical imaging*, 20 (3), 175-192.

Luders, E., Gaser, C., Jancke, L. ve Schlaug, G., 2004, A voxel-based approach to gray matter asymmetries, *Neuroimage*, 22 (2), 656-664.

Maes, F., Van Leemput, K., DeLisi, L. E., Vandermeulen, D. ve Suetens, P., 1999, Quantification of cerebral grey and white matter asymmetry from MRI, *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 348-357.

Magnin, B., Mesrob, L., Kinkingnéhun, S., Pélégrini-Issac, M., Colliot, O., Sarazin, M., Dubois, B., Lehéricy, S. ve Benali, H., 2009, Support vector machine-based classification of Alzheimer's disease from whole-brain anatomical MRI, *Neuroradiology*, 51 (2), 73-83.

Mahanand, B., Babu, G. S., Suresh, S. ve Sundararajan, N., 2015, Identification of imaging biomarkers responsible for Alzheimer's disease using a McRBFN classifier, *Cognitive Computing and Information Processing (CCIP), 2015 International Conference on*, 1-4.

Mahanand, B. S., Suresh, S., Sundararajan, N. ve Kumar, M. A., 2012, Identification of brain regions responsible for Alzheimer's disease using a Self-adaptive Resource Allocation Network, *Neural Networks*, 32, 313-322.

Mahmood, R. ve Ghimire, B., 2013, Automatic detection and classification of Alzheimer's Disease from MRI scans using principal component analysis and artificial neural networks, *Systems, Signals and Image Processing (IWSSIP), 2013 20th International Conference on*, 133-137.

Maldjian, J., 2017, WFU PickAtlas version 3.0 User Manual, http://fmri.wfubmc.edu/downloads/WFU_PickAtlas_User_Manual_v3.0.pdf:[ZiyaretTarihi:11.09.2017].

Maldjian, J. A., Laurienti, P. J., Kraft, R. A. ve Burdette, J. H., 2003, An automated method for neuroanatomic and cytoarchitectonic atlas-based interrogation of fMRI data sets, *Neuroimage*, 19 (3), 1233-1239.

Maldjian, J. A., Laurienti, P. J. ve Burdette, J. H., 2004, Precentral gyrus discrepancy in electronic versions of the Talairach atlas, *Neuroimage*, 21 (1), 450-455.

Malone, I. B., Cash, D., Ridgway, G. R., MacManus, D. G., Ourselin, S., Fox, N. C. ve Schott, J. M., 2013, MIRIAD—Public release of a multiple time point Alzheimer's MR imaging dataset, *NeuroImage*, 70, 33-36.

Manjón, J. V., Carbonell-Caballero, J., Lull, J. J., García-Martí, G., Martí-Bonmatí, L. ve Robles, M., 2008, MRI denoising using non-local means, *Medical image analysis*, 12 (4), 514-523.

Manjón, J. V., Coupé, P., Martí-Bonmatí, L., Collins, D. L. ve Robles, M., 2010, Adaptive non-local means denoising of MR images with spatially varying noise levels, *Journal of Magnetic Resonance Imaging*, 31 (1), 192-203.

Manjón, J. V., Coupé, P., Buades, A., Collins, D. L. ve Robles, M., 2012, New methods for MRI denoising based on sparseness and self-similarity, *Medical image analysis*, 16 (1), 18-27.

Marcus, D. S., Wang, T. H., Parker, J., Csernansky, J. G., Morris, J. C. ve Buckner, R. L., 2007, Open Access Series of Imaging Studies (OASIS): cross-sectional MRI data in young, middle aged, nondemented, and demented older adults, *Journal of cognitive neuroscience*, 19 (9), 1498-1507.

Materka, A. ve Strzelecki, M., 1998, Texture analysis methods–a review, *Technical university of lodz, institute of electronics, COST B11 report, Brussels*, 9-11.

Matsunari, I., Samuraki, M., Chen, W.-P., Yanase, D., Takeda, N., Ono, K., Yoshita, M., Matsuda, H., Yamada, M. ve Kinuya, S., 2007, Comparison of 18F-FDG PET and optimized voxel-based morphometry for detection of Alzheimer's disease: aging effect on diagnostic performance, *Journal of Nuclear Medicine*, 48 (12), 1961-1970.

McAuliffe, M., 2009, Medical image processing, analysis, and visualization (MIPAV), *National Institutes of Health*, 4 (0).

Mechelli, A., Price, C. J., Friston, K. J. ve Ashburner, J., 2005, Voxel-based morphometry of the human brain: methods and applications, *Current medical imaging reviews*, 1 (2), 105-113.

Mesrob, L., Magnin, B., Colliot, O., Sarazin, M., Hahn-Barma, V., Dubois, B., Gallinari, P., Lehéricy, S., Kinkingnéhun, S. ve Benali, H., 2008, Identification of atrophy patterns in Alzheimer's disease based on SVM feature selection and anatomical parcellation, *Medical imaging and augmented reality*, 124-132.

Minoshima, S., Frey, K. A., Koeppe, R. A., Foster, N. L. ve Kuhl, D. E., 1995, A diagnostic approach in Alzheimer's Disease using three-dimensional stereotactic surface, *J Nucl med*, 36, 1238-1248.

Murcia, Francisco Jesús Martínez. 2017. 'Statistical neuroimage modeling, processing and synthesis based on texture and component analysis Tackling the small sample size problem', Universidad de Granada.

Mwangi, B., Tian, T. S. ve Soares, J. C., 2014, A review of feature reduction techniques in neuroimaging, *Neuroinformatics*, 12 (2), 229-244.

Nguyen, T., Nahavandi, S., Creighton, D. ve Khosravi, A., 2015, Mass spectrometry cancer data classification using wavelets and genetic algorithm, *FEBS letters*, 589 (24), 3879-3886.

Othmen, E. B., Sayadi, M. ve Fniaech, F., 2013, 3D gray level co-occurrence matrices for volumetric texture classification, *Systems and Control (ICSC), 2013 3rd International Conference on*, 833-837.

Özler, C., 2017, Parametrik Olmayan İstatistik, kisi.deu.edu.tr/userweb/murat.tanik /poi%204_%20hafta-1%20rev%201.ppt: [Ziyaret Tarihi: 13.09.2017].

Özmen, G. ve Özşen, S., 2017, A new denoising method for fMRI based on weighted three-dimensional wavelet transform, *Neural Computing and Applications*, 1-14.

Öztürk, G. B. ve Karan, M. A., 2006, Alzheimer hastalığının fizyopatolojisi, *Klinik GeliÇim Dergisi*, 36-45.

Papakostas, G. A., Savio, A., Graña, M. ve Kaburlasos, V. G., 2015, A lattice computing approach to Alzheimer's disease computer assisted diagnosis based on MRI data, *Neurocomputing*, 150, 37-42.

Patil, S. ve Udupi, V., 2012, Preprocessing to be considered for MR and CT images containing tumors, *IOSR journal of electrical and electronics engineering*, 1 (4), 54-57.

Pell, G. S., Briellmann, R. S., Chan, C. H. P., Pardoe, H., Abbott, D. F. ve Jackson, G. D., 2008, Selection of the control group for VBM analysis: influence of covariates, matching and sample size, *Neuroimage*, 41 (4), 1324-1335.

Philips, C. ve Li, D., 2008, Implementation of 3D co-occurrence matrix and Haralick features in MATLAB, MATLAB Central, http://www.mathworks.com/matlab central/fileexchange/19058-cooc3d: [Ziyaret Tarihi: 13.09.2017].

Philips, C. ve Li, D., 2017, Three-dimensional co-occurrence matrices & Gabor filters: Current progress, http://facweb.cs.depaul.edu/research/vc/medix/2007 /presentations/Final%20Presentation/Dan_Carl_Final_Presentation.ppt: [Ziyaret Tarihi: 13.09.2017].

Pourreza, A., Lee, W. S. D., Raveh, E., Hong, Y. ve Kim, H.-J., 2013, Identification of citrus greening disease using a visible band image analysis, *2013 Kansas City, Missouri, July 21-July 24, 2013*, 1.

Querbes, O., Aubry, F., Pariente, J., Lotterie, J.-A., Démonet, J.-F., Duret, V., Puel, M., Berry, I., Fort, J.-C. ve Celsis, P., 2009, Early diagnosis of Alzheimer's disease using cortical thickness: impact of cognitive reserve, *Brain*, 132 (8), 2036-2047.

Radua, J., Canales-Rodríguez, E. J., Pomarol-Clotet, E. ve Salvador, R., 2014, Validity of modulation and optimal settings for advanced voxel-based morphometry, *Neuroimage*, 86, 81-90.

Rajapakse, J. C., Giedd, J. N. ve Rapoport, J. L., 1997, Statistical approach to segmentation of single-channel cerebral MR images, *IEEE transactions on medical imaging*, 16 (2), 176-186.

Rajeesh, J., Moni, R. S. ve Gopalakrishnan, T., 2012, Discrimination of Alzheimer's disease using hippocampus texture features from MRI, *Asian Biomedicine*, 6 (1), 87-94.

Ridgway, G., 2008, Voxel-Based Morphometry with Unified Segmentation http://www.fil.ion.ucl.ac.uk/spm/course/slides08-zurich/Ged_seg_vbm.ppt: [Ziyaret Tarihi: 20.07.2017].

Ridgway, G., 2010a, SPM Course: Voxel Based Morphometry Practical http://www0.cs.ucl.ac.uk/staff/g.ridgway/zurich/vbm_practical_zurich2010.ppt [Ziyaret Tarihi: 20.07.2017].

Ridgway, G., 2010b, Spatial Preprocessing, http://www.fil.ion.ucl.ac.uk/spm/course /slides10vancouver/01_Spatial_Preprocessing.pdf: [Ziyaret Tarihi: 20.07.2017].

Saraswathi, S., Mahanand, B., Kloczkowski, A., Suresh, S. ve Sundararajan, N., 2013, Detection of onset of Alzheimer's disease from MRI images using a GA-ELM-PSO classifier, *Computational Intelligence in Medical Imaging (CIMI), 2013 IEEE Fourth International Workshop on*, 42-48.

Savio, A., García-Sebastián, M., Graña, M. ve Villanúa, J., 2009, Results of an adaboost approach on Alzheimer's disease detection on MRI, *Bioinspired Applications in Artificial and Natural Computation*, 114-123.

Savio, A., García-Sebastián, M. T., Chyzyk, D., Hernández, C., Graña, M., Sistiaga, A., De Munain, A. L. ve Villanúa, J., 2011, Neurocognitive disorder detection based

on feature vectors extracted from VBM analysis of structural MRI, *Computers in Biology and Medicine*, 41 (8), 600-610.

Savio, A. ve GrañA, M., 2013a, Deformation based feature selection for computer aided diagnosis of Alzheimer's disease, *Expert Systems with Applications*, 40 (5), 1619-1628.

Savio, A. ve Graña, M., 2013b, An Ensemble of Classifiers Guided by the AAL Brain Atlas for Alzheimer's Disease Detection, *International Work-Conference on Artificial Neural Networks*, 107-114.

Selekler, K., 2010, Alois alzheimer ve alzheimer hastalığı, *Türk Geriatri Dergisi*, 13, 9-14.

Sevindir, H. K., Çetinkaya, S. ve Şayli, Ö., 2015, EKG Sinyalinden Doğru Kalp Atım Hızı Algılama İçin Dalgacık Dönüşümü Tabanlı Gürültü Giderme Wavelet Transform Based Noise Removal from ECG Signal for Accurate Heart Rate Detection Using ECG, *Vogue*, 15 (18).

Sezer, C. ve Memiş, L., 2001, Alzheimer hastalığı histopatolojisi, *Demans Dergisi*, 1 (2), 42-49.

Svapriya, T. R., 2011, An Efficient Wavelet Based Feature Reduction and Classificaiton Technique For The Diagnosis of Dementia *International Journal of Computer Science, Engineering and Information Technology (IJCSEIT)*, Vol.1, No.5.

Şenvardar, E. K., 2011, Nörogörüntülemede SPM Uygulamaları: İşlevsel MR İmgelerinde Uzaysal Önişleme, http://www.bad.org.tr/usk10/spmonesin.pdf: [Ziyaret Tarihi:19.07.2017].

Talairach, J. ve Tournoux, P., 1988, Co-planar stereotaxic atlas of the human brain. 3-Dimensional proportional system: an approach to cerebral imaging.

Tohka, J., Zijdenbos, A. ve Evans, A., 2004, Fast and robust parameter estimation for statistical partial volume models in brain MRI, *Neuroimage*, 23 (1), 84-97.

Tustison, N. J., Avants, B. B., Cook, P. A., Zheng, Y., Egan, A., Yushkevich, P. A. ve Gee, J. C., 2010, N4ITK: improved N3 bias correction, *IEEE transactions on medical imaging*, 29 (6), 1310-1320.

Tzourio-Mazoyer, N., Landeau, B., Papathanassiou, D., Crivello, F., Etard, O., Delcroix, N., Mazoyer, B. ve Joliot, M., 2002, Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI MRI single-subject brain, *Neuroimage*, 15 (1), 273-289.

Ünsalan, C. ve Erçil, A., 1998, Öznitelik Seçme Yöntemlerinin Karşılaştırılması ve Başarı Kriteri, *Proceedings of IEEE SIU*, 98, 60-65.

Vakharia, V., Gupta, V. ve Kankar, P., 2016, A comparison of feature ranking techniques for fault diagnosis of ball bearing, *Soft Computing*, 20 (4), 1601-1619.

Valentin, M. B., de Bom, C. R., Márcio, P., Marcelo, P., Faria, E. L. ve Correia, M. D., 2016, Texture classification based on spectral analysis and haralick features classificaçao de texturas mediante análise espectral e parâmetros de haralick, *NOTAS TÉCNICAS*, 6 (1).

Van Leemput, K., Maes, F., Vandermeulen, D. ve Suetens, P., 1999, Automated model-based bias field correction of MR images of the brain, *IEEE transactions on medical imaging*, 18 (10), 885-896.

Varjo, J., 2014, Implementing texture analysis software frame for magnetic resonance image data in MATLAB.

Walhovd, K., Fjell, A., Brewer, J., McEvoy, L., Fennema-Notestine, C., Hagler, D., Jennings, R., Karow, D., Dale, A. ve Initiative, A. s. D. N., 2010, Combining MR imaging, positron-emission tomography, and CSF biomarkers in the

diagnosis and prognosis of Alzheimer disease, *American Journal of Neuroradiology*, 31 (2), 347-354.

Wang, S.-H., Zhang, Y., Li, Y.-J., Jia, W.-J., Liu, F.-Y., Yang, M.-M. ve Zhang, Y.-D., 2016, Single slice based detection for Alzheimer's disease via wavelet entropy and multilayer perceptron trained by biogeography-based optimization, *Multimedia Tools and Applications*, 1-25.

WANG, S., CHEN, Y., ZHANG, Y., DONG, Z., LEE, E. ve PHILLIPS, P., 2015, 3D-DWT Improves Prediction of AD and MCI, *Proceedings of the First International Conference on Information Science and Electronic Technology*, 60-63.

Wang, Z., Bovik, A. C., Sheikh, H. R. ve Simoncelli, E. P., 2004, Image quality assessment: from error visibility to structural similarity, *IEEE transactions on image processing*, 13 (4), 600-612.

Westman, E., Simmons, A., Muehlboeck, J.-S., Mecocci, P., Vellas, B., Tsolaki, M., Kłoszewska, I., Soininen, H., Weiner, M. W. ve Lovestone, S., 2011a, AddNeuroMed and ADNI: similar patterns of Alzheimer's atrophy and automated MRI classification accuracy in Europe and North America, *Neuroimage*, 58 (3), 818-828.

Westman, E., Simmons, A., Zhang, Y., Muehlboeck, J.-S., Tunnard, C., Liu, Y., Collins, L., Evans, A., Mecocci, P. ve Vellas, B., 2011b, Multivariate analysis of MRI data for Alzheimer's disease, mild cognitive impairment and healthy controls, *Neuroimage*, 54 (2), 1178-1187.

Westman, E., Muehlboeck, J.-S. ve Simmons, A., 2012, Combining MRI and CSF measures for classification of Alzheimer's disease and prediction of mild cognitive impairment conversion, *Neuroimage*, 62 (1), 229-238.

Whitwell, J. L., Crum, W. R., Watt, H. C. ve Fox, N. C., 2001, Normalization of cerebral volumes by use of intracranial volume: implications for longitudinal quantitative MR imaging, *American Journal of Neuroradiology*, 22 (8), 1483-1489.

Wilcox, R., 2005, Kolmogorov–smirnov test, *Encyclopedia of biostatistics*.

Wolz, R., Julkunen, V., Koikkalainen, J., Niskanen, E., Zhang, D. P., Rueckert, D., Soininen, H., Lötjönen, J. ve Initiative, A. s. D. N., 2011, Multi-method analysis of MRI images in early diagnostics of Alzheimer's disease, *PloS one*, 6 (10), e25446.

Yang, W., Chen, X., Xie, H. ve Huang, X., 2010, ICA-Based Automatic Classification of Magnetic Resonance Images from ADNI Data, *LSMS/ICSEE*, 340-347.

Zhang, D., Wang, Y., Zhou, L., Yuan, H., Shen, D. ve Initiative, A. s. D. N., 2011, Multimodal classification of Alzheimer's disease and mild cognitive impairment, *Neuroimage*, 55 (3), 856-867.

Zhang, Y. ve Wang, S., 2015, Detection of Alzheimer's disease by displacement field and machine learning, *PeerJ*, 3, e1251.

Zhou, Q., Goryawala, M., Cabrerizo, M., Barker, W., Duara, R. ve Adjouadi, M., 2014, Significance of normalization on anatomical MRI measures in predicting Alzheimer's disease, *The Scientific World Journal*, 2014.

EKLER

EK-1 OASIS veri tabanından alınan veri numaralarının nöropsikolojik test sonuçları, demografik dağılımları ve ölçülmüş bazı beyin büyüklükleri (ID:Identity, M:Male, F:Female, R:Right, Educ:Education, SES:Socioeconomic Status Scale, MMSE:Minimental State Examination, CDR:Clinical Dementia Rating, eTIV:Estimated Total Intracranial Volume, nWBV:Normalize Whole Brain Volume, ASF:Atlas Scaling Factor)

	ID	M/F	Hand	Age	Educ	SES	MMSE	CDR	eTIV	nWBV	ASF
AH	OAS1_0307_MR1	M	R	67	4	2	23	0.5	1399	0.735	0.978
AH	OAS1_0300_MR1	M	R	68	3	2	30	0.5	1556	0.723	1.213
AH	OAS1_0390_MR1	M	R	69	2	2	24	0.5	1480	0.794	1.236
AH	OAS1_0142_MR1	M	R	70	4	1	27	0.5	1581	0.695	1.252
AH	OAS1_0155_MR1	M	R	71	4		28	0.5	1359	0.753	1.200
AH	OAS1_0288_MR1	M	R	71	2	4	20	0.5	1461	0.727	1.300
AH	OAS1_0115_MR1	M	R	72	5	1	26	0.5	1911	0.726	0.947
AH	OAS1_0124_MR1	M	R	73	2		23	0.5	1661	0.709	1.299
AH	OAS1_0451_MR1	M	R	73	5	3	27	0.5	1687	0.728	1.200
AH	OAS1_0418_MR1	M	R	74	5	2	28	0.5	1659	0.747	1.268
AH	OAS1_0205_MR1	M	R	75	4	1	30	0.5	1891	0.716	1.325
AH	OAS1_0015_MR1	M	R	76	2		28	0.5	1738	0.719	1.122
AH	OAS1_0315_MR1	M	R	77	5	1	25	0.5	1604	0.773	1.341
AH	OAS1_0042_MR1	M	R	80	4	2	29	0.5	1854	0.709	1.247
AH	OAS1_0158_MR1	M	R	81	5	1	26	0.5	1556	0.689	1.213
AH	OAS1_0441_MR1	M	R	81	5	1	29	0.5	1647	0.721	1.062
AH	OAS1_0016_MR1	M	R	82	2	4	27	0.5	1477	0.739	0.919
AH	OAS1_0023_MR1	M	R	82	2	3	27	0.5	1420	0.71	0.977
AH	OAS1_0290_MR1	M	R	83	3	2	26	0.5	1992	0.706	1.274
AH	OAS1_0304_MR1	M	R	84	3	3	29	0.5	1497	0.693	1.369
AH	OAS1_0440_MR1	M	R	86	1	4	27	0.5	1320	0.723	1.056
AH	OAS1_0226_MR1	M	R	90	1	4	23	0.5	1668	0.644	1.175
AH	OAS1_0247_MR1	M	R	90	2	3	21	0.5	1307	0.689	1.171
AH	OAS1_0430_MR1	M	R	71	4	1	17	1	1562	0.687	1.110
AH	OAS1_0424_MR1	M	R	75	4	1	20	1	1613	0.715	1.214
AH	OAS1_0452_MR1	M	R	75	1	4	22	1	1656	0.762	1.291
AH	OAS1_0399_MR1	M	R	78	2		29	1	1569	0.706	1.174
AH	OAS1_0134_MR1	M	R	80	2	4	20	1	1494	0.665	1.190
AH	OAS1_0223_MR1	M	R	84	2		20	1	1641	0.703	1.405
AH	OAS1_0351_MR1	M	R	86	1	4	15	2	1512	0.665	1.336
AH	OAS1_0066_MR1	F	R	66	1	4	28	0.5	1309	0.765	1.260
AH	OAS1_0022_MR1	F	R	69	2	4	23	0.5	1447	0.757	1.275
AH	OAS1_0411_MR1	F	R	71	5	1	29	0.5	1346	0.742	1.499
AH	OAS1_0432_MR1	F	R	72	2	4	26	0.5	1453	0.773	1.342
AH	OAS1_0003_MR1	F	R	73	4	3	27	0.5	1454	0.708	1.019
AH	OAS1_0210_MR1	F	R	73	4	1	28	0.5	1676	0.722	1.166
AH	OAS1_0374_MR1	F	R	73	3	3	29	0.5	1238	0.76	1.179
AH	OAS1_0454_MR1	F	R	73	3	2	23	0.5	1536	0.73	1.296
AH	OAS1_0240_MR1	F	R	74	2		26	0.5	1171	0.736	1.186
AH	OAS1_0082_MR1	F	R	75	2	3	28	0.5	1407	0.776	1.198
AH	OAS1_0272_MR1	F	R	75	3	2	26	0.5	1355	0.745	1.189
AH	OAS1_0402_MR1	F	R	76	3	2	30	0.5	1350	0.763	1.470
AH	OAS1_0238_MR1	F	R	77	2	3	28	0.5	1484	0.786	0.881
AH	OAS1_0217_MR1	F	R	78	4	3	27	0.5	1393	0.692	1.377
AH	OAS1_0339_MR1	F	R	79	2		24	0.5	1211	0.694	1.128
AH	OAS1_0166_MR1	F	R	80	2		27	0.5	1475	0.771	1.255
AH	OAS1_0329_MR1	F	R	80	2	3	29	0.5	1209	0.76	1.253
AH	OAS1_0335_MR1	F	R	80	1	4	27	0.5	1654	0.678	1.339

AH	OAS1_0084_MR1	F	R	81	2		27	0.5	1453	0.727	1.094
AH	OAS1_0352_MR1	F	R	81	5	2	26	0.5	1174	0.743	1.451
AH	OAS1_0123_MR1	F	R	83	3	4	24	0.5	1282	0.797	1.061
AH	OAS1_0286_MR1	F	R	83	3	2	20	0.5	1476	0.751	1.449
AH	OAS1_0273_MR1	F	R	89	1	4	18	0.5	1480	0.676	1.013
AH	OAS1_0400_MR1	F	R	92	5	1	25	0.5	1774	0.644	1.418
AH	OAS1_0447_MR1	F	R	92	4	1	24	0.5	1388	0.739	1.337
AH	OAS1_0382_MR1	F	R	67	4		15	1	1288	0.763	1.300
AH	OAS1_0073_MR1	F	R	69	2	4	21	1	1495	0.655	1.186
AH	OAS1_0056_MR1	F	R	72	3	3	15	1	1324	0.668	0.989
AH	OAS1_0269_MR1	F	R	72	1	4	21	1	1489	0.683	1.300
AH	OAS1_0316_MR1	F	R	72	4	2	22	1	1493	0.69	1.024
AH	OAS1_0388_MR1	F	R	77	2	4	22	1	1350	0.736	1.058
AH	OAS1_0052_MR1	F	R	78	1	5	23	1	1462	0.697	1.088
AH	OAS1_0185_MR1	F	R	78	2	4	17	1	1314	0.739	1.201
AH	OAS1_0425_MR1	F	R	78	1	4	23	1	1461	0.715	1.123
AH	OAS1_0308_MR1	F	R	78	3	3	15	2	1401	0.703	1.142
AH	OAS1_0373_MR1	F	R	80	3	2	20	1	1732	0.692	1.208
AH	OAS1_0053_MR1	F	R	83	1	4	21	1	1384	0.699	1.329
AH	OAS1_0028_MR1	F	R	86	2	4	27	1	1449	0.738	1.040
AH	OAS1_0137_MR1	F	R	87	2	3	22	1	1499	0.672	1.060
AH	OAS1_0278_MR1	F	R	96	5	1	26	1	1465	0.684	1.355
NK	OAS1_0130_MR1	M	R	68	3	3	26	0	1444	0.789	1.261
NK	OAS1_0343_MR1	M	R	68	3	3	30	0	1441	0.811	1.076
NK	OAS1_0199_MR1	M	R	69	5	1	30	0	1601	0.784	1.326
NK	OAS1_0256_MR1	M	R	70	5	1	30	0	1660	0.739	1.205
NK	OAS1_0170_MR1	M	R	71	2	4	29	0	1455	0.725	1.108
NK	OAS1_0398_MR1	M	R	71	5	1	30	0	1769	0.716	1.349
NK	OAS1_0332_MR1	M	R	72	1	3	29	0	1734	0.762	1.164
NK	OAS1_0354_MR1	M	R	74	1	3	26	0	1367	0.776	1.252
NK	OAS1_0234_MR1	M	R	75	5	2	29	0	1534	0.771	1.258
NK	OAS1_0423_MR1	M	R	75	2	4	28	0	1511	0.749	1.462
NK	OAS1_0338_MR1	M	R	77	4	1	29	0	1818	0.736	1.368
NK	OAS1_0138_MR1	M	R	80	2	4	28	0	1689	0.706	1.427
NK	OAS1_0337_MR1	M	R	81	1	4	28	0	1750	0.676	1.337
NK	OAS1_0186_MR1	M	R	84	5	1	29	0	1707	0.731	1.143
NK	OAS1_0317_MR1	M	R	86	4	1	26	0	1501	0.702	1.118
NK	OAS1_0363_MR1	M	R	87	4	2	30	0	1398	0.702	1.216
NK	OAS1_0032_MR1	M	R	89	4	1	28	0	1631	0.682	1.374
NK	OAS1_0065_MR1	M	R	90	2	3	25	0	1301	0.645	1.124
NK	OAS1_0438_MR1	F	R	66	5	2	29	0	1191	0.787	1.521
NK	OAS1_0068_MR1	F	R	67	3	4	30	0	1508	0.805	1.096
NK	OAS1_0303_MR1	F	R	67	2	4	30	0	1221	0.831	1.285
NK	OAS1_0112_MR1	F	R	69	5	2	29	0	1536	0.733	1.291
NK	OAS1_0293_MR1	F	R	69	1	2	26	0	1384	0.783	1.412
NK	OAS1_0422_MR1	F	R	69	4	3	29	0	1380	0.809	1.087
NK	OAS1_0085_MR1	F	R	70	2	3	29	0	1283	0.791	1.168
NK	OAS1_0371_MR1	F	R	70	3	4	30	0	1361	0.783	1.332
NK	OAS1_0203_MR1	F	R	71	2	3	30	0	1360	0.779	1.190
NK	OAS1_0216_MR1	F	R	71	4	3	30	0	1503	0.792	1.181
NK	OAS1_0255_MR1	F	R	71	5	1	30	0	1426	0.737	1.144
NK	OAS1_0341_MR1	F	R	71	2	4	30	0	1479	0.772	1.328
NK	OAS1_0449_MR1	F	R	71	3	4	29	0	1264	0.818	1.254
NK	OAS1_0139_MR1	F	R	72	3	3	28	0	1512	0.779	1.309
NK	OAS1_0062_MR1	F	R	73	3	2	30	0	1456	0.754	1.231
NK	OAS1_0279_MR1	F	R	73	1	4	30	0	1475	0.721	1.057
NK	OAS1_0326_MR1	F	R	73	3	4	29	0	1272	0.7	1.316
NK	OAS1_0355_MR1	F	R	73	4	2	29	0	1123	0.79	0.996

NK	OAS1_0369_MR1	F	R	73	4	1	28	0	1295	0.772	1.380
NK	OAS1_0404_MR1	F	R	73	2	2	29	0	1465	0.776	1.320
NK	OAS1_0001_MR1	F	R	74	2	3	29	0	1344	0.743	1.190
NK	OAS1_0165_MR1	F	R	74	2	3	29	0	1395	0.787	1.219
NK	OAS1_0212_MR1	F	R	74	3		28	0	1614	0.697	1.024
NK	OAS1_0241_MR1	F	R	74	5	2	30	0	1400	0.754	1.240
NK	OAS1_0220_MR1	F	R	75	5	1	30	0	1317	0.742	1.268
NK	OAS1_0195_MR1	F	R	76	4	1	28	0	1346	0.766	1.190
NK	OAS1_0064_MR1	F	R	77	1	4	29	0	1583	0.767	1.174
NK	OAS1_0206_MR1	F	R	78	5	1	30	0	1243	0.747	1.438
NK	OAS1_0259_MR1	F	R	78	3	2	29	0	1334	0.773	1.169
NK	OAS1_0280_MR1	F	R	78	5	1	30	0	1440	0.67	1.315
NK	OAS1_0033_MR1	F	R	80	4	2	29	0	1323	0.735	1.380
NK	OAS1_0180_MR1	F	R	80	4	2	30	0	1496	0.745	1.270
NK	OAS1_0244_MR1	F	R	80	4	2	29	0	1341	0.737	1.012
NK	OAS1_0330_MR1	F	R	80	1	5	27	0	1381	0.752	1.003
NK	OAS1_0446_MR1	F	R	80	2	4	30	0	1390	0.748	0.965
NK	OAS1_0106_MR1	F	R	81	2	4	30	0	1230	0.717	1.281
NK	OAS1_0228_MR1	F	R	81	3	2	28	0	1486	0.759	1.217
NK	OAS1_0146_MR1	F	R	82	5	1	28	0	1513	0.742	1.284
NK	OAS1_0426_MR1	F	R	82	5	2	29	0	1316	0.791	1.563
NK	OAS1_0075_MR1	F	R	83	3	2	30	0	1335	0.72	1.165
NK	OAS1_0113_MR1	F	R	83	2	2	29	0	1569	0.768	1.289
NK	OAS1_0201_MR1	F	R	85	4	1	26	0	1460	0.754	0.972
NK	OAS1_0157_MR1	F	R	86	4	3	30	0	1293	0.756	1.290
NK	OAS1_0169_MR1	F	R	88	2	3	30	0	1445	0.718	0.992
NK	OAS1_0176_MR1	F	R	88	3	1	29	0	1398	0.712	1.198
NK	OAS1_0019_MR1	F	R	89	5	1	30	0	1536	0.715	1.162
NK	OAS1_0299_MR1	F	R	90	2	3	29	0	1475	0.671	1.289
NK	OAS1_0301_MR1	F	R	90	3	2	28	0	1495	0.761	1.263
NK	OAS1_0445_MR1	F	R	90	1	2	29	0	1362	0.673	1.388
NK	OAS1_0284_MR1	F	R	91	5	2	30	0	1714	0.746	1.297
NK	OAS1_0270_MR1	F	R	93	3	2	30	0	1272	0.703	1.072
NK	OAS1_0221_MR1	F	R	94	5	1	29	0	1474	0.696	1.279

EK-2 Selçuk Üniversitesi Tıp Fakültesi Dekanlığı tarafından verilen Girişimsel Olmayan Klinik Araştırmalar Etik Kurul İzni

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI

Toplantı Sayısı: 2016/17	Toplantı Tarihi : 09.11.2016

Karar Sayısı 2016/273 S.Ü. Tıp Fakültesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Elektronik Anabilim Dalı Öğretim Üyesi Doç.Dr. Seral ÖZŞEN'in, "Çoklu Değişken Yöntemlerle Alzheimer Hastalığının Sınıflandırılmasında Yenilikçi Yaklaşımlar" başlıklı araştırmasının değerlendirilme talebi ile ilgili 17.10.2016 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç.Dr. Seral ÖZŞEN'in, "Çoklu Değişken Yöntemlerle Alzheimer Hastalığının Sınıflandırılmasında Yenilikçi Yaklaşımlar" adlı araştırmanın kabulüne oy birliği ile karar verildi.

ASLI GİBİDİR
09/11/2016

Mahmut KESİK
Sekreterya

EK-3 Selçuk Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Bilgilendirilmiş Gönüllü Olur Formu Asgari İçeriği

SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU
BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU ASGARİ İÇERİĞİ

Araştırmanın Adı: Çoklu Değişken Yöntemlerle Alzheimer Hastalığının Sınıflandırılmasında Yenilikçi Yaklaşımlar
Proje Yürütücüsü/Araştırmacı: Arş. Gör. Muhammet Üsame ÖZİÇ

Bu çalışmada ülkemizde sıklıkla karşılaşılan Alzheimer Hastalığının klinik ve radyolojik bilgilerle araştırılması, hastalığın meydana getirdiği değişikliklerin incelenmesi, yeni teşhis yöntemleri geliştirilerek tanı ve müdahale süreçlerinin hızlandırılması hedeflenmektedir. Araştırma sırasında alınan verilerden kişiye ek bir maliyet oluşmayacaktır. Herhangi bir ilaç tedavisi uygulanmayacak, rutin test ve görüntüler alınacaktır.

Hastalığım nedeniyle……...
……..kliniğinden istenmiş olan ve benim durumumda şüphelenilen hastalıklar için rutin istenmekte olan tetkikler olarak bilgilendirileceğim; klinik, laboratuvar değerleri ve MR görüntülerinin "Çoklu Değişken Yöntemlerle Alzheimer Hastalığının Sınıflandırılmasında Yenilikçi Yaklaşımlar" adlı çalışmada klinik araştırma amacıyla kullanılmasına, hiçbir baskı ve zorlama olmaksızın kendi rızamla katılmayı kabul ediyor, kimlik bilgilerim gizli kalması şartıyla izin veriyorum. Çalışma ile ilgili bir sorum veya herhangi bir problemle karşılaşmam durumunda iletişim kurmak ve ve gerekli desteği almak üzere yirmidört saat boyunca Araştırma Görevlisi Dr. Aydın Talip YILDOĞAN'a --- telefonundan ulaşabileceğim bildirilmiştir.

Bana anlatılanları ve yukarıda yazılanları anladım. Bu formun bir kopyasını aldım.
Hasta Adı Soyadı:……
İmzası:……
Tarih(gün/ay/yıl):……/……/……..

CDR™
Clinical Dementia Rating Assessment Protocol

Subject Initials _____

KLİNİK DEMANS DERECELENDİRME (CDR)

KLİNİK DEMANS DERECELENDİRME (CDR):	0	0.5	1	2	3

	Bozukluk				
	Yok 0	Şüpheli 0.5	Hafif 1	Orta 2	Ciddi 3
Bellek	Bellek kaybı yok ya da hafif, belirsiz unutkanlık	Hafif aşikar unutkanlık; olayların kısmen hatırlanabilmesi; "selim" unutkanlık	Orta derecede unutkanlık; yakın dönem olayları için daha belirgin; unutkanlık günlük faaliyetleri engelliyor	Ciddi unutkanlık; yalnızca çok iyi öğrenilmiş materyal kalmış; yeni materyal hızla kayboluyor	Ciddi unutkanlık; Yalnızca parçalar kalır
Oryantasyon	Tümüyle oryante	Zaman ilişkilerindeki hafif güçlük dışında tümüyle oryante	Zaman ilişkilerinde orta derecede güçlük; muayene yerini tanıyor; fakat dışarıda coğrafi dezoryantasyonu olabilir	Zamanla ilişkilerinde ciddi güçlük; genellikle zamana, sıklıkla da mekana dezoryante	Yalnızca kişilere oryante
Yargılama & Sorun çözme	Gündelik sorunları çözüyor ve işe ve paraya ilişkin işlerin iyi bir şekilde üstesinden geliyor; geçmiş performansı ile ilişkili yargılamalar iyi	Sorunları çözmede, benzerliklerde ve farklılıklarda hafif bozukluk	Sorunları ele almada, benzerlikleri ve farklılıkları kavramada orta düzeyde bozukluk; toplumsal yargılama genellikle korunmuştur	Sorunları ele almada, benzerlikleri ve farklılıkları kavramada ciddi düzeyde bozukluk; toplumsal yargılama genellikle bozuk	Yargılama yapamıyor ve sorun çözemiyor
Ev Dışı Faaliyetler	İşte, alışverişte, gönüllü ve sosyal gruplarda her zamanki düzeyde bağımsız işlevsellik	Bu faaliyetlerde hafif bozulma	Bu faaliyetlerin bir kısmını halen sürdürse de bağımsız işlev göremiyor; yüzeysel bir bakışla normal görünüyor	Evin dışında bağımsız işlevini tümüyle yitirmiş Aile evinin dışındaki faaliyetlere götürülebilecek kadar iyi görünüyor	Aile evinin dışındaki faaliyetlere götürülmeyecek kadar hasta görünüyor
Ev ve Hobiler	Ev yaşamı, hobiler ve entelektüel ilgiler iyi korunmuş	Ev yaşamı, hobiler ve entelektüel ilgilerde hafif bozulma	Evdeki işlevlerde hafif fakat aşikar bozukluk; güç ev işleri, daha karmaşık hobiler ve ilgiler terkedilmiş	Yalnızca basit ev işleri devam ediyor; ilgiler son derece sınırlı, zayıf biçimde sürüyor	Evde önemli bir işlevi yok
Kişisel Bakım	Kendine bakımda tam yeterlik		Gayrete getirilmesi gerekiyor	Elbise giyme, hijyen, kişisel eşyaların bakımı için yardıma ihtiyaç duyuyor	Kişisel bakım için çok fazla yardıma ihtiyaç duyuyor; sık idrar ve dışkı kaçırıyor

Diğer nedenlere bağlı olan bozuklukları değil, yalnızca kognitif kayba bağlı olarak daha önceki alışıldık düzeyden gerilemeyi puanlayınız.

EK-5 Lokal Hacimler için 127 bölgenin AH ve NK'daki ortalama, standart sapma ve iki grup arasındaki farklılığın bağımsız örneklem t-testi ile elde edilen p değerleri

	Ham					Ham/GM					Ham/PRNKM					Ham/TBH				
	AH		NK		İstat.	AH		NK		İstat.	AH		NK		İstat.	AH		NK		İstat.
	Ort	SS	Ort	SS	p	Ort	SS	Ort	SS	p	Ort	SS	Ort	SS	p	Ort	SS	Ort	SS	p
Amygdala_L	0.8823	0.1351	0.9928	0.1079	4E-07	0.002	0.0002	0.0017	1E-04	6E-08	0.0009	0.0001	0.001	9E-05	7E-09	0.0006	8E-05	0.0007	7E-05	2E-11
Amygdala_R	0.9533	0.1505	1.0902	0.116	1E-08	0.002	0.0002	0.0019	1E-04	3E-09	0.0009	0.0001	0.001	9E-05	7E-10	0.0007	0.0001	0.0008	7E-05	2E-12
Angular_L	3.338	0.5627	3.562	0.5293	0.017	0.006	0.0006	0.0062	7E-04	0.015	0.0032	0.0004	0.0034	4E-04	0.0041	0.0024	0.0003	0.0026	0.0003	0.0002
Angular_R	4.4945	0.7322	4.6786	0.6476	0.117	0.008	0.0009	0.0081	8E-04	0.2889	0.0044	0.0006	0.0045	5E-04	0.1315	0.0033	0.0005	0.0035	0.0004	0.0093
Calcarine_L	7.2523	1.3934	7.1272	1.18	0.567	0.013	0.0018	0.0123	0.002	0.0965	0.007	0.001	0.0068	8E-04	0.2584	0.0053	0.0008	0.0053	0.0007	0.987
Calcarine_R	5.4331	0.9255	5.3497	0.9371	0.597	0.01	0.0012	0.0092	0.001	0.0851	0.0053	0.0006	0.0051	6E-04	0.2369	0.004	0.0005	0.004	0.0005	0.9877
Caudate_L	4.068	0.9272	3.7623	0.7348	0.032	0.007	0.0016	0.0065	0.001	0.0043	0.004	0.0009	0.0036	7E-04	0.0136	0.003	0.0007	0.0028	0.0005	0.0672
Caudate_R	4.1152	0.99	3.7928	0.7285	0.03	0.007	0.0017	0.0066	0.001	0.0039	0.004	0.001	0.0036	7E-04	0.012	0.003	0.0007	0.0028	0.0005	0.0592
Cerebelum_10_L	0.21	0.0341	0.2079	0.0302	0.705	4E-04	6E-05	0.0004	4E-05	0.1421	0.0002	3E-05	0.0002	3E-05	0.377	0.0002	2E-05	0.0002	2E-05	0.8804
Cerebelum_10_R	0.2292	0.0455	0.2293	0.0374	0.998	4E-04	8E-05	0.0004	6E-05	0.3968	0.0002	4E-05	0.0002	3E-05	0.7089	0.0002	3E-05	0.0002	3E-05	0.6684
Cerebelum_3_L	0.3663	0.0516	0.3549	0.0529	0.197	6E-04	9E-05	0.0006	8E-05	0.0096	0.0004	5E-05	0.0003	4E-05	0.0539	0.0003	4E-05	0.0003	4E-05	0.4307
Cerebelum_3_R	0.5051	0.0731	0.4666	0.056	6E-04	9E-04	0.0001	0.0008	8E-05	4E-07	0.0005	6E-05	0.0004	5E-05	2E-05	0.0004	5E-05	0.0003	4E-05	0.0029
Cerebelum_4_5_L	4.2136	0.5133	4.047	0.4615	0.045	0.007	0.0007	0.007	5E-04	2E-05	0.0041	0.0004	0.0039	3E-04	0.0012	0.0031	0.0003	0.003	0.0003	0.1123
Cerebelum_4_5_R	3.6459	0.4863	3.5077	0.4093	0.071	0.006	0.0007	0.0061	5E-04	0.0002	0.0035	0.0004	0.0034	3E-04	0.0051	0.0027	0.0003	0.0026	0.0002	0.1808
Cerebelum_6_L	7.4339	0.9779	7.2272	0.8784	0.19	0.013	0.0014	0.0125	0.001	0.0018	0.0072	0.0008	0.0069	6E-04	0.0247	0.0054	0.0006	0.0054	0.0005	0.4754
Cerebelum_6_R	7.6287	0.9547	7.4785	0.923	0.346	0.014	0.0015	0.0129	0.001	0.0105	0.0074	0.0008	0.0072	7E-04	0.0802	0.0056	0.0007	0.0056	0.0006	0.7755
Cerebelum_7b_L	2.0454	0.3478	2.0187	0.2453	0.601	0.004	0.0006	0.0035	4E-04	0.1136	0.002	0.0003	0.0019	2E-04	0.3346	0.0015	0.0002	0.0015	0.0002	0.8943
Cerebelum_7b_R	1.8205	0.2914	1.7931	0.2431	0.547	0.003	0.0005	0.0031	4E-04	0.102	0.0018	0.0003	0.0017	2E-04	0.3223	0.0013	0.0002	0.0013	0.0002	0.9102
Cerebelum_8_L	6.9219	1.0172	6.8621	0.8274	0.704	0.012	0.0014	0.0119	0.001	0.097	0.0067	0.0008	0.0066	7E-04	0.3747	0.0051	0.0006	0.0051	0.0005	0.6464
Cerebelum_8_R	8.4055	1.1738	8.3021	1.0439	0.583	0.015	0.0017	0.0144	0.001	0.0555	0.0082	0.001	0.008	9E-04	0.2598	0.0062	0.0007	0.0062	0.0007	0.8377
Cerebelum_9_L	3.0918	0.4196	2.9851	0.3869	0.12	0.005	0.0006	0.0052	6E-04	0.0031	0.003	0.0004	0.0029	3E-04	0.0235	0.0023	0.0003	0.0022	0.0003	0.3389
Cerebelum_9_R	2.9502	0.4575	2.826	0.4047	0.091	0.005	0.0007	0.0049	6E-04	0.0032	0.0029	0.0004	0.0027	3E-04	0.0193	0.0022	0.0003	0.0021	0.0003	0.2343
Cerebelum_Crus1_L	8.2732	1.1148	8.1273	1.0319	0.423	0.015	0.0017	0.0141	0.001	0.0242	0.008	0.0009	0.0078	8E-04	0.1325	0.0061	0.0008	0.006	0.0006	0.859
Cerebelum_Crus1_R	8.0625	1.1323	7.9635	1.0911	0.599	0.014	0.0019	0.0138	0.002	0.0765	0.0078	0.001	0.0077	9E-04	0.2675	0.0059	0.0008	0.0059	0.0007	0.9438
Cerebelum_Crus2_L	6.603	1.0357	6.6071	0.8713	0.979	0.012	0.0017	0.0114	0.001	0.3399	0.0064	0.0009	0.0064	8E-04	0.7404	0.0048	0.0007	0.0049	0.0007	0.4637
Cerebelum_Crus2_R	6.0086	0.9159	5.8665	0.7835	0.325	0.011	0.0014	0.0102	0.001	0.0357	0.0058	0.0008	0.0057	7E-04	0.158	0.0044	0.0006	0.0044	0.0006	0.7841
Cingulum_Ant_L	4.5235	0.5704	4.7503	0.6049	0.024	0.008	0.0007	0.0082	7E-04	0.0888	0.0044	0.0004	0.0046	4E-04	0.0154	0.0033	0.0003	0.0035	0.0003	0.0002
Cingulum_Ant_R	4.377	0.6188	4.4996	0.5354	0.212	0.008	0.0007	0.0078	7E-04	0.6493	0.0042	0.0004	0.0043	4E-04	0.2229	0.0032	0.0003	0.0033	0.0003	0.0087
Cingulum_Mid_L	6.0004	0.7576	6.2176	0.7328	0.087	0.011	0.0009	0.0107	8E-04	0.3224	0.0058	0.0005	0.006	5E-04	0.0805	0.0044	0.0005	0.0046	0.0004	0.0023
Cingulum_Mid_R	6.6538	0.8629	6.8864	0.7544	0.092	0.012	0.0008	0.0119	7E-04	0.2383	0.0064	0.0006	0.0066	4E-04	0.053	0.0049	0.0005	0.0051	0.0004	0.0011

Cingulum_Post_L	1.153	0.1853	1.2126	0.1858	0.059	0.002	0.0002	0.0021	2E-04	0.1062	0.0011	0.0001	0.0012	1E-04	0.0261	0.0008	0.0001	0.0009	9E-05	0.0008
Cingulum_Post_R	0.6652	0.1099	0.706	0.1039	0.026	0.001	0.0001	0.0012	1E-04	0.0354	0.0006	7E-05	0.0007	7E-05	0.0069	0.0005	6E-05	0.0005	6E-05	0.0001
Cuneus_L	4.1217	0.7676	4.0739	0.6064	0.684	0.007	0.001	0.007	7E-04	0.1095	0.004	0.0005	0.0039	4E-04	0.3513	0.003	0.0004	0.003	0.0003	0.8206
Cuneus_R	3.6454	0.6026	3.7068	0.5672	0.536	0.006	0.0008	0.0064	7E-04	0.7987	0.0035	0.0004	0.0036	4E-04	0.687	0.0027	0.0004	0.0028	0.0003	0.1371
Frontal_Inf_Oper_L	2.3752	0.3805	2.3933	0.3259	0.762	0.004	0.0005	0.0041	4E-04	0.4148	0.0023	0.0003	0.0023	2E-04	0.8796	0.0017	0.0002	0.0018	0.0002	0.2966
Frontal_Inf_Oper_R	3.2693	0.4171	3.2987	0.3961	0.669	0.006	0.0005	0.0057	5E-04	0.402	0.0032	0.0003	0.0032	3E-04	0.9918	0.0024	0.0003	0.0025	0.0002	0.1965
Frontal_Inf_Orb_L	5.0226	0.638	5.176	0.5769	0.138	0.009	0.0008	0.009	8E-04	0.5404	0.0049	0.0005	0.005	5E-04	0.1679	0.0037	0.0004	0.0039	0.0004	0.0051
Frontal_Inf_Orb_R	4.666	0.5693	4.7919	0.5178	0.173	0.008	0.0008	0.0083	7E-04	0.7514	0.0045	0.0005	0.0046	4E-04	0.2613	0.0034	0.0004	0.0036	0.0003	0.0107
Frontal_Inf_Tri_L	5.4736	0.749	5.6699	0.7407	0.121	0.01	0.0009	0.0098	9E-04	0.363	0.0053	0.0005	0.0054	5E-04	0.0897	0.004	0.0004	0.0042	0.0004	0.0027
Frontal_Inf_Tri_R	4.5137	0.5907	4.5531	0.5312	0.679	0.008	0.0007	0.0079	7E-04	0.4042	0.0044	0.0004	0.0044	4E-04	0.9837	0.0033	0.0003	0.0034	0.0003	0.138
Frontal_Med_Orb_L	2.2501	0.3424	2.346	0.2531	0.062	0.004	0.0004	0.0041	3E-04	0.1735	0.0022	0.0002	0.0023	2E-04	0.0311	0.0016	0.0002	0.0017	0.0001	0.0003
Frontal_Med_Orb_R	2.7034	0.3992	2.7842	0.3295	0.194	0.005	0.0005	0.0048	4E-04	0.5696	0.0026	0.0003	0.0027	2E-04	0.1763	0.002	0.0002	0.0021	0.0002	0.0068
Frontal_Mid_L	11	1.5854	11.233	1.2653	0.339	0.019	0.0017	0.0194	0.002	0.8983	0.0106	0.0009	0.0108	9E-04	0.2995	0.008	0.0008	0.0083	0.0007	0.011
Frontal_Mid_Orb_L	2.6205	0.365	2.6697	0.3398	0.411	0.005	0.0005	0.0046	4E-04	0.8716	0.0025	0.0003	0.0026	3E-04	0.531	0.0019	0.0002	0.002	0.0002	0.044
Frontal_Mid_Orb_R	3.2689	0.3977	3.3115	0.3745	0.515	0.006	0.0006	0.0057	5E-04	0.5321	0.0032	0.0003	0.0032	3E-04	0.7997	0.0024	0.0002	0.0025	0.0002	0.0837
Frontal_Mid_R	12.707	1.6807	12.826	1.4372	0.653	0.022	0.0018	0.0222	0.002	0.4026	0.0123	0.001	0.0123	9E-04	0.8835	0.0093	0.0009	0.0095	0.0007	0.0678
Frontal_Sup_L	7.5728	1.0303	7.5598	0.8683	0.936	0.013	0.0012	0.0131	0.001	0.1272	0.0073	0.0007	0.0073	6E-04	0.5408	0.0055	0.0006	0.0056	0.0005	0.3529
Frontal_Sup_Medial_L	6.1947	0.8321	6.2839	0.6228	0.474	0.011	0.001	0.0109	9E-04	0.7456	0.006	0.0005	0.0061	5E-04	0.5526	0.0045	0.0004	0.0047	0.0004	0.0266
Frontal_Sup_Medial_R	5.1586	0.6278	5.3182	0.519	0.103	0.009	0.0008	0.0092	7E-04	0.4805	0.005	0.0004	0.0051	4E-04	0.1034	0.0038	0.0003	0.004	0.0003	0.0006
Frontal_Sup_Orb_L	3.3661	0.4087	3.4003	0.3454	0.594	0.006	0.0005	0.0059	5E-04	0.4478	0.0033	0.0003	0.0033	3E-04	0.8459	0.0025	0.0002	0.0025	0.0002	0.0647
Frontal_Sup_Orb_R	3.0992	0.4107	3.1492	0.3384	0.433	0.005	0.0005	0.0055	4E-04	0.7433	0.003	0.0003	0.003	2E-04	0.5315	0.0023	0.0002	0.0023	0.0002	0.0257
Frontal_Sup_R	8.639	1.0578	8.8331	1.058	0.28	0.015	0.0011	0.0153	0.001	0.9772	0.0084	0.0006	0.0085	7E-04	0.3103	0.0063	0.0005	0.0066	0.0006	0.0082
Fusiform_L	8.3497	1.1025	8.8323	0.9175	0.006	0.015	0.0011	0.0153	9E-04	0.0022	0.0081	0.0007	0.0085	6E-04	0.0003	0.0061	0.0006	0.0066	0.0005	7E-07
Fusiform_R	8.6739	1.2627	9.1792	0.9532	0.008	0.015	0.0015	0.0159	0.001	0.0082	0.0084	0.0009	0.0088	6E-04	0.0019	0.0063	0.0007	0.0068	0.0005	2E-05
Heschl_L	0.5616	0.1118	0.6332	0.1237	5E-04	1E-03	0.0002	0.0011	2E-04	0.0005	0.0005	9E-05	0.0006	9E-05	0.0001	0.0004	8E-05	0.0005	8E-05	1E-05
Heschl_R	0.6096	0.128	0.6686	0.131	0.008	0.001	0.0002	0.0012	2E-04	0.0113	0.0006	0.0001	0.0006	1E-04	0.0039	0.0004	9E-05	0.0005	9E-05	0.0007
Hippocampus_L	3.1564	0.5577	3.7639	0.4503	6E-11	0.006	0.0008	0.0065	6E-04	1E-12	0.0031	0.0005	0.0036	3E-04	2E-13	0.0023	0.0004	0.0028	0.0003	1E-14
Hippocampus_R	2.7701	0.5744	3.4512	0.4118	3E-13	0.005	0.0009	0.006	5E-04	2E-14	0.0027	0.0005	0.0033	3E-04	3E-15	0.002	0.0004	0.0026	0.0003	3E-16
Insula_L	6.519	0.8683	6.7844	0.8093	0.064	0.012	0.0011	0.0117	0.001	0.2543	0.0063	0.0007	0.0065	6E-04	0.0724	0.0048	0.0005	0.005	0.0005	0.0019
Insula_R	6.1551	0.833	6.3989	0.6575	0.057	0.011	0.001	0.0111	8E-04	0.1803	0.006	0.0006	0.0062	5E-04	0.0391	0.0045	0.0005	0.0048	0.0004	0.0007
Lingual_L	6.5202	0.8197	6.5347	0.7289	0.912	0.012	0.0008	0.0113	9E-04	0.1373	0.0063	0.0004	0.0063	5E-04	0.7159	0.0048	0.0004	0.0049	0.0004	0.148
Lingual_R	6.8191	0.8628	6.9607	0.7763	0.309	0.012	0.0009	0.012	9E-04	0.9951	0.0066	0.0005	0.0067	5E-04	0.3341	0.005	0.0004	0.0052	0.0004	0.008
Occipital_Inf_L	2.5363	0.4068	2.6929	0.4499	0.033	0.004	0.0005	0.0047	6E-04	0.0609	0.0025	0.0003	0.0026	4E-04	0.0191	0.0019	0.0002	0.002	0.0003	0.0008

Occipital_Inf_R	2.9906	0.5694	2.9679	0.5027	0.803	0.005	0.0007	0.0051	7E-04	0.2551	0.0029	0.0004	0.0029	4E-04	0.5835	0.0022	0.0003	0.0022	0.0003	0.6833
Occipital_Mid_L	9.3427	1.3071	9.6466	1.4364	0.193	0.016	0.0014	0.0167	0.002	0.5204	0.009	0.0008	0.0093	1E-03	0.1625	0.0068	0.0007	0.0072	0.0008	0.0103
Occipital_Mid_R	5.6268	0.9222	5.902	0.9139	0.078	0.01	0.0012	0.0102	0.001	0.1803	0.0054	0.0007	0.0057	6E-04	0.0543	0.0041	0.0006	0.0044	0.0005	0.0045
Occipital_Sup_L	2.8758	0.5216	2.8937	0.4186	0.824	0.005	0.0007	0.005	5E-04	0.4927	0.0028	0.0004	0.0028	3E-04	0.9634	0.0021	0.0003	0.0021	0.0002	0.2867
Occipital_Sup_R	3.2467	0.5328	3.3194	0.5373	0.423	0.006	0.0006	0.0057	7E-04	0.9498	0.0031	0.0004	0.0032	4E-04	0.498	0.0024	0.0003	0.0025	0.0003	0.0838
Olfactory_L	1.1625	0.1587	1.219	0.1412	0.028	0.002	0.0002	0.0021	1E-04	0.0908	0.0011	0.0001	0.0012	8E-05	0.0137	0.0008	9E-05	0.0009	7E-05	5E-05
Olfactory_R	1.2269	0.169	1.2944	0.1537	0.015	0.002	0.0002	0.0022	2E-04	0.0287	0.0012	0.0001	0.0012	1E-04	0.0058	0.0009	1E-04	0.001	8E-05	6E-05
Pallidum_L	0.1483	0.0616	0.1212	0.0507	0.005	3E-04	0.0001	0.0002	9E-05	0.0026	0.0001	6E-05	0.0001	5E-05	0.0048	0.0001	5E-05	9E-05	4E-05	0.0139
Pallidum_R	0.1169	0.0567	0.0971	0.0443	0.023	2E-04	1E-04	0.0002	8E-05	0.0138	0.0001	5E-05	9E-05	4E-05	0.0211	9E-05	4E-05	7E-05	3E-05	0.0459
ParaHippocampal_L	3.0407	0.3993	3.2739	0.297	1E-04	0.005	0.0005	0.0057	4E-04	0.0002	0.003	0.0003	0.0032	2E-04	1E-05	0.0022	0.0002	0.0024	0.0002	1E-09
ParaHippocampal_R	3.7296	0.5334	4.1182	0.3745	2E-06	0.007	0.0007	0.0071	4E-04	8E-07	0.0036	0.0004	0.004	3E-04	6E-08	0.0027	0.0003	0.0031	0.0002	6E-12
Paracentral_Lobule_L	2.7064	0.5216	2.6213	0.3381	0.254	0.005	0.0008	0.0045	5E-04	0.0275	0.0026	0.0004	0.0025	3E-04	0.103	0.002	0.0003	0.0019	0.0002	0.5807
Paracentral_Lobule_R	1.9704	0.3672	1.8688	0.3119	0.08	0.003	0.0005	0.0032	5E-04	0.0039	0.0019	0.0003	0.0018	3E-04	0.0214	0.0014	0.0002	0.0014	0.0002	0.1563
Parietal_Inf_L	6.5596	1.0318	6.8965	0.8042	0.033	0.012	0.0012	0.0119	0.001	0.0524	0.0064	0.0007	0.0066	6E-04	0.0153	0.0048	0.0006	0.0051	0.0005	0.0006
Parietal_Inf_R	3.2774	0.4949	3.4354	0.4522	0.051	0.006	0.0007	0.0059	6E-04	0.1544	0.0032	0.0004	0.0033	4E-04	0.054	0.0024	0.0003	0.0026	0.0003	0.0035
Parietal_Sup_L	4.4862	0.7978	4.5465	0.6129	0.617	0.008	0.0009	0.0079	9E-04	0.8107	0.0043	0.0005	0.0044	5E-04	0.6741	0.0033	0.0004	0.0034	0.0004	0.1228
Parietal_Sup_R	3.7331	0.5727	3.7636	0.4175	0.719	0.007	0.0007	0.0065	7E-04	0.5793	0.0036	0.0004	0.0036	4E-04	0.8532	0.0027	0.0003	0.0028	0.0003	0.1425
Postcentral_L	8.2774	0.989	8.4521	0.8777	0.271	0.015	0.0011	0.0146	9E-04	0.9303	0.008	0.0007	0.0081	5E-04	0.3691	0.0061	0.0006	0.0063	0.0005	0.0101
Postcentral_R	7.8437	1.0166	8.0716	0.9734	0.178	0.014	0.0012	0.014	0.001	0.6077	0.0076	0.0007	0.0078	8E-04	0.2104	0.0057	0.0006	0.006	0.0007	0.0135
Precentral_L	7.6995	0.9987	7.7159	0.8493	0.917	0.014	0.0011	0.0133	9E-04	0.1449	0.0075	0.0006	0.0074	5E-04	0.6496	0.0056	0.0005	0.0057	0.0005	0.1941
Precentral_R	6.7966	0.9193	6.8047	0.8869	0.958	0.012	0.0011	0.0118	0.001	0.178	0.0066	0.0007	0.0065	6E-04	0.6042	0.005	0.0006	0.0051	0.0005	0.3692
Precuneus_L	9.1781	1.4682	9.4506	1.1089	0.217	0.016	0.0015	0.0164	0.001	0.4342	0.0089	0.0009	0.0091	8E-04	0.1161	0.0067	0.0007	0.007	0.0006	0.0037
Precuneus_R	8.9006	1.3645	9.2269	1.1296	0.126	0.016	0.0015	0.016	0.001	0.2639	0.0086	0.0009	0.0089	7E-04	0.0643	0.0065	0.0007	0.0069	0.0005	0.0017
Putamen_L	3.1154	0.5971	3.2037	0.6243	0.394	0.006	0.0011	0.0056	0.001	0.9341	0.003	0.0006	0.0031	6E-04	0.6674	0.0023	0.0005	0.0024	0.0005	0.2399
Putamen_R	2.9892	0.675	3.0195	0.6058	0.78	0.005	0.0012	0.0052	0.001	0.7238	0.0029	0.0007	0.0029	6E-04	0.9624	0.0022	0.0006	0.0023	0.0005	0.5489
Rectus_L	2.6807	0.3515	2.837	0.2864	0.005	0.005	0.0004	0.0049	4E-04	0.0111	0.0026	0.0003	0.0027	2E-04	0.0014	0.002	0.0002	0.0021	0.0002	3E-06
Rectus_R	2.6802	0.3633	2.8096	0.2958	0.022	0.005	0.0004	0.0049	3E-04	0.0518	0.0026	0.0003	0.0027	2E-04	0.0073	0.002	0.0002	0.0021	0.0001	2E-05
Rolandic_Oper_L	2.794	0.3402	2.8461	0.3433	0.369	0.005	0.0004	0.0049	4E-04	0.7657	0.0027	0.0002	0.0027	2E-04	0.5545	0.002	0.0002	0.0021	0.0002	0.025
Rolandic_Oper_R	3.8041	0.5174	3.8452	0.4793	0.627	0.007	0.0006	0.0066	6E-04	0.488	0.0037	0.0003	0.0037	3E-04	0.8684	0.0028	0.0003	0.0029	0.0003	0.1074
Supp_Motor_Area_L	5.3442	0.8792	5.2974	0.6661	0.723	0.009	0.0011	0.0092	8E-04	0.1171	0.0052	0.0006	0.0051	5E-04	0.4292	0.0039	0.0005	0.0039	0.0004	0.6064
Supp_Motor_Area_R	6.1213	0.8825	6.1047	0.7762	0.906	0.011	0.0011	0.0106	0.001	0.1973	0.0059	0.0006	0.0059	6E-04	0.6194	0.0045	0.0005	0.0045	0.0005	0.3907
SupraMarginal_L	3.3948	0.5138	3.558	0.4299	0.043	0.006	0.0007	0.0062	6E-04	0.1348	0.0033	0.0004	0.0034	3E-04	0.0321	0.0025	0.0003	0.0026	0.0003	0.0006
SupraMarginal_R	4.9161	0.7255	5.0849	0.611	0.139	0.009	0.0009	0.0088	8E-04	0.4417	0.0048	0.0005	0.0049	4E-04	0.1484	0.0036	0.0004	0.0038	0.0004	0.0099

Temporal_Inf_L	10.473	1.5333	11.342	1.1524	2E-04	0.019	0.0019	0.0196	0.001	6E-05	0.0102	0.0011	0.0109	7E-04	9E-06	0.0077	0.0009	0.0084	0.0006	1E-08
Temporal_Inf_R	11.151	1.8194	11.872	1.2004	0.006	0.02	0.0024	0.0205	0.001	0.0081	0.0108	0.0014	0.0114	8E-04	0.0024	0.0082	0.0012	0.0088	0.0006	4E-05
Temporal_Mid_L	13.618	1.9592	14.679	1.5187	5E-04	0.024	0.002	0.0254	0.002	2E-05	0.0132	0.0013	0.0141	0.001	6E-06	0.01	0.0011	0.0109	0.0009	7E-08
Temporal_Mid_R	11.972	1.9267	13.057	1.4886	3E-04	0.021	0.0023	0.0226	0.001	1E-05	0.0116	0.0014	0.0125	9E-04	6E-06	0.0088	0.0012	0.0097	0.0008	2E-07
Temporal_Pole_Mid_L	2.3657	0.4062	2.5425	0.2907	0.004	0.004	0.0006	0.0044	4E-04	0.0147	0.0023	0.0003	0.0025	3E-04	0.0034	0.0017	0.0003	0.0019	0.0002	5E-05
Temporal_Pole_Mid_R	2.8432	0.5571	3.0476	0.3771	0.012	0.005	0.0009	0.0053	6E-04	0.0373	0.0028	0.0005	0.0029	3E-04	0.0124	0.0021	0.0004	0.0023	0.0002	0.0005
Temporal_Pole_Sup_L	2.5712	0.4591	2.8502	0.3383	7E-05	0.005	0.0006	0.0049	5E-04	7E-05	0.0025	0.0004	0.0027	3E-04	1E-05	0.0019	0.0003	0.0021	0.0002	9E-08
Temporal_Pole_Sup_R	2.886	0.4767	3.1385	0.3798	7E-04	0.005	0.0007	0.0054	6E-04	0.0014	0.0028	0.0004	0.003	3E-04	0.0003	0.0021	0.0003	0.0023	0.0002	3E-06
Temporal_Sup_L	6.2656	0.8137	6.6746	0.8624	0.005	0.011	0.0011	0.0115	0.001	0.0115	0.0061	0.0006	0.0064	6E-04	0.001	0.0046	0.0005	0.005	0.0005	1E-05
Temporal_Sup_R	7.6914	1.0549	8.0266	0.9509	0.05	0.014	0.0013	0.0139	0.001	0.1525	0.0075	0.0007	0.0077	6E-04	0.0307	0.0056	0.0006	0.006	0.0005	0.001
Thalamus_L	2.716	0.3952	3.066	0.4366	2E-06	0.005	0.0006	0.0053	7E-04	1E-05	0.0026	0.0004	0.003	4E-04	5E-06	0.002	0.0003	0.0023	0.0003	2E-07
Thalamus_R	2.9308	0.4789	3.2756	0.4631	3E-05	0.005	0.0008	0.0057	7E-04	0.0001	0.0028	0.0004	0.0032	4E-04	4E-05	0.0022	0.0004	0.0024	0.0003	2E-06
Vermis_10	0.1146	0.0203	0.1039	0.0179	0.001	2E-04	4E-05	0.0002	3E-05	4E-05	0.0001	2E-05	0.0001	2E-05	0.0003	8E-05	2E-05	8E-05	1E-05	0.0044
Vermis_1_2	0.1627	0.0197	0.1594	0.0179	0.303	3E-04	3E-05	0.0003	3E-05	0.0184	0.0002	2E-05	0.0002	2E-05	0.1174	0.0001	2E-05	0.0001	1E-05	0.7607
Vermis_3	0.6183	0.0713	0.6034	0.073	0.224	0.001	0.0001	0.001	1E-04	0.0101	0.0006	7E-05	0.0006	7E-05	0.0759	0.0005	6E-05	0.0004	5E-05	0.5808
Vermis_4_5	2.1186	0.267	1.9931	0.2289	0.003	0.004	0.0005	0.0035	3E-04	9E-06	0.0021	0.0002	0.0019	2E-04	0.0003	0.0016	0.0002	0.0015	0.0001	0.0141
Vermis_6	1.1927	0.159	1.1213	0.1405	0.006	0.002	0.0003	0.0019	2E-04	4E-05	0.0012	0.0002	0.0011	1E-04	0.0005	0.0009	0.0001	0.0008	9E-05	0.0252
Vermis_7	0.7119	0.0844	0.6986	0.0764	0.333	0.001	0.0002	0.0012	1E-04	0.0268	0.0007	9E-05	0.0007	7E-05	0.1377	0.0005	7E-05	0.0005	5E-05	0.807
Vermis_8	1.0394	0.1431	1.0257	0.117	0.535	0.002	0.0002	0.0018	2E-04	0.0555	0.001	0.0001	0.001	1E-04	0.2323	0.0008	9E-05	0.0008	8E-05	0.8915
Vermis_9	0.7765	0.1059	0.7553	0.0937	0.213	0.001	0.0002	0.0013	1E-04	0.0105	0.0008	1E-04	0.0007	8E-05	0.0619	0.0006	7E-05	0.0006	6E-05	0.5426
Cerebellum_Anterior_Lobe	23.028	2.5929	22.212	2.2836	0.049	0.041	0.0035	0.0385	0.002	1E-05	0.0224	0.0019	0.0214	0.001	0.001	0.0169	0.0016	0.0165	0.0013	0.1627
Cerebellum_Posterior_Lobe	56.995	6.6663	56.194	5.8442	0.449	0.101	0.0098	0.0975	0.008	0.0198	0.0554	0.0054	0.0542	0.005	0.148	0.0418	0.0044	0.0419	0.0039	0.8944
Frontal_Lobe	147.73	15.964	149.32	13.601	0.526	0.261	0.0114	0.2589	0.011	0.2481	0.1432	0.0073	0.1438	0.007	0.6409	0.108	0.0067	0.1111	0.0058	0.0039
Left_Cerebellum	39.771	4.6068	39.096	3.8229	0.345	0.07	0.0064	0.0678	0.005	0.0055	0.0386	0.0036	0.0377	0.003	0.0735	0.0291	0.0029	0.0291	0.0024	0.9578
Left_Cerebrum	225.18	24.171	231.3	19.992	0.103	0.398	0.012	0.4009	0.007	0.0561	0.2182	0.0097	0.2226	0.007	0.0022	0.1645	0.0095	0.172	0.0068	3E-07
Limbic_Lobe	52.924	6.069	55.863	5.3426	0.003	0.093	0.0045	0.0968	0.004	3E-06	0.0513	0.0032	0.0538	0.002	9E-07	0.0387	0.0028	0.0415	0.002	1E-10
Occipital_Lobe	55.071	7.5035	55.707	7.0467	0.605	0.097	0.0065	0.0964	0.007	0.5512	0.0533	0.0038	0.0535	0.004	0.6931	0.0402	0.0035	0.0414	0.0035	0.0462
Parietal_Lobe	67.215	8.7059	68.916	6.7053	0.196	0.119	0.0074	0.1194	0.006	0.4525	0.0651	0.005	0.0663	0.004	0.0937	0.0491	0.0045	0.0513	0.0033	0.0014
Right_Cerebellum	39.74	4.3251	38.824	3.9802	0.193	0.07	0.0062	0.0673	0.005	0.0014	0.0386	0.0034	0.0374	0.003	0.0264	0.0291	0.0028	0.0289	0.0026	0.6395
Right_Cerebrum	226.7	24.195	232.55	20.357	0.122	0.4	0.011	0.403	0.007	0.089	0.2198	0.0107	0.2238	0.007	0.0087	0.1657	0.0108	0.1729	0.0068	6E-06
Temporal_Lobe	84.335	10.119	89.451	8.6068	0.002	0.149	0.0083	0.155	0.006	2E-06	0.0817	0.0059	0.0861	0.004	2E-06	0.0617	0.0052	0.0665	0.0039	3E-09

EK6- 3B GSEOM için GM(614) ve BM(283) en yüksek sınıflandırma doğruluğunu veren özellikler

1	Correlation_UZ_2_YON_6	56	ClusterShade_UZ_3_YON_5	111	MaxProbability_UZ_2_YON_6
2	Contrast_UZ_2_YON_7	57	Contrast_UZ_1_YON_2	112	Inertia_UZ_3_YON_5
3	ClusterShade_UZ_2_YON_7	58	ClusterShade_UZ_1_YON_2	113	Inertia_UZ_3_YON_6
4	Contrast_UZ_1_YON_4	59	Contrast_UZ_3_YON_4	114	Inertia_UZ_1_YON_6
5	ClusterShade_UZ_1_YON_4	60	ClusterShade_UZ_3_YON_4	115	Inertia_UZ_2_YON_5
6	Correlation_UZ_2_YON_7	61	Contrast_UZ_2_YON_3	116	Inertia_UZ_4_YON_6
7	Contrast_UZ_1_YON_8	62	ClusterShade_UZ_2_YON_3	117	Inertia_UZ_2_YON_6
8	ClusterShade_UZ_1_YON_8	63	Contrast_UZ_4_YON_7	118	Inertia_UZ_4_YON_5
9	Contrast_UZ_1_YON_3	64	ClusterShade_UZ_4_YON_7	119	Inertia_UZ_1_YON_7
10	ClusterShade_UZ_1_YON_3	65	MaxProbability_UZ_1_YON_5	120	Inertia_UZ_2_YON_7
11	Contrast_UZ_2_YON_6	66	Energy_UZ_1_YON_5	121	Energy_UZ_2_YON_6
12	ClusterShade_UZ_2_YON_6	67	MaxProbability_UZ_2_YON_7	122	ClusterTendendy_UZ_4_YON_8
13	Correlation_UZ_1_YON_8	68	Contrast_UZ_2_YON_8	123	MaxProbability_UZ_3_YON_4
14	Correlation_UZ_1_YON_6	69	ClusterShade_UZ_2_YON_8	124	MaxProbability_UZ_4_YON_10
15	Homogeneity_UZ_2_YON_10	70	Energy_UZ_2_YON_7	125	Homogeneity_UZ_2_YON_9
16	Correlation_UZ_1_YON_5	71	Correlation_UZ_4_YON_4	126	Inertia_UZ_3_YON_8
17	Homogeneity_UZ_1_YON_12	72	Contrast_UZ_2_YON_2	127	Inertia_UZ_2_YON_10
18	Correlation_UZ_3_YON_8	73	ClusterShade_UZ_2_YON_2	128	Inertia_UZ_4_YON_8
19	MaxProbability_UZ_3_YON_7	74	Contrast_UZ_4_YON_13	129	Inertia_UZ_4_YON_9
20	Energy_UZ_3_YON_7	75	ClusterShade_UZ_4_YON_13	130	Inertia_UZ_3_YON_9
21	Contrast_UZ_2_YON_5	76	Correlation_UZ_4_YON_3	131	Inertia_UZ_3_YON_10
22	ClusterShade_UZ_2_YON_5	77	MaxProbability_UZ_3_YON_10	132	Inertia_UZ_2_YON_9
23	Contrast_UZ_3_YON_1	78	MaxProbability_UZ_3_YON_8	133	Inertia_UZ_1_YON_9
24	ClusterShade_UZ_3_YON_1	79	MaxProbability_UZ_2_YON_8	134	Inertia_UZ_1_YON_10
25	Correlation_UZ_3_YON_4	80	Energy_UZ_3_YON_10	135	MaxProbability_UZ_1_YON_6
26	Contrast_UZ_4_YON_4	81	Energy_UZ_3_YON_8	136	Energy_UZ_3_YON_4
27	ClusterShade_UZ_4_YON_4	82	Energy_UZ_2_YON_8	137	Homogeneity_UZ_2_YON_12
28	Contrast_UZ_4_YON_9	83	Contrast_UZ_4_YON_10	138	Energy_UZ_4_YON_10
29	ClusterShade_UZ_4_YON_9	84	ClusterShade_UZ_4_YON_10	139	Homogeneity_UZ_1_YON_9
30	Contrast_UZ_3_YON_10	85	Inertia_UZ_2_YON_1	140	Energy_UZ_1_YON_6
31	ClusterShade_UZ_3_YON_10	86	Inertia_UZ_3_YON_4	141	Correlation_UZ_3_YON_3
32	Contrast_UZ_1_YON_6	87	Inertia_UZ_4_YON_1	142	ClusterTendendy_UZ_2_YON_9
33	ClusterShade_UZ_1_YON_6	88	Inertia_UZ_3_YON_1	143	Homogeneity_UZ_4_YON_8
34	Contrast_UZ_3_YON_8	89	Inertia_UZ_1_YON_5	144	Contrast_UZ_3_YON_3
35	ClusterShade_UZ_3_YON_8	90	Inertia_UZ_4_YON_7	145	ClusterShade_UZ_3_YON_3
36	Contrast_UZ_2_YON_11	91	Inertia_UZ_1_YON_1	146	SumMean_UZ_1_YON_1
37	ClusterShade_UZ_2_YON_11	92	Inertia_UZ_4_YON_4	147	SumMean_UZ_3_YON_1
38	Contrast_UZ_1_YON_5	93	Inertia_UZ_2_YON_8	148	SumMean_UZ_2_YON_4
39	ClusterShade_UZ_1_YON_5	94	Inertia_UZ_1_YON_8	149	SumMean_UZ_2_YON_1
40	ClusterTendendy_UZ_2_YON_10	95	Inertia_UZ_1_YON_11	150	SumMean_UZ_4_YON_1
41	Contrast_UZ_4_YON_2	96	Inertia_UZ_2_YON_11	151	SumMean_UZ_4_YON_4
42	ClusterShade_UZ_4_YON_2	97	Inertia_UZ_3_YON_11	152	SumMean_UZ_3_YON_7
43	ClusterTendendy_UZ_1_YON_12	98	Inertia_UZ_4_YON_10	153	SumMean_UZ_3_YON_4
44	Contrast_UZ_3_YON_6	99	Inertia_UZ_3_YON_7	154	SumMean_UZ_1_YON_5
45	ClusterShade_UZ_3_YON_6	100	Inertia_UZ_2_YON_4	155	SumMean_UZ_1_YON_8
46	Contrast_UZ_4_YON_1	101	ClusterTendendy_UZ_1_YON_9	156	SumMean_UZ_4_YON_10
47	ClusterShade_UZ_4_YON_1	102	Inertia_UZ_1_YON_2	157	SumMean_UZ_4_YON_7
48	Correlation_UZ_3_YON_6	103	Inertia_UZ_2_YON_2	158	SumMean_UZ_2_YON_8
49	MaxProbability_UZ_1_YON_8	104	Inertia_UZ_1_YON_4	159	SumMean_UZ_2_YON_11
50	Contrast_UZ_2_YON_1	105	Inertia_UZ_4_YON_3	160	SumMean_UZ_1_YON_11
51	ClusterShade_UZ_2_YON_1	106	Inertia_UZ_4_YON_2	161	SumMean_UZ_3_YON_11
52	Energy_UZ_1_YON_8	107	Inertia_UZ_3_YON_3	162	MaxProbability_UZ_4_YON_6
53	Contrast_UZ_1_YON_11	108	Inertia_UZ_3_YON_2	163	SumMean_UZ_2_YON_2
54	ClusterShade_UZ_1_YON_11	109	Inertia_UZ_2_YON_3	164	SumMean_UZ_3_YON_2
55	Contrast_UZ_3_YON_5	110	Inertia_UZ_1_YON_3	165	SumMean_UZ_1_YON_2

166	SumMean_UZ_1_YON_3	221	ClusterTendendy_UZ_2_YON_12	276	Variance_UZ_1_YON_4
167	SumMean_UZ_4_YON_2	222	MaxProbability_UZ_3_YON_6	277	Variance_UZ_4_YON_3
168	SumMean_UZ_2_YON_3	223	Energy_UZ_3_YON_6	278	Variance_UZ_2_YON_3
169	SumMean_UZ_4_YON_3	224	Contrast_UZ_4_YON_3	279	Variance_UZ_3_YON_3
170	SumMean_UZ_3_YON_3	225	ClusterShade_UZ_4_YON_3	280	ClusterTendendy_UZ_3_YON_2
171	SumMean_UZ_1_YON_4	226	Contrast_UZ_4_YON_12	281	ClusterTendendy_UZ_3_YON_11
172	Energy_UZ_4_YON_6	227	ClusterShade_UZ_4_YON_12	282	ClusterTendendy_UZ_1_YON_2
173	SumMean_UZ_3_YON_5	228	Correlation_UZ_2_YON_4	283	Variance_UZ_3_YON_9
174	SumMean_UZ_2_YON_5	229	ClusterTendendy_UZ_4_YON_5	284	Variance_UZ_2_YON_9
175	SumMean_UZ_4_YON_5	230	Contrast_UZ_2_YON_13	285	Variance_UZ_3_YON_10
176	SumMean_UZ_2_YON_6	231	ClusterShade_UZ_2_YON_13	286	Variance_UZ_4_YON_9
177	SumMean_UZ_1_YON_6	232	SumMean_UZ_1_YON_12	287	Variance_UZ_2_YON_10
178	SumMean_UZ_4_YON_6	233	SumMean_UZ_2_YON_12	288	Variance_UZ_1_YON_10
179	SumMean_UZ_3_YON_6	234	SumMean_UZ_4_YON_11	289	Variance_UZ_3_YON_8
180	SumMean_UZ_1_YON_7	235	SumMean_UZ_4_YON_12	290	Variance_UZ_1_YON_9
181	SumMean_UZ_2_YON_7	236	SumMean_UZ_3_YON_12	291	Variance_UZ_4_YON_8
182	MaxProbability_UZ_4_YON_9	237	SumMean_UZ_3_YON_13	292	Variance_UZ_3_YON_6
183	Energy_UZ_4_YON_9	238	SumMean_UZ_4_YON_13	293	Variance_UZ_4_YON_6
184	SumMean_UZ_4_YON_8	239	SumMean_UZ_1_YON_13	294	Variance_UZ_3_YON_5
185	SumMean_UZ_1_YON_9	240	SumMean_UZ_2_YON_13	295	Variance_UZ_1_YON_6
186	SumMean_UZ_3_YON_8	241	Contrast_UZ_3_YON_13	296	Variance_UZ_4_YON_5
187	SumMean_UZ_3_YON_9	242	ClusterShade_UZ_3_YON_13	297	Variance_UZ_2_YON_5
188	SumMean_UZ_2_YON_9	243	ClusterTendendy_UZ_3_YON_12	298	Variance_UZ_2_YON_7
189	SumMean_UZ_2_YON_10	244	Homogeneity_UZ_4_YON_5	299	Variance_UZ_1_YON_7
190	SumMean_UZ_1_YON_10	245	ClusterTendendy_UZ_1_YON_1	300	Variance_UZ_2_YON_6
191	SumMean_UZ_4_YON_9	246	Contrast_UZ_2_YON_12	301	Homogeneity_UZ_1_YON_1
192	SumMean_UZ_3_YON_10	247	ClusterShade_UZ_2_YON_12	302	Correlation_UZ_2_YON_5
193	MaxProbability_UZ_4_YON_7	248	MaxProbability_UZ_2_YON_5	303	Homogeneity_UZ_3_YON_12
194	Correlation_UZ_3_YON_5	249	Variance_UZ_3_YON_4	304	Contrast_UZ_4_YON_6
195	Contrast_UZ_3_YON_9	250	Variance_UZ_4_YON_4	305	ClusterShade_UZ_4_YON_6
196	ClusterShade_UZ_3_YON_9	251	Variance_UZ_4_YON_10	306	Homogeneity_UZ_3_YON_2
197	Contrast_UZ_3_YON_11	252	Variance_UZ_2_YON_8	307	ClusterTendendy_UZ_2_YON_13
198	ClusterShade_UZ_3_YON_11	253	Variance_UZ_1_YON_8	308	Homogeneity_UZ_2_YON_2
199	Inertia_UZ_4_YON_13	254	Variance_UZ_2_YON_1	309	ClusterTendendy_UZ_3_YON_1
200	Inertia_UZ_1_YON_13	255	Variance_UZ_3_YON_1	310	Contrast_UZ_2_YON_9
201	Inertia_UZ_4_YON_12	256	Variance_UZ_2_YON_11	311	ClusterShade_UZ_2_YON_9
202	Inertia_UZ_3_YON_13	257	Variance_UZ_2_YON_4	312	Homogeneity_UZ_1_YON_2
203	Inertia_UZ_3_YON_12	258	Variance_UZ_1_YON_11	313	ClusterTendendy_UZ_3_YON_13
204	Inertia_UZ_2_YON_13	259	Variance_UZ_1_YON_5	314	ClusterTendendy_UZ_2_YON_4
205	Inertia_UZ_2_YON_12	260	Variance_UZ_3_YON_7	315	ClusterTendendy_UZ_3_YON_9
206	Inertia_UZ_1_YON_12	261	Variance_UZ_3_YON_11	316	Variance_UZ_2_YON_12
207	Inertia_UZ_4_YON_11	262	Variance_UZ_4_YON_1	317	Variance_UZ_2_YON_13
208	MaxProbability_UZ_1_YON_7	263	Variance_UZ_1_YON_1	318	Variance_UZ_3_YON_13
209	Energy_UZ_4_YON_7	264	Variance_UZ_4_YON_7	319	Variance_UZ_1_YON_12
210	Contrast_UZ_1_YON_10	265	MaxProbability_UZ_2_YON_11	320	Variance_UZ_4_YON_13
211	ClusterShade_UZ_1_YON_10	266	Energy_UZ_2_YON_5	321	Variance_UZ_1_YON_13
212	Energy_UZ_1_YON_7	267	Energy_UZ_2_YON_11	322	Variance_UZ_3_YON_12
213	MaxProbability_UZ_4_YON_5	268	Contrast_UZ_3_YON_12	323	Variance_UZ_4_YON_11
214	Contrast_UZ_4_YON_11	269	ClusterShade_UZ_3_YON_12	324	Variance_UZ_4_YON_12
215	ClusterShade_UZ_4_YON_11	270	ClusterTendendy_UZ_2_YON_2	325	ClusterTendendy_UZ_2_YON_3
216	Energy_UZ_4_YON_5	271	Variance_UZ_2_YON_2	326	MaxProbability_UZ_3_YON_5
217	Contrast_UZ_3_YON_7	272	Variance_UZ_1_YON_3	327	ClusterTendendy_UZ_1_YON_7
218	ClusterShade_UZ_3_YON_7	273	Variance_UZ_3_YON_2	328	ClusterTendendy_UZ_4_YON_12
219	Contrast_UZ_1_YON_13	274	Variance_UZ_4_YON_2	329	Energy_UZ_3_YON_5
220	ClusterShade_UZ_1_YON_13	275	Variance_UZ_1_YON_2	330	Contrast_UZ_1_YON_9

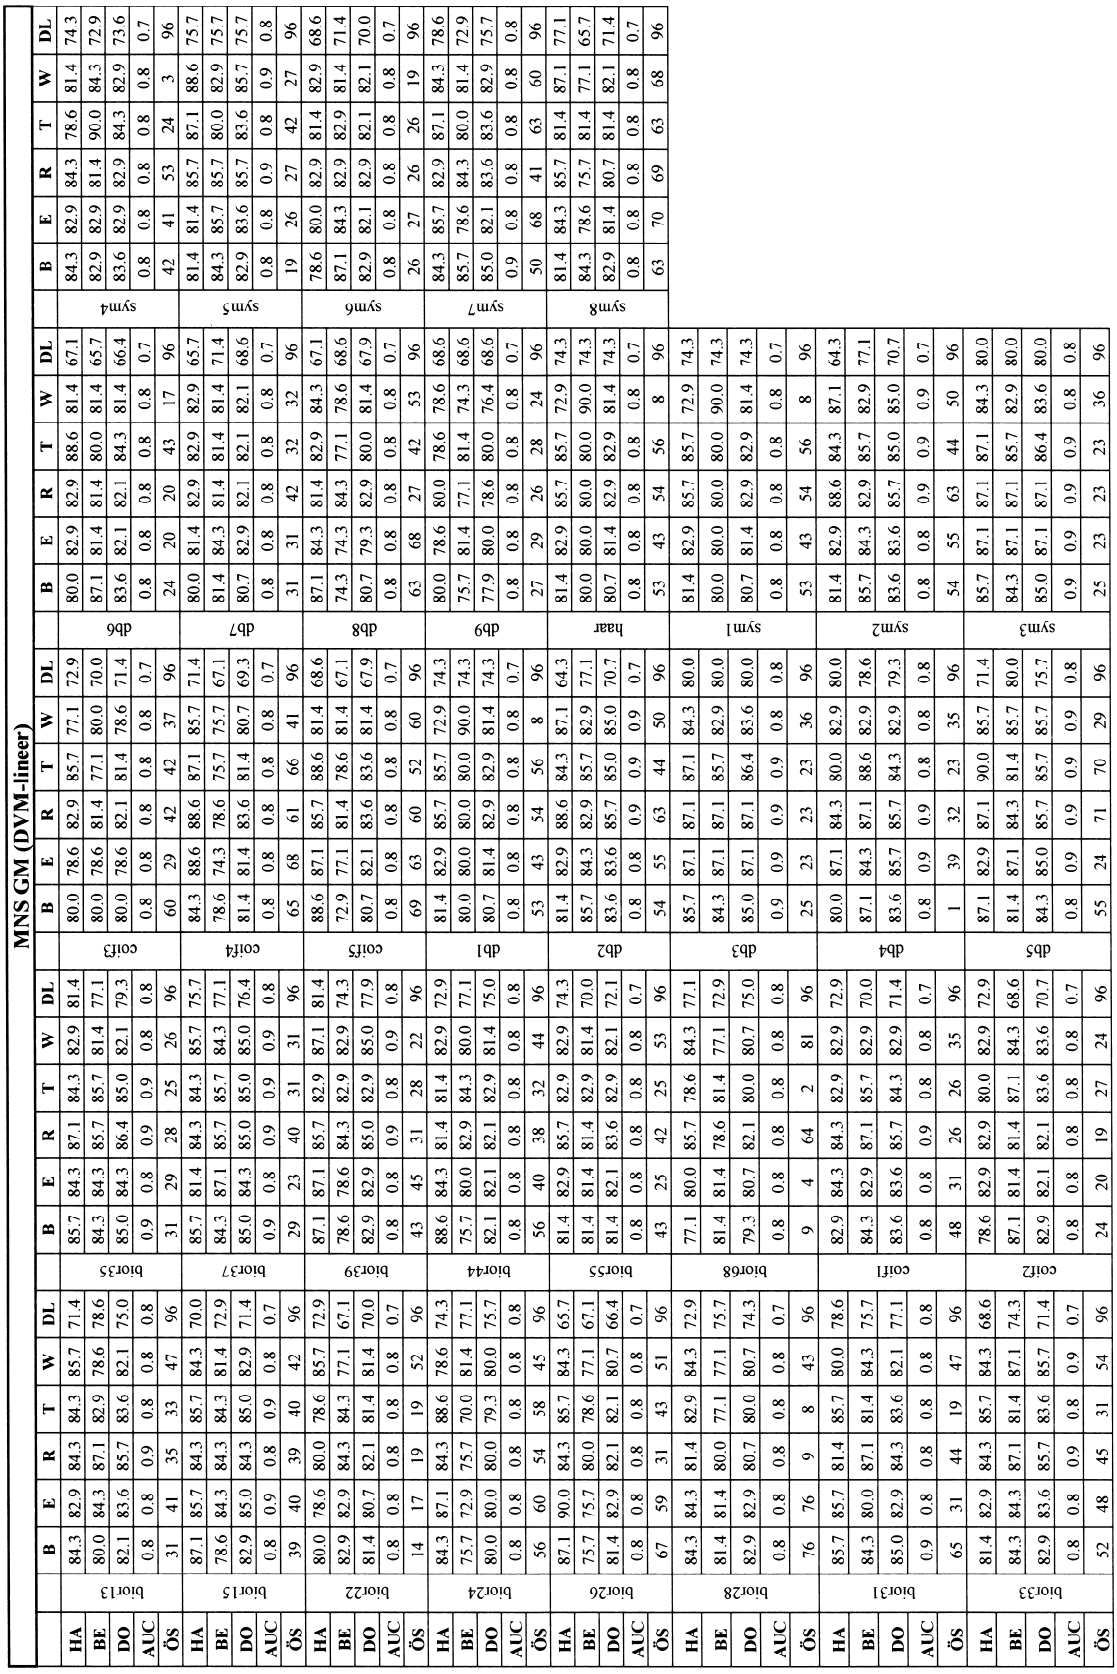
331	ClusterShade_UZ_1_YON_9	386	Homogeneity_UZ_4_YON_6	441	Energy_UZ_2_YON_2
332	Contrast_UZ_1_YON_7	387	Contrast_UZ_2_YON_4	442	Energy_UZ_3_YON_13
333	ClusterShade_UZ_1_YON_7	388	ClusterShade_UZ_2_YON_4	443	Energy_UZ_3_YON_12
334	ClusterTendendy_UZ_4_YON_1	389	ClusterTendendy_UZ_3_YON_6	444	ClusterTendendy_UZ_2_YON_7
335	ClusterTendendy_UZ_4_YON_2	390	MaxProbability_UZ_4_YON_2	445	Homogeneity_UZ_1_YON_10
336	ClusterTendendy_UZ_2_YON_1	391	Homogeneity_UZ_2_YON_5	446	ClusterTendendy_UZ_2_YON_6
337	ClusterTendendy_UZ_4_YON_3	392	ClusterTendendy_UZ_3_YON_4	447	MaxProbability_UZ_2_YON_3
338	ClusterTendendy_UZ_3_YON_5	393	Energy_UZ_4_YON_2	448	Energy_UZ_2_YON_3
339	ClusterTendendy_UZ_1_YON_10	394	Correlation_UZ_4_YON_2	449	Homogeneity_UZ_3_YON_6
340	ClusterTendendy_UZ_3_YON_3	395	MaxProbability_UZ_3_YON_11	450	Homogeneity_UZ_4_YON_4
341	MaxProbability_UZ_4_YON_3	396	MaxProbability_UZ_1_YON_4	451	Homogeneity_UZ_3_YON_4
342	Homogeneity_UZ_2_YON_4	397	MaxProbability_UZ_4_YON_1	452	Homogeneity_UZ_3_YON_7
343	ClusterTendendy_UZ_1_YON_3	398	ClusterTendendy_UZ_1_YON_6	453	Correlation_UZ_2_YON_3
344	Energy_UZ_4_YON_3	399	Energy_UZ_3_YON_11	454	MaxProbability_UZ_2_YON_10
345	ClusterTendendy_UZ_1_YON_4	400	Homogeneity_UZ_4_YON_10	455	ClusterTendendy_UZ_3_YON_10
346	Homogeneity_UZ_3_YON_1	401	Correlation_UZ_4_YON_1	456	Energy_UZ_2_YON_10
347	ClusterTendendy_UZ_4_YON_6	402	MaxProbability_UZ_2_YON_13	457	MaxProbability_UZ_1_YON_13
348	MaxProbability_UZ_4_YON_4	403	Homogeneity_UZ_3_YON_13	458	MaxProbability_UZ_1_YON_2
349	MaxProbability_UZ_1_YON_11	404	ClusterTendendy_UZ_2_YON_8	459	Energy_UZ_1_YON_13
350	MaxProbability_UZ_3_YON_9	405	Energy_UZ_1_YON_4	460	Energy_UZ_1_YON_2
351	Energy_UZ_4_YON_4	406	Energy_UZ_4_YON_1	461	MaxProbability_UZ_1_YON_12
352	ClusterTendendy_UZ_4_YON_10	407	Correlation_UZ_1_YON_3	462	Homogeneity_UZ_1_YON_6
353	Homogeneity_UZ_1_YON_7	408	MaxProbability_UZ_1_YON_9	463	Homogeneity_UZ_1_YON_5
354	Energy_UZ_1_YON_11	409	MaxProbability_UZ_2_YON_9	464	Homogeneity_UZ_2_YON_8
355	Energy_UZ_3_YON_9	410	MaxProbability_UZ_4_YON_13	465	Energy_UZ_1_YON_12
356	Homogeneity_UZ_4_YON_1	411	MaxProbability_UZ_2_YON_12	466	MaxProbability_UZ_1_YON_1
357	Homogeneity_UZ_4_YON_3	412	Energy_UZ_2_YON_13	467	MaxProbability_UZ_3_YON_1
358	Homogeneity_UZ_2_YON_3	413	Energy_UZ_1_YON_9	468	Energy_UZ_1_YON_1
359	ClusterTendendy_UZ_2_YON_5	414	MaxProbability_UZ_4_YON_11	469	Energy_UZ_3_YON_1
360	ClusterTendendy_UZ_4_YON_11	415	Energy_UZ_2_YON_9	470	ClusterTendendy_UZ_4_YON_9
361	Homogeneity_UZ_3_YON_5	416	ClusterTendendy_UZ_3_YON_7	471	Homogeneity_UZ_3_YON_8
362	Homogeneity_UZ_4_YON_2	417	Contrast_UZ_1_YON_1	472	Contrast_UZ_4_YON_5
363	Contrast_UZ_1_YON_12	418	ClusterShade_UZ_1_YON_1	473	ClusterShade_UZ_4_YON_5
364	ClusterShade_UZ_1_YON_12	419	MaxProbability_UZ_1_YON_10	474	ClusterTendendy_UZ_1_YON_8
365	Homogeneity_UZ_3_YON_9	420	Energy_UZ_4_YON_13	475	Homogeneity_UZ_2_YON_7
366	Homogeneity_UZ_4_YON_12	421	Homogeneity_UZ_4_YON_11	476	Homogeneity_UZ_4_YON_7
367	Homogeneity_UZ_2_YON_1	422	ClusterTendendy_UZ_1_YON_5	477	ClusterTendendy_UZ_1_YON_11
368	MaxProbability_UZ_3_YON_3	423	Energy_UZ_2_YON_12	478	ClusterTendendy_UZ_4_YON_13
369	Homogeneity_UZ_2_YON_13	424	Energy_UZ_4_YON_11	479	Homogeneity_UZ_1_YON_13
370	ClusterTendendy_UZ_1_YON_13	425	MaxProbability_UZ_4_YON_12	480	Homogeneity_UZ_2_YON_6
371	Energy_UZ_3_YON_3	426	MaxProbability_UZ_3_YON_2	481	Correlation_UZ_3_YON_1
372	Homogeneity_UZ_3_YON_3	427	Energy_UZ_1_YON_10	482	MaxProbability_UZ_2_YON_1
373	Homogeneity_UZ_1_YON_4	428	Correlation_UZ_1_YON_4	483	Energy_UZ_2_YON_1
374	MaxProbability_UZ_2_YON_4	429	MaxProbability_UZ_1_YON_3	484	Homogeneity_UZ_3_YON_10
375	Homogeneity_UZ_1_YON_3	430	Energy_UZ_3_YON_2	485	ClusterTendendy_UZ_2_YON_11
376	Energy_UZ_2_YON_4	431	ClusterTendendy_UZ_3_YON_8	486	Correlation_UZ_2_YON_2
377	MaxProbability_UZ_4_YON_8	432	MaxProbability_UZ_3_YON_13	487	Homogeneity_UZ_4_YON_9
378	Homogeneity_UZ_3_YON_11	433	MaxProbability_UZ_3_YON_12	488	Correlation_UZ_1_YON_2
379	Contrast_UZ_2_YON_10	434	Energy_UZ_1_YON_3	489	Homogeneity_UZ_1_YON_8
380	ClusterShade_UZ_2_YON_10	435	Energy_UZ_4_YON_12	490	Correlation_UZ_1_YON_1
381	Energy_UZ_4_YON_8	436	MaxProbability_UZ_2_YON_2	491	Entropy_UZ_4_YON_10
382	Contrast_UZ_4_YON_8	437	Contrast_UZ_3_YON_2	492	Entropy_UZ_1_YON_8
383	ClusterShade_UZ_4_YON_8	438	ClusterShade_UZ_3_YON_2	493	Entropy_UZ_4_YON_9
384	ClusterTendendy_UZ_4_YON_4	439	ClusterTendendy_UZ_4_YON_7	494	Entropy_UZ_2_YON_8
385	Correlation_UZ_3_YON_2	440	Correlation_UZ_2_YON_1	495	Entropy_UZ_3_YON_10

496	Entropy_UZ_4_YON_7	551	Entropy_UZ_2_YON_4	606	InverseVariance_UZ_3_YON_6
497	Entropy_UZ_2_YON_11	552	Entropy_UZ_1_YON_3	607	InverseVariance_UZ_1_YON_2
498	Homogeneity_UZ_4_YON_13	553	Correlation_UZ_1_YON_10	608	InverseVariance_UZ_1_YON_4
499	Entropy_UZ_3_YON_7	554	InverseVariance_UZ_2_YON_10	609	InverseVariance_UZ_1_YON_5
500	Entropy_UZ_1_YON_11	555	Entropy_UZ_4_YON_1	610	InverseVariance_UZ_3_YON_2
501	Homogeneity_UZ_1_YON_11	556	Entropy_UZ_3_YON_2	611	InverseVariance_UZ_4_YON_3
502	InverseVariance_UZ_1_YON_11	557	InverseVariance_UZ_1_YON_9	612	InverseVariance_UZ_3_YON_4
503	Entropy_UZ_2_YON_12	558	Entropy_UZ_2_YON_2	613	Correlation_UZ_2_YON_12
504	Entropy_UZ_2_YON_13	559	Entropy_UZ_1_YON_2	614	Correlation_UZ_3_YON_11
505	Entropy_UZ_3_YON_8	560	InverseVariance_UZ_4_YON_11		
506	Entropy_UZ_3_YON_12	561	InverseVariance_UZ_2_YON_9		
507	Entropy_UZ_1_YON_10	562	Correlation_UZ_3_YON_10		
508	Entropy_UZ_3_YON_9	563	Entropy_UZ_3_YON_1		
509	Entropy_UZ_3_YON_11	564	InverseVariance_UZ_4_YON_9		
510	Entropy_UZ_1_YON_9	565	Entropy_UZ_2_YON_1		
511	Entropy_UZ_4_YON_12	566	Correlation_UZ_1_YON_9		
512	Entropy_UZ_3_YON_13	567	InverseVariance_UZ_3_YON_9		
513	InverseVariance_UZ_2_YON_11	568	Entropy_UZ_1_YON_1		
514	Entropy_UZ_4_YON_13	569	InverseVariance_UZ_4_YON_8		
515	Entropy_UZ_1_YON_12	570	InverseVariance_UZ_4_YON_7		
516	InverseVariance_UZ_4_YON_12	571	InverseVariance_UZ_2_YON_8		
517	Entropy_UZ_4_YON_11	572	Correlation_UZ_3_YON_9		
518	Entropy_UZ_2_YON_10	573	Correlation_UZ_4_YON_8		
519	Entropy_UZ_2_YON_9	574	Correlation_UZ_4_YON_5		
520	Entropy_UZ_1_YON_13	575	InverseVariance_UZ_3_YON_10		
521	InverseVariance_UZ_1_YON_13	576	Correlation_UZ_2_YON_9		
522	Homogeneity_UZ_2_YON_11	577	Correlation_UZ_4_YON_9		
523	InverseVariance_UZ_2_YON_13	578	Correlation_UZ_3_YON_13		
524	Entropy_UZ_1_YON_7	579	InverseVariance_UZ_1_YON_7		
525	Entropy_UZ_4_YON_6	580	InverseVariance_UZ_3_YON_8		
526	Entropy_UZ_2_YON_7	581	Correlation_UZ_3_YON_7		
527	Entropy_UZ_4_YON_8	582	InverseVariance_UZ_4_YON_6		
528	Entropy_UZ_1_YON_6	583	InverseVariance_UZ_1_YON_8		
529	InverseVariance_UZ_4_YON_13	584	Correlation_UZ_4_YON_7		
530	Entropy_UZ_2_YON_6	585	Correlation_UZ_4_YON_6		
531	Entropy_UZ_3_YON_6	586	InverseVariance_UZ_4_YON_1		
532	Entropy_UZ_1_YON_5	587	InverseVariance_UZ_4_YON_5		
533	InverseVariance_UZ_3_YON_13	588	InverseVariance_UZ_3_YON_1		
534	InverseVariance_UZ_3_YON_11	589	InverseVariance_UZ_1_YON_6		
535	Entropy_UZ_3_YON_4	590	Correlation_UZ_2_YON_10		
536	Entropy_UZ_4_YON_5	591	InverseVariance_UZ_2_YON_1		
537	InverseVariance_UZ_2_YON_12	592	Correlation_UZ_1_YON_7		
538	InverseVariance_UZ_1_YON_12	593	InverseVariance_UZ_3_YON_7		
539	InverseVariance_UZ_3_YON_12	594	Correlation_UZ_4_YON_11		
540	Entropy_UZ_2_YON_5	595	InverseVariance_UZ_1_YON_3		
541	Correlation_UZ_4_YON_10	596	InverseVariance_UZ_2_YON_7		
542	InverseVariance_UZ_1_YON_10	597	Correlation_UZ_2_YON_8		
543	Entropy_UZ_4_YON_4	598	Correlation_UZ_1_YON_12		
544	Entropy_UZ_3_YON_5	599	InverseVariance_UZ_1_YON_1		
545	InverseVariance_UZ_4_YON_10	600	InverseVariance_UZ_2_YON_2		
546	Entropy_UZ_4_YON_3	601	InverseVariance_UZ_2_YON_6		
547	Entropy_UZ_1_YON_4	602	InverseVariance_UZ_4_YON_2		
548	Entropy_UZ_4_YON_2	603	InverseVariance_UZ_2_YON_3		
549	Entropy_UZ_2_YON_3	604	Correlation_UZ_1_YON_11		
550	Entropy_UZ_3_YON_3	605	Correlation_UZ_2_YON_13		

1	InverseVariance_UZ_2_YON_2	53	Energy_UZ_4_YON_9	105	MaxProbability_UZ_3_YON_9
2	Entropy_UZ_2_YON_11	54	Entropy_UZ_1_YON_10	106	Entropy_UZ_3_YON_9
3	Energy_UZ_1_YON_11	55	Energy_UZ_4_YON_10	107	Energy_UZ_2_YON_2
4	Entropy_UZ_2_YON_10	56	Entropy_UZ_2_YON_12	108	Energy_UZ_1_YON_5
5	Entropy_UZ_2_YON_8	57	Energy_UZ_4_YON_5	109	Entropy_UZ_4_YON_7
6	Entropy_UZ_3_YON_11	58	MaxProbability_UZ_4_YON_5	110	Energy_UZ_4_YON_13
7	MaxProbability_UZ_1_YON_11	59	MaxProbability_UZ_1_YON_8	111	Entropy_UZ_1_YON_2
8	Energy_UZ_3_YON_6	60	Energy_UZ_2_YON_8	112	Energy_UZ_4_YON_2
9	Entropy_UZ_3_YON_10	61	Entropy_UZ_3_YON_12	113	MaxProbability_UZ_2_YON_1
10	Energy_UZ_2_YON_11	62	Entropy_UZ_2_YON_13	114	Entropy_UZ_4_YON_6
11	Energy_UZ_3_YON_10	63	Entropy_UZ_3_YON_13	115	MaxProbability_UZ_2_YON_2
12	MaxProbability_UZ_2_YON_11	64	MaxProbability_UZ_1_YON_4	116	MaxProbability_UZ_3_YON_3
13	Entropy_UZ_2_YON_9	65	Entropy_UZ_2_YON_6	117	MaxProbability_UZ_1_YON_5
14	MaxProbability_UZ_3_YON_6	66	MaxProbability_UZ_4_YON_10	118	MaxProbability_UZ_4_YON_6
15	Entropy_UZ_3_YON_6	67	Entropy_UZ_2_YON_2	119	Energy_UZ_2_YON_12
16	Energy_UZ_3_YON_11	68	Entropy_UZ_4_YON_8	120	Energy_UZ_3_YON_12
17	Entropy_UZ_1_YON_8	69	Entropy_UZ_4_YON_13	121	Energy_UZ_1_YON_13
18	MaxProbability_UZ_3_YON_10	70	MaxProbability_UZ_1_YON_2	122	MaxProbability_UZ_4_YON_13
19	Entropy_UZ_1_YON_11	71	Energy_UZ_3_YON_4	123	Entropy_UZ_2_YON_4
20	Entropy_UZ_3_YON_7	72	MaxProbability_UZ_4_YON_4	124	Energy_UZ_2_YON_13
21	Energy_UZ_2_YON_6	73	MaxProbability_UZ_3_YON_8	125	Energy_UZ_3_YON_13
22	Energy_UZ_1_YON_10	74	Energy_UZ_1_YON_9	126	Entropy_UZ_3_YON_4
23	MaxProbability_UZ_3_YON_11	75	MaxProbability_UZ_2_YON_10	127	Energy_UZ_1_YON_12
24	MaxProbability_UZ_2_YON_6	76	Entropy_UZ_4_YON_11	128	Energy_UZ_4_YON_11
25	MaxProbability_UZ_1_YON_10	77	Entropy_UZ_1_YON_12	129	MaxProbability_UZ_3_YON_12
26	Entropy_UZ_4_YON_12	78	Energy_UZ_1_YON_3	130	Energy_UZ_2_YON_4
27	Energy_UZ_3_YON_1	79	Energy_UZ_2_YON_5	131	Energy_UZ_1_YON_6
28	Energy_UZ_2_YON_7	80	MaxProbability_UZ_2_YON_8	132	MaxProbability_UZ_4_YON_7
29	MaxProbability_UZ_2_YON_7	81	MaxProbability_UZ_1_YON_9	133	MaxProbability_UZ_1_YON_13
30	Entropy_UZ_3_YON_8	82	MaxProbability_UZ_4_YON_9	134	Entropy_UZ_1_YON_4
31	Entropy_UZ_4_YON_9	83	Energy_UZ_2_YON_3	135	Entropy_UZ_3_YON_2
32	Entropy_UZ_4_YON_5	84	MaxProbability_UZ_3_YON_4	136	Energy_UZ_4_YON_3
33	Energy_UZ_3_YON_7	85	MaxProbability_UZ_2_YON_3	137	MaxProbability_UZ_2_YON_13
34	Energy_UZ_4_YON_8	86	Entropy_UZ_1_YON_9	138	MaxProbability_UZ_3_YON_13
35	Entropy_UZ_4_YON_10	87	Energy_UZ_4_YON_12	139	Entropy_UZ_3_YON_3
36	MaxProbability_UZ_3_YON_1	88	MaxProbability_UZ_1_YON_3	140	MaxProbability_UZ_2_YON_4
37	Entropy_UZ_2_YON_5	89	Entropy_UZ_2_YON_3	141	MaxProbability_UZ_2_YON_12
38	Entropy_UZ_2_YON_7	90	MaxProbability_UZ_2_YON_5	142	Energy_UZ_1_YON_1
39	Energy_UZ_2_YON_9	91	Entropy_UZ_1_YON_5	143	Energy_UZ_3_YON_2
40	Energy_UZ_1_YON_4	92	Entropy_UZ_3_YON_5	144	MaxProbability_UZ_1_YON_6
41	Energy_UZ_4_YON_4	93	Entropy_UZ_4_YON_2	145	MaxProbability_UZ_4_YON_11
42	Entropy_UZ_4_YON_4	94	Energy_UZ_3_YON_9	146	MaxProbability_UZ_1_YON_12
43	Energy_UZ_1_YON_7	95	Entropy_UZ_1_YON_13	147	Entropy_UZ_2_YON_1
44	MaxProbability_UZ_1_YON_7	96	Energy_UZ_2_YON_1	148	MaxProbability_UZ_4_YON_2
45	MaxProbability_UZ_3_YON_7	97	Entropy_UZ_3_YON_1	149	Entropy_UZ_4_YON_3
46	Energy_UZ_1_YON_8	98	Energy_UZ_3_YON_5	150	Entropy_UZ_1_YON_3
47	Energy_UZ_3_YON_8	99	Entropy_UZ_1_YON_6	151	MaxProbability_UZ_1_YON_1
48	MaxProbability_UZ_4_YON_8	100	MaxProbability_UZ_4_YON_12	152	MaxProbability_UZ_3_YON_2
49	Energy_UZ_2_YON_10	101	Energy_UZ_3_YON_3	153	MaxProbability_UZ_4_YON_3
50	Energy_UZ_1_YON_2	102	MaxProbability_UZ_3_YON_5	154	Energy_UZ_4_YON_1
51	Entropy_UZ_1_YON_7	103	Energy_UZ_4_YON_6	155	MaxProbability_UZ_4_YON_1
52	MaxProbability_UZ_2_YON_9	104	Energy_UZ_4_YON_7	156	Entropy_UZ_4_YON_1

157	InverseVariance_UZ_1_YON_1	209	Variance_UZ_2_YON_12	261	InverseVariance_UZ_3_YON_9
158	Entropy_UZ_1_YON_1	210	Variance_UZ_3_YON_12	262	Correlation_UZ_2_YON_11
159	InverseVariance_UZ_1_YON_2	211	Variance_UZ_4_YON_12	263	Correlation_UZ_1_YON_11
160	InverseVariance_UZ_4_YON_2	212	Variance_UZ_1_YON_13	264	Correlation_UZ_4_YON_13
161	Variance_UZ_3_YON_8	213	Variance_UZ_2_YON_13	265	Correlation_UZ_3_YON_11
162	Variance_UZ_4_YON_8	214	Variance_UZ_3_YON_13	266	Correlation_UZ_3_YON_12
163	Variance_UZ_1_YON_9	215	Variance_UZ_4_YON_13	267	Correlation_UZ_4_YON_12
164	Variance_UZ_2_YON_9	216	InverseVariance_UZ_1_YON_9	268	Correlation_UZ_2_YON_13
165	Variance_UZ_3_YON_9	217	InverseVariance_UZ_2_YON_5	269	Correlation_UZ_3_YON_13
166	Variance_UZ_4_YON_9	218	InverseVariance_UZ_3_YON_3	270	Correlation_UZ_2_YON_10
167	Variance_UZ_1_YON_10	219	InverseVariance_UZ_2_YON_10	271	Correlation_UZ_2_YON_12
168	Variance_UZ_2_YON_10	220	InverseVariance_UZ_1_YON_12	272	Contrast_UZ_3_YON_1
169	Variance_UZ_3_YON_10	221	InverseVariance_UZ_2_YON_8	273	ClusterShade_UZ_3_YON_1
170	Variance_UZ_2_YON_5	222	InverseVariance_UZ_1_YON_4	274	Correlation_UZ_1_YON_12
171	Variance_UZ_3_YON_5	223	InverseVariance_UZ_3_YON_2	275	Contrast_UZ_4_YON_1
172	Variance_UZ_4_YON_5	224	InverseVariance_UZ_1_YON_6	276	ClusterShade_UZ_4_YON_1
173	Variance_UZ_1_YON_6	225	InverseVariance_UZ_2_YON_9	277	Correlation_UZ_2_YON_8
174	Variance_UZ_2_YON_6	226	InverseVariance_UZ_4_YON_12	278	Contrast_UZ_4_YON_4
175	Variance_UZ_3_YON_6	227	InverseVariance_UZ_3_YON_11	279	ClusterShade_UZ_4_YON_4
176	Variance_UZ_4_YON_6	228	InverseVariance_UZ_4_YON_13	280	Contrast_UZ_4_YON_2
177	Variance_UZ_1_YON_7	229	InverseVariance_UZ_3_YON_4	281	ClusterShade_UZ_4_YON_2
178	Variance_UZ_2_YON_7	230	InverseVariance_UZ_1_YON_5	282	Homogeneity_UZ_1_YON_10
179	InverseVariance_UZ_2_YON_3	231	InverseVariance_UZ_2_YON_13	283	Correlation_UZ_4_YON_9
180	Variance_UZ_1_YON_2	232	InverseVariance_UZ_3_YON_13		
181	Variance_UZ_2_YON_2	233	InverseVariance_UZ_1_YON_3		
182	Variance_UZ_3_YON_2	234	InverseVariance_UZ_2_YON_12		
183	Variance_UZ_4_YON_2	235	InverseVariance_UZ_2_YON_4		
184	Variance_UZ_1_YON_3	236	InverseVariance_UZ_3_YON_12		
185	Variance_UZ_2_YON_3	237	InverseVariance_UZ_4_YON_3		
186	Variance_UZ_3_YON_3	238	InverseVariance_UZ_2_YON_6		
187	Variance_UZ_4_YON_3	239	InverseVariance_UZ_3_YON_5		
188	Variance_UZ_1_YON_4	240	InverseVariance_UZ_1_YON_13		
189	Variance_UZ_1_YON_1	241	InverseVariance_UZ_4_YON_1		
190	Variance_UZ_2_YON_1	242	InverseVariance_UZ_2_YON_11		
191	Variance_UZ_3_YON_1	243	InverseVariance_UZ_4_YON_11		
192	Variance_UZ_4_YON_1	244	InverseVariance_UZ_4_YON_10		
193	Variance_UZ_2_YON_4	245	InverseVariance_UZ_1_YON_10		
194	Variance_UZ_3_YON_4	246	InverseVariance_UZ_1_YON_11		
195	Variance_UZ_4_YON_4	247	InverseVariance_UZ_3_YON_8		
196	Variance_UZ_1_YON_5	248	InverseVariance_UZ_4_YON_4		
197	Variance_UZ_3_YON_7	249	InverseVariance_UZ_1_YON_7		
198	Variance_UZ_4_YON_7	250	Correlation_UZ_1_YON_13		
199	Variance_UZ_1_YON_8	251	InverseVariance_UZ_4_YON_8		
200	Variance_UZ_2_YON_8	252	InverseVariance_UZ_4_YON_9		
201	Variance_UZ_4_YON_10	253	InverseVariance_UZ_3_YON_7		
202	Variance_UZ_1_YON_11	254	InverseVariance_UZ_2_YON_7		
203	Variance_UZ_2_YON_11	255	InverseVariance_UZ_4_YON_5		
204	Variance_UZ_3_YON_11	256	InverseVariance_UZ_3_YON_10		
205	InverseVariance_UZ_3_YON_1	257	InverseVariance_UZ_3_YON_6		
206	InverseVariance_UZ_2_YON_1	258	InverseVariance_UZ_1_YON_8		
207	Variance_UZ_4_YON_11	259	InverseVariance_UZ_4_YON_6		
208	Variance_UZ_1_YON_12	260	InverseVariance_UZ_4_YON_7		

EK -7 OASIS veritabanında VOI bölgelerde sekiz senaryo, 37 dalgacık, özellik derecelendirme ve iki kernelli DVM için sınıflandırma sonuçları (Sırasıyla DVM-lineer MNS GM, NS GM, MNS BM, NS BM, MNS GM_200, NS GM_200, MNS BM_200, NS BM_200, DVM-rbf MNS GM, NS GM, MNS BM, NS BM, MNS GM_200, NS GM_200, MNS BM_200, NS BM_200)



NS GM (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	90.0	87.1	85.7	85.7	85.7	68.6	bior35	88.6	85.7	84.3	84.3	88.6	71.4	coif3	82.9	85.7	82.9	84.3	84.3	65.7	db6	85.7	87.1	85.7	87.1	85.7	67.1	sym4	85.7	87.1	84.3	84.3	85.7	75.7
ÖZ		85.7	90.0	85.7	87.1	88.6	81.4		81.4	84.3	84.3	84.3	80.0	77.1		82.9	78.6	81.4	81.4	81.4	70.0		85.7	82.9	85.7	80.0	85.7	74.3		84.3	84.3	85.7	85.7	85.7	78.6
DO		87.9	88.6	85.7	86.4	87.1	75.0		85.0	85.0	84.3	84.3	84.3	74.3		82.9	82.1	82.1	82.9	82.9	67.9		85.7	85.0	85.7	83.6	85.7	70.7		85.0	85.7	85.0	85.0	85.7	77.1
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.9	0.9	0.8	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.8
ÖS		26	19	17	22	19	96		9	11	53	44	12	96		4	16	33	4	22	96		28	29	25	27	25	96		29	11	17	17	10	96
HA	bior15	84.3	84.3	88.6	88.6	88.6	74.3	bior37	84.3	90.0	88.6	91.4	88.6	81.4	coif4	84.3	84.3	84.3	85.7	85.7	71.4	db7	88.6	88.6	85.7	85.7	85.7	64.3	sym5	91.4	90.0	90.0	92.9	90.0	61.4
ÖZ		82.9	84.3	87.1	84.3	85.7	74.3		85.7	84.3	85.7	82.9	84.3	78.6		82.9	82.9	85.7	81.4	87.1	74.3		81.4	81.4	81.4	81.4	80.0	71.4		81.4	82.9	84.3	81.4	84.3	71.4
DO		83.6	84.3	87.9	86.4	87.1	74.3		85.0	87.1	87.1	87.1	86.4	80.0		83.6	83.6	85.0	83.6	86.4	72.9		85.0	85.0	83.6	83.6	82.9	67.9		86.4	86.4	87.1	87.1	87.1	66.4
AUC		0.8	0.8	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.9	0.8	0.9	0.7		0.9	0.9	0.8	0.8	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.7
ÖS		22	29	47	47	45	96		29	35	39	35	35	96		7	11	46	5	33	96		15	21	37	37	14	96		12	15	32	27	32	96
HA	bior22	87.1	88.6	87.1	87.1	87.1	77.1	bior39	88.6	88.6	82.9	87.1	82.9	70.0	coif5	87.1	85.7	85.7	85.7	85.7	70.0	db8	92.9	92.9	92.9	91.4	92.9	75.7	sym6	87.1	88.6	90.0	90.0	91.4	77.1
ÖZ		87.1	87.1	87.1	87.1	87.1	84.3		80.0	80.0	81.4	82.9	81.4	71.4		77.1	78.6	81.4	82.9	81.4	75.7		87.1	87.1	87.1	84.3	87.1	72.9		85.7	84.3	84.3	84.3	82.9	80.0
DO		87.1	87.9	87.1	87.1	87.1	80.7		84.3	84.3	82.1	85.0	82.1	70.7		82.1	82.1	83.6	84.3	83.6	72.9		90.0	90.0	90.0	87.9	90.0	74.3		86.4	86.4	87.1	87.1	87.1	78.6
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.9	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.8
ÖS		12	47	17	16	20	96		20	18	2	7	3	96		4	9	10	37	10	96		16	16	16	19	16	96		16	27	45	45	16	96
HA	bior24	88.6	87.1	85.7	85.7	85.7	72.9	bior44	85.7	90.0	84.3	84.3	84.3	72.9	db1	90.0	90.0	90.0	91.4	88.6	70.0	db9	88.6	88.6	88.6	90.0	88.6	67.1	sym7	85.7	85.7	85.7	87.1	87.1	71.4
ÖZ		87.1	87.1	87.1	87.1	88.6	81.4		87.1	85.7	88.6	90.0	87.1	81.4		85.7	85.7	87.1	84.3	84.3	78.6		88.6	87.1	87.1	85.7	88.6	70.0		81.4	81.4	82.9	82.9	81.4	74.3
DO		87.9	87.1	86.4	86.4	87.1	77.1		86.4	87.9	86.4	87.1	85.7	77.1		87.9	87.9	88.6	87.9	86.4	74.3		88.6	87.9	87.9	87.9	88.6	68.6		83.6	83.6	84.3	85.0	84.3	72.9
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.7		0.8	0.8	0.8	0.9	0.8	0.7
ÖS		21	21	21	17	30	96		47	43	17	16	13	96		15	15	29	19	21	96		26	41	22	40	22	96		4	13	20	20	20	96
HA	bior26	87.1	87.1	87.1	85.7	85.7	74.3	bior55	87.1	84.3	85.7	84.3	85.7	67.1	db2	88.6	85.7	91.4	91.4	91.4	70.0	haar	90.0	90.0	90.0	91.4	88.6	70.0	sym8	84.3	87.1	84.3	87.1	85.7	68.6
ÖZ		82.9	82.9	82.9	84.3	85.7	81.4		80.0	82.9	81.4	80.0	81.4	74.3		81.4	85.7	84.3	82.9	84.3	72.9		85.7	85.7	87.1	84.3	84.3	78.6		81.4	77.1	78.6	77.1	78.6	74.3
DO		85.0	85.0	85.0	85.0	85.7	77.9		83.6	83.6	83.6	82.1	83.6	70.7		85.0	85.7	87.9	87.1	87.9	71.4		87.9	87.9	88.6	87.9	86.4	74.3		82.9	82.1	81.4	82.1	82.1	71.4
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		31	15	24	20	18	96		9	11	17	9	17	96		35	12	27	27	27	96		15	15	29	19	21	96		17	11	4	2	5	96
HA	bior28	85.7	90.0	90.0	90.0	88.6	80.0	bior68	84.3	85.7	85.7	85.7	87.1	78.6	db3	84.3	82.9	84.3	82.9	85.7	70.0	sym1	90.0	90.0	90.0	91.4	88.6	70.0							
ÖZ		87.1	85.7	87.1	87.1	87.1	78.6		91.4	88.6	85.7	84.3	82.9	77.1		84.3	85.7	84.3	84.3	84.3	74.3		85.7	85.7	87.1	84.3	84.3	78.6							
DO		86.4	87.9	88.6	88.6	87.9	79.3		87.9	87.1	85.7	85.0	85.0	77.9		84.3	84.3	84.3	83.6	85.0	72.1		87.9	87.9	88.6	87.9	86.4	74.3							
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.7							
ÖS		82	78	75	75	76	96		49	46	29	42	41	96		35	15	8	32	50	96		15	15	29	19	21	96							
HA	bior31	85.7	85.7	88.6	87.1	84.3	72.9	coif1	85.7	87.1	88.6	87.1	87.1	74.3	db4	88.6	91.4	91.4	88.6	91.4	61.4	sym2	88.6	85.7	91.4	91.4	91.4	70.0							
ÖZ		84.3	84.3	82.9	82.9	87.1	74.3		85.7	82.9	84.3	85.7	85.7	75.7		88.6	82.9	82.9	90.0	84.3	75.7		81.4	85.7	84.3	82.9	84.3	72.9							
DO		85.0	85.0	85.7	85.0	85.7	73.6		85.7	85.0	86.4	86.4	86.4	75.0		88.6	87.1	87.1	89.3	87.9	68.6		85.0	85.7	87.9	87.1	87.9	71.4							
AUC		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.9	0.9	0.7							
ÖS		24	50	18	18	7	96		28	32	24	21	31	96		59	42	50	59	42	96		35	12	27	27	27	96							
HA	bior33	91.4	87.1	90.0	90.0	90.0	74.3	coif2	85.7	87.1	85.7	84.3	82.9	70.0	db5	90.0	90.0	85.7	90.0	90.0	74.3	sym3	84.3	82.9	84.3	82.9	85.7	70.0							
ÖZ		85.7	87.1	85.7	85.7	84.3	71.4		84.3	85.7	84.3	81.4	85.7	75.7		84.3	84.3	88.6	85.7	85.7	77.1		84.3	85.7	84.3	84.3	84.3	74.3							
DO		88.6	87.1	87.9	87.9	87.1	72.9		85.0	86.4	85.0	82.9	84.3	72.9		87.1	87.1	87.1	87.9	87.9	75.7		84.3	84.3	84.3	83.6	85.0	72.1							
AUC		0.9	0.9	0.9	0.9	0.9	0.7		0.9	0.9	0.9	0.8	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.9	0.7							
ÖS		50	68	24	24	24	96		28	28	24	21	19	96		20	66	23	18	64	96		35	15	8	32	50	96							

MNS BM (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	70.0	72.9	74.3	70.0	74.3	57.1	bior35	81.4	85.7	80.0	78.6	77.1	65.7	coif3	81.4	82.9	84.3	81.4	84.3	72.9	db6	84.3	84.3	85.7	84.3	84.3	65.7	sym4	68.6	81.4	85.7	82.9	67.1	68.6
ÖZ		75.7	71.4	77.1	75.7	75.7	52.9		67.1	58.6	70.0	65.7	71.4	65.7		68.6	68.6	68.6	62.9	65.7	71.4		70.0	70.0	68.6	68.6	70.0	61.4		74.3	62.9	57.1	64.3	74.3	64.3
DO		72.9	72.1	75.7	72.9	75.0	55.0		74.3	72.1	75.0	72.1	74.3	65.7		75.0	75.7	76.4	72.1	75.0	72.1		77.1	77.1	77.1	76.4	77.1	63.6		71.4	72.1	71.4	73.6	70.7	66.4
AUC		0.7	0.7	0.8	0.7	0.8	0.6		0.7	0.7	0.8	0.7	0.7	0.7		0.8	0.8	0.8	0.7	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.7
ÖS		6	2	8	6	6	96		32	32	21	21	15	96		23	20	12	14	20	96		2	13	4	13	2	96		22	59	57	92	7	96
HA	bior15	85.7	75.7	72.9	77.1	85.7	62.9	bior37	78.6	81.4	81.4	81.4	81.4	64.3	coif4	81.4	80.0	78.6	81.4	80.0	70.0	db7	78.6	78.6	80.0	84.3	80.0	57.1	sym5	80.0	85.7	74.3	84.3	71.4	60.0
ÖZ		60.0	68.6	72.9	70.0	65.7	58.6		71.4	70.0	71.4	71.4	71.4	55.7		64.3	64.3	65.7	68.6	68.6	64.3		71.4	68.6	74.3	61.4	70.0	58.6		68.6	58.6	70.0	62.9	70.0	58.6
DO		72.9	72.1	72.9	73.6	75.7	60.7		75.0	75.7	76.4	76.4	76.4	60.0		72.9	72.1	72.1	75.0	74.3	67.1		75.0	73.6	77.1	72.9	75.0	57.9		74.3	72.1	72.1	73.6	70.7	59.3
AUC		0.7	0.7	0.7	0.7	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.8	0.7	0.7		0.8	0.7	0.8	0.7	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6
ÖS		52	10	9	13	49	96		8	10	2	3	2	96		19	18	6	18	10	96		31	34	40	35	42	96		21	52	21	45	6	96
HA	bior22	80.0	80.0	82.9	82.9	77.1	61.4	bior39	75.7	74.3	74.3	74.3	74.3	67.1	coif5	72.9	71.4	84.3	68.6	84.3	65.7	db8	72.9	65.7	65.7	65.7	65.7	60.0	sym6	82.9	82.9	78.6	74.3	75.7	72.9
ÖZ		72.9	72.9	72.9	71.4	78.6	67.1		74.3	77.1	75.7	72.9	75.7	65.7		70.0	70.0	62.9	78.6	62.9	54.3		68.6	74.3	74.3	77.1	74.3	55.7		71.4	68.6	72.9	74.3	74.3	65.7
DO		76.4	76.4	77.9	77.1	77.9	64.3		75.0	75.7	75.0	73.6	75.0	66.4		71.4	70.7	73.6	73.6	73.6	60.0		70.7	70.0	70.0	71.4	70.0	57.9		77.1	75.7	75.7	74.3	75.0	69.3
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.7	0.8	0.7		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.8	0.8	0.8	0.7	0.8	0.7
ÖS		27	13	6	3	18	96		18	11	4	9	4	96		36	36	76	21	65	96		22	2	2	2	2	96		29	24	24	13	4	96
HA	bior24	84.3	84.3	82.9	80.0	82.9	62.9	bior44	81.4	84.3	80.0	74.3	81.4	65.7	db1	74.3	74.3	78.6	74.3	74.3	54.3	db9	74.3	78.6	80.0	78.6	78.6	57.1	sym7	84.3	82.9	78.6	81.4	78.6	62.9
ÖZ		65.7	67.1	72.9	72.9	71.4	54.3		65.7	62.9	72.9	80.0	68.6	54.3		72.9	72.9	68.6	75.7	75.7	55.7		70.0	65.7	68.6	71.4	71.4	58.6		61.4	61.4	70.0	60.0	67.1	51.4
DO		75.0	75.7	77.9	76.4	77.1	58.6		73.6	73.6	76.4	77.1	75.0	60.0		73.6	73.6	73.6	75.0	75.0	55.0		72.1	72.1	74.3	75.0	75.0	57.9		72.9	72.1	74.3	70.7	72.9	57.1
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.8	0.8	0.6		0.7	0.7	0.7	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6
ÖS		17	8	6	2	2	96		14	11	25	25	2	96		17	5	25	17	9	96		33	34	17	16	16	96		46	39	32	23	24	96
HA	bior26	81.4	82.9	84.3	81.4	82.9	64.3	bior55	74.3	80.0	70.0	72.9	71.4	65.7	db2	75.7	71.4	74.3	68.6	74.3	60.0	haar	74.3	74.3	78.6	74.3	74.3	54.3	sym8	85.7	80.0	81.4	82.9	82.9	70.0
ÖZ		68.6	65.7	70.0	74.3	71.4	51.4		68.6	65.7	71.4	71.4	70.0	62.9		72.9	70.0	68.6	71.4	68.6	55.7		72.9	72.9	68.6	75.7	75.7	55.7		65.7	62.9	61.4	58.6	62.9	58.6
DO		75.0	74.3	77.1	77.9	77.1	57.9		71.4	72.9	70.7	72.1	70.7	64.3		74.3	70.7	71.4	70.0	71.4	57.9		73.6	73.6	73.6	75.0	75.0	55.0		75.7	71.4	71.4	70.7	72.9	64.3
AUC		0.8	0.7	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.8	0.8	0.6		0.8	0.7	0.7	0.7	0.7	0.6
ÖS		18	34	2	2	14	96		21	26	27	18	9	96		21	21	25	7	22	96		17	5	25	17	9	96		65	67	90	90	77	96
HA	bior28	80.0	81.4	82.9	82.9	82.9	61.4	bior68	82.9	84.3	80.0	80.0	78.6	74.3	db3	75.7	74.3	74.3	75.7	72.9	68.6	sym1	74.3	74.3	78.6	74.3	74.3	54.3							
ÖZ		68.6	70.0	70.0	67.1	74.3	57.1		64.3	64.3	70.0	70.0	72.9	74.3		70.0	70.0	68.6	70.0	71.4	57.1		72.9	72.9	68.6	75.7	75.7	55.7							
DO		74.3	75.7	76.4	75.0	78.6	59.3		73.6	74.3	75.0	75.0	75.7	74.3		72.9	72.1	71.4	72.9	72.1	62.9		73.6	73.6	73.6	75.0	75.0	55.0							
AUC		0.7	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.8	0.8	0.8	0.7		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.8	0.8	0.6							
ÖS		28	23	19	5	13	96		23	20	23	19	20	96		22	11	17	18	12	96		17	5	25	17	9	96							
HA	bior31	75.7	75.7	75.7	78.6	75.7	67.1	coif1	77.1	80.0	74.3	80.0	78.6	65.7	db4	74.3	77.1	74.3	62.9	71.4	67.1	sym2	75.7	71.4	74.3	68.6	74.3	60.0							
ÖZ		77.1	77.1	77.1	62.9	75.7	67.1		74.3	68.6	75.7	70.0	71.4	58.6		70.0	64.3	65.7	75.7	67.1	55.7		72.9	70.0	68.6	71.4	68.6	55.7							
DO		76.4	76.4	76.4	70.7	75.7	67.1		75.7	74.3	75.0	75.0	75.0	62.1		72.1	70.7	70.0	69.3	69.3	61.4		74.3	70.7	71.4	70.0	71.4	57.9							
AUC		0.8	0.8	0.8	0.7	0.8	0.7		0.8	0.7	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6							
ÖS		9	9	9	32	8	96		26	31	33	17	2	96		9	5	9	7	4	96		21	21	25	7	22	96							
HA	bior33	82.9	77.1	78.6	70.0	77.1	65.7	coif2	78.6	78.6	78.6	80.0	82.9	67.1	db5	71.4	80.0	78.6	81.4	84.3	72.9	sym3	75.7	74.3	74.3	75.7	72.9	68.6							
ÖZ		70.0	74.3	68.6	71.4	71.4	62.9		71.4	67.1	65.7	67.1	62.9	55.7		68.6	64.3	72.9	71.4	64.3	61.4		70.0	70.0	68.6	70.0	71.4	57.1							
DO		76.4	75.7	73.6	70.7	74.3	64.3		75.0	72.9	72.1	73.6	72.9	61.4		70.0	72.1	75.7	76.4	74.3	67.1		72.9	72.1	71.4	72.9	72.1	62.9							
AUC		0.8	0.8	0.7	0.7	0.7	0.6		0.8	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.8	0.8	0.7	0.7		0.7	0.7	0.7	0.7	0.7	0.6							
ÖS		21	15	21	2	15	96		14	4	38	4	18	96		25	38	6	25	28	96		22	11	17	18	12	96							

NS BM (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	81.4	81.4	80.0	81.4	81.4	65.7	bior35	74.3	72.9	71.4	74.3	72.9	67.1	coif3	72.9	74.3	71.4	74.3	74.3	70.0	db6	75.7	75.7	74.3	77.1	77.1	68.6	sym4	74.3	80.0	78.6	78.6	78.6	61.4
ÖZ		80.0	80.0	80.0	78.6	80.0	68.6		74.3	75.7	78.6	80.0	78.6	62.9		75.7	71.4	78.6	77.1	78.6	64.3		74.3	74.3	77.1	72.9	74.3	60.0		80.0	77.1	81.4	81.4	81.4	65.7
DO		80.7	80.7	80.0	80.0	80.7	67.1		74.3	74.3	75.0	77.1	75.7	65.0		74.3	72.9	75.0	75.7	76.4	67.1		75.0	75.0	75.7	75.0	75.7	64.3		77.1	78.6	80.0	80.0	80.0	63.6
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		17	12	9	25	22	96		2	6	3	2	3	96		5	4	9	7	8	96		24	8	10	24	5	96		2	5	2	2	2	96
HA	bior15	80.0	77.1	78.6	80.0	75.7	72.9	bior37	72.9	72.9	72.9	72.9	72.9	60.0	coif4	75.7	75.7	75.7	77.1	77.1	64.3	db7	74.3	72.9	75.7	71.4	71.4	67.1	sym5	78.6	80.0	78.6	78.6	80.0	71.4
ÖZ		78.6	80.0	80.0	78.6	81.4	67.1		80.0	78.6	78.6	80.0	78.6	65.7		77.1	75.7	75.7	78.6	78.6	58.6		78.6	81.4	77.1	80.0	80.0	68.6		82.9	80.0	80.0	80.0	77.1	64.3
DO		79.3	78.6	79.3	79.3	78.6	70.0		76.4	75.7	75.7	76.4	75.7	62.9		76.4	75.7	75.7	77.9	77.9	61.4		76.4	77.1	76.4	75.7	75.7	67.9		80.7	80.0	79.3	79.3	78.6	67.9
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		3	13	4	3	2	96		12	10	5	3	3	96		5	27	10	24	3	96		24	7	5	5	13	96		7	4	2	2	29	96
HA	bior22	75.7	75.7	75.7	80.0	78.6	67.1	bior39	74.3	74.3	77.1	77.1	75.7	68.6	coif5	72.9	72.9	68.6	74.3	78.6	64.3	db8	72.9	72.9	74.3	72.9	77.1	68.6	sym6	75.7	75.7	78.6	81.4	77.1	70.0
ÖZ		72.9	71.4	75.7	71.4	72.9	68.6		81.4	78.6	80.0	75.7	77.1	61.4		78.6	77.1	85.7	78.6	74.3	65.7		81.4	78.6	81.4	81.4	77.1	58.6		82.9	84.3	82.9	80.0	82.9	68.6
DO		74.3	73.6	75.7	75.7	75.7	67.9		77.9	76.4	78.6	76.4	76.4	65.0		75.7	75.0	77.1	76.4	76.4	65.0		77.1	75.7	77.9	77.1	77.1	63.6		79.3	80.0	80.7	80.7	80.0	69.3
AUC		0.7	0.7	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		12	7	22	15	13	96		21	18	25	2	12	96		2	1	5	10	19	96		14	9	4	7	6	96		6	10	9	33	9	96
HA	bior24	80.0	77.1	75.7	75.7	77.1	62.9	bior44	75.7	80.0	75.7	77.1	78.6	64.3	db1	72.9	78.6	88.6	88.6	74.3	65.7	db9	75.7	72.9	71.4	70.0	72.9	67.1	sym7	72.9	72.9	72.9	72.9	72.9	62.9
ÖZ		78.6	80.0	80.0	80.0	78.6	65.7		81.4	78.6	81.4	81.4	80.0	65.7		81.4	74.3	65.7	65.7	80.0	67.1		77.1	74.3	77.1	78.6	78.6	60.0		78.6	80.0	80.0	78.6	78.6	68.6
DO		79.3	78.6	77.9	77.9	77.9	64.3		78.6	79.3	78.6	79.3	79.3	65.0		77.1	76.4	77.1	77.1	77.1	66.4		76.4	73.6	74.3	74.3	75.7	63.6		75.7	76.4	76.4	75.7	75.7	65.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.7	0.7	0.7	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		4	8	2	2	5	96		3	5	3	3	6	96		9	21	59	55	10	96		2	12	11	8	16	96		28	24	11	3	13	96
HA	bior26	72.9	81.4	74.3	75.7	78.6	67.1	bior55	72.9	72.9	70.0	70.0	71.4	61.4	db2	72.9	72.9	74.3	72.9	71.4	62.9	haar	72.9	78.6	88.6	88.6	74.3	65.7	sym8	78.6	81.4	78.6	78.6	78.6	74.3
ÖZ		75.7	68.6	78.6	75.7	78.6	62.9		80.0	81.4	84.3	84.3	85.7	62.9		77.1	77.1	78.6	78.6	80.0	58.6		81.4	74.3	65.7	65.7	80.0	67.1		80.0	77.1	80.0	80.0	80.0	70.0
DO		74.3	75.0	76.4	75.7	78.6	65.0		76.4	77.1	77.1	77.1	78.6	62.1		75.0	75.0	76.4	75.7	75.7	60.7		77.1	76.4	77.1	77.1	77.1	66.4		79.3	79.3	79.3	79.3	79.3	72.1
AUC		0.7	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		21	45	21	10	2	96		5	5	10	10	19	96		2	14	22	5	22	96		9	21	59	55	10	96		2	4	2	2	2	96
HA	bior28	72.9	77.1	70.0	72.9	74.3	64.3	bior68	72.9	75.7	71.4	72.9	77.1	64.3	db3	74.3	74.3	75.7	75.7	75.7	64.3	sym1	72.9	78.6	88.6	88.6	74.3	65.7							
ÖZ		78.6	78.6	82.9	78.6	77.1	64.3		80.0	75.7	81.4	80.0	78.6	61.4		78.6	78.6	82.9	80.0	80.0	58.6		81.4	74.3	65.7	65.7	80.0	67.1							
DO		75.7	77.9	76.4	75.7	75.7	64.3		76.4	75.7	76.4	76.4	77.9	62.9		76.4	76.4	79.3	77.9	77.9	61.4		77.1	76.4	77.1	77.1	77.1	66.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7							
ÖS		7	4	3	10	7	96		4	10	6	2	3	96		8	7	13	13	16	96		9	21	59	55	10	96							
HA	bior31	75.7	75.7	78.6	78.6	74.3	67.1	coif1	80.0	77.1	78.6	78.6	78.6	62.9	db4	75.7	77.1	77.1	75.7	74.3	64.3	sym2	72.9	72.9	74.3	72.9	71.4	62.9							
ÖZ		74.3	75.7	74.3	74.3	78.6	64.3		74.3	77.1	74.3	77.1	74.3	68.6		75.7	74.3	75.7	75.7	75.7	58.6		77.1	77.1	78.6	78.6	80.0	58.6							
DO		75.0	75.7	76.4	76.4	76.4	65.7		77.1	77.1	76.4	77.9	76.4	65.7		75.7	75.7	76.4	75.7	75.0	61.4		75.0	75.0	76.4	75.7	75.7	60.7							
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		5	4	7	7	1	96		30	7	10	13	18	96		5	8	2	24	7	96		2	14	22	5	22	96							
HA	bior33	70.0	72.9	72.9	74.3	72.9	64.3	coif2	78.6	72.9	78.6	75.7	75.7	64.3	db5	72.9	74.3	74.3	75.7	71.4	61.4	sym3	74.3	74.3	75.7	75.7	75.7	64.3							
ÖZ		80.0	80.0	80.0	77.1	80.0	65.7		75.7	82.9	77.1	80.0	80.0	70.0		75.7	74.3	80.0	77.1	81.4	52.9		78.6	78.6	82.9	80.0	80.0	58.6							
DO		75.0	76.4	76.4	75.7	76.4	65.0		77.1	77.9	77.9	77.9	77.9	67.1		74.3	74.3	77.1	76.4	76.4	57.1		76.4	76.4	79.3	77.9	77.9	61.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		7	1	1	10	1	96		57	9	2	6	5	96		16	8	14	2	1	96		8	7	13	13	16	96							

MNS GM_200 (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	82.9	84.3	82.9	82.9	80.0	68.6	bior35	85.7	85.7	88.6	82.9	84.3	75.7	coif3	84.3	81.4	84.3	85.7	82.9	72.9	db6	81.4	84.3	85.7	84.3	87.1	72.9	sym4	81.4	81.4	80.0	80.0	78.6	74.3
ÖZ		82.9	80.0	80.0	80.0	81.4	77.1		82.9	84.3	81.4	85.7	82.9	72.9		77.1	77.1	77.1	78.6	81.4	65.7		81.4	77.1	74.3	78.6	74.3	68.6		84.3	88.6	88.6	88.6	87.1	81.4
DO		82.9	82.1	81.4	81.4	80.7	72.9		84.3	85.0	85.0	84.3	83.6	74.3		80.7	79.3	80.7	82.1	82.1	69.3		81.4	80.7	80.0	81.4	80.7	70.7		82.9	85.0	84.3	84.3	82.9	77.9
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.9	0.9	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.9	0.8	0.8	0.8	0.8
ÖS		32	30	33	37	38	96		35	31	48	24	40	96		34	35	60	44	74	96		40	29	36	29	37	96		28	24	32	24	33	96
HA	bior15	81.4	80.0	84.3	84.3	81.4	74.3	bior37	87.1	85.7	85.7	85.7	84.3	77.1	coif4	87.1	82.9	85.7	82.9	85.7	72.9	db7	80.0	80.0	82.9	80.0	82.9	75.7	sym5	82.9	80.0	81.4	81.4	88.6	75.7
ÖZ		82.9	84.3	82.9	81.4	81.4	77.1		80.0	81.4	87.1	81.4	87.1	78.6		77.1	77.1	74.3	77.1	72.9	62.9		81.4	80.0	78.6	80.0	80.0	72.9		84.3	84.3	84.3	84.3	78.6	74.3
DO		82.1	82.1	83.6	82.9	81.4	75.7		83.6	83.6	86.4	83.6	85.7	77.9		82.1	80.0	80.0	80.0	79.3	67.9		80.7	80.0	80.7	80.0	81.4	74.3		83.6	82.1	82.9	82.9	83.6	75.0
AUC		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.8	0.9	0.8	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.8
ÖS		44	49	45	48	66	96		29	35	40	27	44	96		68	76	59	63	76	96		32	32	54	40	26	96		26	26	26	26	27	96
HA	bior22	84.3	84.3	84.3	84.3	87.1	72.9	bior39	81.4	84.3	87.1	85.7	84.3	75.7	coif5	78.6	88.6	84.3	81.4	90.0	68.6	db8	85.7	85.7	81.4	84.3	82.9	72.9	sym6	78.6	81.4	81.4	88.6	84.3	72.9
ÖZ		81.4	81.4	81.4	81.4	77.1	64.3		81.4	82.9	78.6	81.4	81.4	78.6		81.4	72.9	77.1	80.0	70.0	67.1		74.3	75.7	80.0	77.1	72.9	71.4		82.9	80.0	81.4	77.1	77.1	74.3
DO		82.9	82.9	82.9	82.9	82.1	68.6		81.4	83.6	82.9	83.6	82.9	77.1		80.0	80.7	80.7	80.7	80.0	67.9		80.0	80.7	80.7	80.7	77.9	72.1		80.7	80.7	81.4	82.9	80.7	73.6
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		17	17	17	17	45	96		50	45	31	36	53	96		15	49	60	17	50	96		28	44	37	32	46	96		31	27	26	43	43	96
HA	bior24	84.3	88.6	84.3	84.3	84.3	75.7	bior44	82.9	84.3	84.3	87.1	80.0	74.3	db1	82.9	81.4	81.4	87.1	84.3	75.7	db9	82.9	80.0	78.6	78.6	84.3	68.6	sym7	84.3	84.3	88.6	87.1	87.1	77.1
ÖZ		81.4	80.0	81.4	81.4	81.4	75.7		84.3	87.1	81.4	82.9	81.4	71.4		78.6	77.1	78.6	75.7	75.7	74.3		78.6	75.7	75.7	75.7	74.3	67.1		74.3	75.7	75.7	81.4	77.1	70.0
DO		82.9	84.3	82.9	82.9	82.9	75.7		83.6	85.7	82.9	85.0	80.7	72.9		80.7	79.3	80.0	81.4	80.0	75.0		80.7	77.9	77.1	77.1	79.3	67.9		79.3	80.0	82.1	84.3	82.1	73.6
AUC		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.9	0.8	0.9	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		55	45	35	35	44	96		44	40	37	37	40	96		57	32	40	56	59	96		33	30	33	33	74	96		68	51	38	43	41	96
HA	bior26	80.0	82.9	88.6	82.9	75.7	64.3	bior55	82.9	82.9	82.9	82.9	87.1	75.7	db2	82.9	84.3	84.3	84.3	84.3	70.0	haar	82.9	81.4	81.4	87.1	84.3	75.7	sym8	82.9	87.1	85.7	87.1	84.3	75.7
ÖZ		82.9	80.0	75.7	81.4	82.9	74.3		82.9	85.7	87.1	87.1	78.6	72.9		84.3	82.9	85.7	84.3	84.3	77.1		78.6	77.1	78.6	75.7	75.7	74.3		77.1	72.9	75.7	80.0	80.0	67.1
DO		81.4	81.4	82.1	82.1	79.3	69.3		82.9	84.3	85.0	85.0	82.9	74.3		83.6	83.6	85.0	84.3	84.3	73.6		80.7	79.3	80.0	81.4	80.0	75.0		80.0	80.0	80.7	83.6	82.1	71.4
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.9	0.9	0.8	0.7		0.8	0.8	0.9	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		35	28	37	23	43	96		29	29	23	23	54	96		32	60	56	45	44	96		57	32	40	56	59	96		35	35	80	41	74	96
HA	bior28	82.9	82.9	85.7	84.3	84.3	72.9	bior68	78.6	87.1	85.7	84.3	82.9	78.6	db3	81.4	80.0	82.9	82.9	82.9	80.0	sym1	82.9	81.4	81.4	87.1	84.3	75.7							
ÖZ		78.6	77.1	72.9	80.0	75.7	77.1		81.4	74.3	80.0	78.6	74.3	72.9		90.0	88.6	85.7	88.6	85.7	80.0		78.6	77.1	78.6	75.7	75.7	74.3							
DO		80.7	80.0	79.3	82.1	80.0	75.0		80.0	80.7	82.9	81.4	78.6	75.7		85.7	84.3	84.3	85.7	84.3	80.0		80.7	79.3	80.0	81.4	80.0	75.0							
AUC		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.8		0.9	0.8	0.8	0.9	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.8							
ÖS		14	14	23	47	16	96		17	58	61	55	83	96		24	24	29	24	30	96		57	32	40	56	59	96							
HA	bior31	82.9	82.9	82.9	84.3	82.9	78.6	coif1	80.0	80.0	84.3	84.3	84.3	71.4	db4	81.4	82.9	80.0	80.0	87.1	80.0	sym2	82.9	84.3	84.3	84.3	84.3	70.0							
ÖZ		82.9	81.4	82.9	80.0	81.4	70.0		88.6	88.6	84.3	82.9	87.1	72.9		85.7	90.0	90.0	90.0	80.0	80.0		84.3	82.9	85.7	84.3	84.3	77.1							
DO		82.9	82.1	82.9	82.1	82.1	74.3		84.3	84.3	84.3	83.6	85.7	72.1		83.6	86.4	85.0	85.0	83.6	80.0		83.6	83.6	85.0	84.3	84.3	73.6							
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.9	0.7		0.8	0.9	0.9	0.9	0.8	0.8		0.8	0.8	0.9	0.8	0.8	0.7							
ÖS		24	55	37	21	33	96		28	28	27	26	35	96		30	24	24	24	48	96		32	60	56	45	44	96							
HA	bior33	82.9	85.7	87.1	85.7	85.7	78.6	coif2	87.1	84.3	82.9	85.7	82.9	70.0	db5	88.6	77.1	84.3	90.0	90.0	74.3	sym3	81.4	80.0	82.9	82.9	82.9	80.0							
ÖZ		84.3	82.9	81.4	84.3	84.3	75.7		78.6	82.9	81.4	80.0	77.1	67.1		75.7	85.7	81.4	77.1	80.0	80.0		90.0	88.6	85.7	88.6	85.7	80.0							
DO		83.6	84.3	84.3	85.0	85.0	77.1		82.9	83.6	82.1	82.9	80.0	68.6		82.1	81.4	82.9	83.6	85.0	77.1		85.7	84.3	84.3	85.7	84.3	80.0							
AUC		0.8	0.8	0.8	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.9	0.8		0.9	0.8	0.8	0.9	0.8	0.8							
ÖS		35	44	45	40	46	96		33	35	26	44	26	96		57	43	67	56	72	96		24	24	29	24	30	96							

NS GM_200 (DVM-lineer)																																			
		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	84.3	84.3	84.3	84.3	84.3	70.0	bior35	85.7	88.6	81.4	80.0	84.3	62.9	coif3	80.0	82.9	82.9	82.9	78.6	57.1	db6	81.4	84.3	84.3	82.9	84.3	71.4	sym4	84.3	82.9	82.9	87.1	84.3	68.6
ÖZ		80.0	84.3	81.4	82.9	84.3	77.1		84.3	80.0	84.3	82.9	81.4	75.7		77.1	78.6	77.1	77.1	87.1	67.1		81.4	77.1	75.7	78.6	75.7	70.0		78.6	82.9	81.4	80.0	80.0	75.7
DO		82.1	84.3	82.9	83.6	84.3	73.6		85.0	84.3	82.9	81.4	82.9	69.3		78.6	80.7	80.0	80.0	82.9	62.1		81.4	80.7	80.0	80.7	80.0	70.7		81.4	82.9	82.1	83.6	82.1	72.1
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		25	26	21	26	17	96		7	5	22	21	15	96		6	5	6	6	1	96		33	25	21	32	23	96		25	23	47	35	15	96
HA	bior15	80.0	80.0	82.9	85.7	84.3	68.6	bior37	84.3	84.3	84.3	85.7	87.1	74.3	coif4	81.4	80.0	80.0	71.4	81.4	65.7	db7	82.9	84.3	81.4	81.4	82.9	70.0	sym5	87.1	87.1	88.6	85.7	85.7	61.4
ÖZ		84.3	84.3	87.1	82.9	84.3	74.3		82.9	84.3	84.3	84.3	82.9	82.9		81.4	82.9	82.9	90.0	82.9	70.0		81.4	78.6	84.3	84.3	85.7	68.6		82.9	80.0	80.0	82.9	80.0	72.9
DO		82.1	82.1	85.0	84.3	84.3	71.4		83.6	84.3	84.3	85.0	85.0	78.6		81.4	81.4	81.4	80.7	82.1	67.9		82.1	81.4	82.9	82.9	84.3	69.3		85.0	83.6	84.3	84.3	82.9	67.1
AUC		0.8	0.8	0.9	0.8	0.8	0.7		0.8	0.8	0.8	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.8	0.8	0.8	0.8	0.7
ÖS		85	85	40	29	17	96		33	36	32	33	28	96		23	4	7	1	5	96		35	25	17	17	24	96		26	49	17	22	15	96
HA	bior22	87.1	87.1	88.6	90.0	90.0	74.3	bior39	87.1	85.7	82.9	82.9	84.3	68.6	coif5	82.9	81.4	82.9	81.4	81.4	68.6	db8	88.6	85.7	88.6	87.1	87.1	74.3	sym6	84.3	87.1	87.1	85.7	84.3	74.3
ÖZ		84.3	84.3	82.9	81.4	85.7	80.0		80.0	81.4	81.4	78.6	81.4	74.3		80.0	81.4	81.4	81.4	81.4	70.0		82.9	82.9	81.4	85.7	81.4	72.9		81.4	80.0	80.0	81.4	82.9	74.3
DO		85.7	85.7	85.7	85.7	87.9	77.1		83.6	83.6	82.1	80.7	82.9	71.4		81.4	81.4	82.1	81.4	81.4	69.3		85.7	84.3	85.0	86.4	84.3	73.6		82.9	83.6	83.6	83.6	83.6	74.3
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.9	0.8	0.9	0.9	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		44	50	43	48	47	96		57	10	50	21	14	96		24	20	4	5	1	96		38	38	31	22	15	96		41	15	41	41	41	96
HA	bior24	85.7	87.1	85.7	82.9	84.3	84.3	bior44	85.7	84.3	85.7	87.1	85.7	77.1	db1	90.0	90.0	88.6	88.6	90.0	80.0	db9	87.1	87.1	90.0	92.9	90.0	67.1	sym7	82.9	84.3	87.1	87.1	82.9	70.0
ÖZ		82.9	84.3	82.9	85.7	84.3	74.3		85.7	87.1	85.7	85.7	87.1	74.3		82.9	82.9	85.7	85.7	84.3	80.0		78.6	78.6	80.0	77.1	80.0	61.4		81.4	78.6	72.9	75.7	77.1	58.6
DO		84.3	85.7	84.3	84.3	84.3	79.3		85.7	85.7	85.7	86.4	86.4	75.7		86.4	86.4	87.1	87.1	87.1	80.0		82.9	82.9	85.0	85.0	85.0	64.3		82.1	81.4	80.0	81.4	80.0	64.3
AUC		0.8	0.9	0.8	0.8	0.8	0.8		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.9	0.9	0.9	0.6		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		19	8	13	37	7	96		35	38	31	22	31	96		22	22	22	22	28	96		41	28	40	27	44	96		19	19	26	20	23	96
HA	bior26	85.7	88.6	87.1	88.6	85.7	77.1	bior55	84.3	85.7	82.9	84.3	84.3	72.9	db2	87.1	88.6	88.6	88.6	85.7	71.4	haar	90.0	90.0	88.6	88.6	90.0	80.0	sym8	81.4	81.4	82.9	81.4	81.4	67.1
ÖZ		81.4	81.4	82.9	78.6	84.3	81.4		82.9	81.4	78.6	78.6	80.0	70.0		80.0	84.3	75.7	75.7	80.0	80.0		82.9	82.9	85.7	85.7	84.3	80.0		80.0	80.0	77.1	78.6	80.0	67.1
DO		83.6	85.0	85.0	83.6	85.0	79.3		83.6	83.6	80.7	81.4	82.1	71.4		83.6	86.4	82.1	82.1	82.9	75.7		86.4	86.4	87.1	87.1	87.1	80.0		80.7	80.7	80.0	80.0	80.7	67.1
AUC		0.8	0.9	0.9	0.8	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.9	0.8	0.8	0.8	0.8		0.9	0.9	0.9	0.9	0.9	0.8		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		8	7	13	28	17	96		20	15	23	26	33	96		18	24	35	35	36	96		22	22	22	22	28	96		43	43	43	32	43	96
HA	bior28	87.1	88.6	90.0	85.7	87.1	74.3	bior68	88.6	87.1	85.7	85.7	87.1	77.1	db3	88.6	85.7	84.3	85.7	88.6	68.6	sym1	90.0	90.0	88.6	88.6	90.0	80.0							
ÖZ		82.9	82.9	82.9	84.3	82.9	80.0		82.9	82.9	82.9	85.7	81.4	75.7		78.6	84.3	81.4	81.4	80.0	72.9		82.9	82.9	85.7	85.7	84.3	80.0							
DO		85.0	85.7	86.4	85.0	85.0	77.1		85.7	85.0	84.3	85.7	84.3	76.4		83.6	85.0	82.9	83.6	84.3	70.7		86.4	86.4	87.1	87.1	87.1	80.0							
AUC		0.9	0.9	0.9	0.9	0.9	0.8		0.9	0.9	0.8	0.9	0.8	0.8		0.8	0.9	0.8	0.8	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.8							
ÖS		5	16	37	28	46	96		41	24	22	18	31	96		43	19	32	19	35	96		22	22	22	22	28	96							
HA	bior31	87.1	85.7	85.7	85.7	84.3	72.9	coif1	87.1	87.1	85.7	85.7	85.7	74.3	db4	85.7	85.7	85.7	84.3	84.3	65.7	sym2	87.1	88.6	88.6	88.6	85.7	71.4							
ÖZ		82.9	81.4	80.0	80.0	84.3	74.3		82.9	81.4	82.9	85.7	82.9	70.0		84.3	84.3	84.3	85.7	85.7	78.6		80.0	84.3	75.7	75.7	80.0	80.0							
DO		85.0	83.6	82.9	82.9	84.3	73.6		85.0	84.3	84.3	85.7	84.3	72.1		85.0	85.0	85.0	85.0	85.0	72.1		83.6	86.4	82.1	82.1	82.9	75.7							
AUC		0.9	0.8	0.8	0.8	0.8	0.7		0.9	0.8	0.8	0.9	0.8	0.7		0.9	0.9	0.9	0.9	0.9	0.7		0.8	0.9	0.8	0.8	0.8	0.8							
ÖS		10	21	16	18	9	96		53	52	35	30	11	96		37	37	35	28	28	96		18	24	35	35	36	96							
HA	bior33	84.3	85.7	84.3	84.3	82.9	74.3	coif2	81.4	81.4	81.4	87.1	81.4	67.1	db5	81.4	80.0	84.3	82.9	82.9	78.6	sym3	88.6	85.7	84.3	85.7	88.6	68.6							
ÖZ		84.3	84.3	80.0	80.0	81.4	77.1		78.6	80.0	77.1	70.0	81.4	68.6		82.9	84.3	82.9	85.7	84.3	77.1		78.6	84.3	81.4	81.4	80.0	72.9							
DO		84.3	85.0	82.1	82.1	82.1	75.7		80.0	80.7	79.3	78.6	81.4	67.9		82.1	82.1	83.6	84.3	83.6	77.9		83.6	85.0	82.9	83.6	84.3	70.7							
AUC		0.8	0.9	0.8	0.8	0.8	0.8		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.8		0.8	0.9	0.8	0.8	0.8	0.7							
ÖS		24	24	18	27	3	96		25	25	44	74	25	96		25	88	34	34	34	96		43	19	32	19	35	96							

MNS BM_200 (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	68.6	72.9	68.6	75.7	67.1	58.6	bior35	78.6	78.6	80.0	77.1	82.9	58.6	coif3	82.9	82.9	82.9	82.9	82.9	58.6	db6	72.9	84.3	80.0	78.6	81.4	68.6	sym4	75.7	71.4	80.0	80.0	75.7	62.9
ÖZ		77.1	74.3	77.1	74.3	77.1	50.0		72.9	72.9	70.0	72.9	65.7	54.3		71.4	71.4	71.4	71.4	71.4	57.1		78.6	71.4	70.0	71.4	68.6	61.4		74.3	77.1	77.1	67.1	77.1	61.4
DO		72.9	73.6	72.9	75.0	72.1	54.3		75.7	75.7	75.0	75.0	74.3	56.4		77.1	77.1	77.1	77.1	77.1	57.9		75.7	77.9	75.0	75.0	75.0	65.0		75.0	74.3	78.6	73.6	76.4	62.1
AUC		0.7	0.7	0.7	0.8	0.7	0.5		0.8	0.8	0.8	0.8	0.7	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.7	0.8	0.7	0.8	0.6
ÖS		1	16	1	16	4	96		8	9	15	9	24	96		1	1	1	1	1	96		18	24	22	14	16	96		6	11	16	42	2	96
HA	bior15	70.0	74.3	68.6	68.6	74.3	60.0	bior37	82.9	82.9	80.0	80.0	81.4	61.4	coif4	82.9	82.9	74.3	82.9	74.3	61.4	db7	78.6	78.6	78.6	74.3	78.6	61.4	sym5	74.3	68.6	68.6	68.6	68.6	54.3
ÖZ		75.7	72.9	78.6	78.6	72.9	58.6		67.1	70.0	72.9	71.4	71.4	54.3		64.3	64.3	74.3	64.3	74.3	67.1		65.7	65.7	65.7	71.4	65.7	51.4		75.7	77.1	77.1	77.1	77.1	57.1
DO		72.9	73.6	73.6	73.6	73.6	59.3		75.0	76.4	76.4	75.7	76.4	57.9		73.6	73.6	74.3	73.6	74.3	64.3		72.1	72.1	72.1	72.9	72.1	56.4		75.0	72.9	72.9	72.9	72.9	55.7
AUC		0.7	0.7	0.7	0.7	0.7	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.8	0.7	0.7	0.7	0.7	0.6
ÖS		5	15	9	9	15	96		22	11	13	13	11	96		1	1	9	1	7	96		1	1	1	13	1	96		16	1	1	1	1	96
HA	bior22	81.4	81.4	81.4	87.1	82.9	65.7	bior39	74.3	75.7	75.7	72.9	75.7	50.0	coif5	72.9	71.4	75.7	71.4	81.4	68.6	db8	65.7	68.6	72.9	70.0	72.9	61.4	sym6	70.0	75.7	77.1	75.7	75.7	64.3
ÖZ		74.3	74.3	74.3	67.1	68.6	62.9		74.3	74.3	74.3	74.3	74.3	62.9		75.7	75.7	70.0	75.7	67.1	58.6		80.0	78.6	65.7	68.6	65.7	57.1		77.1	72.9	72.9	71.4	72.9	62.9
DO		77.9	77.9	77.9	77.1	75.7	64.3		74.3	75.0	75.0	73.6	75.0	56.4		74.3	73.6	72.9	73.6	74.3	63.6		72.9	73.6	69.3	69.3	69.3	59.3		73.6	74.3	75.0	73.6	74.3	63.6
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.8	0.8	0.7	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.8	0.7	0.7	0.6
ÖS		13	13	13	33	13	96		11	7	2	7	3	96		5	5	8	5	71	96		9	2	1	15	1	96		9	9	14	9	9	96
HA	bior24	81.4	81.4	81.4	82.9	81.4	62.9	bior44	82.9	82.9	82.9	82.9	82.9	71.4	db1	68.6	68.6	68.6	68.6	74.3	60.0	db9	77.1	74.3	71.4	71.4	71.4	58.6	sym7	70.0	78.6	80.0	74.3	72.9	54.3
ÖZ		68.6	70.0	70.0	70.0	72.9	58.6		74.3	74.3	74.3	74.3	74.3	64.3		78.6	78.6	78.6	77.1	72.9	60.0		65.7	74.3	75.7	75.7	75.7	58.6		78.6	62.9	55.7	61.4	65.7	57.1
DO		75.0	75.7	75.7	76.4	77.1	60.7		78.6	78.6	78.6	78.6	78.6	67.9		73.6	73.6	73.6	72.9	73.6	60.0		71.4	74.3	73.6	73.6	73.6	58.6		74.3	70.7	67.9	67.9	69.3	55.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6
ÖS		2	13	13	16	13	96		1	1	1	1	1	96		1	1	2	1	22	96		2	8	3	3	3	96		16	31	27	33	33	96
HA	bior26	80.0	80.0	80.0	80.0	80.0	61.4	bior55	64.3	71.4	72.9	70.0	70.0	60.0	db2	71.4	71.4	71.4	71.4	71.4	65.7	haar	68.6	68.6	68.6	68.6	74.3	60.0	sym8	78.6	75.7	81.4	81.4	80.0	62.9
ÖZ		72.9	72.9	72.9	72.9	72.9	62.9		74.3	68.6	68.6	77.1	71.4	64.3		74.3	72.9	72.9	71.4	72.9	61.4		78.6	78.6	78.6	77.1	72.9	60.0		72.9	71.4	64.3	70.0	70.0	55.7
DO		76.4	76.4	76.4	76.4	76.4	62.1		69.3	70.0	70.7	73.6	70.7	62.1		72.9	72.1	72.1	71.4	72.1	63.6		73.6	73.6	73.6	72.9	73.6	60.0		75.7	73.6	72.9	75.7	75.0	59.3
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.8	0.7	0.7	0.8	0.8	0.6
ÖS		1	1	1	1	1	96		12	8	20	18	17	96		13	17	17	24	17	96		1	1	2	1	22	96		11	21	9	18	26	96
HA	bior28	81.4	81.4	81.4	81.4	80.0	64.3	bior68	84.3	81.4	81.4	84.3	77.1	64.3	db3	71.4	72.9	77.1	81.4	80.0	57.1	sym1	68.6	68.6	68.6	68.6	74.3	60.0							
ÖZ		72.9	75.7	75.7	72.9	75.7	60.0		67.1	70.0	71.4	67.1	74.3	61.4		68.6	67.1	62.9	61.4	64.3	54.3		78.6	78.6	78.6	77.1	72.9	60.0							
DO		77.1	78.6	78.6	77.1	77.9	62.1		75.7	75.7	76.4	75.7	75.7	62.9		70.0	70.0	70.0	71.4	72.1	55.7		73.6	73.6	73.6	72.9	73.6	60.0							
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6							
ÖS		6	11	14	14	9	96		1	3	12	1	13	96		9	6	17	28	10	96		1	1	2	1	22	96							
HA	bior31	80.0	81.4	75.7	77.1	77.1	58.6	coif1	78.6	81.4	82.9	82.9	82.9	62.9	db4	81.4	75.7	61.4	61.4	75.7	55.7	sym2	71.4	71.4	71.4	71.4	71.4	65.7							
ÖZ		74.3	74.3	78.6	77.1	77.1	65.7		72.9	71.4	71.4	72.9	71.4	52.9		58.6	58.6	74.3	74.3	62.9	62.9		74.3	72.9	72.9	71.4	72.9	61.4							
DO		77.1	77.9	77.1	77.1	77.1	62.1		75.7	76.4	77.1	77.9	77.1	57.9		70.0	67.1	67.9	67.9	69.3	59.3		72.9	72.1	72.1	71.4	72.1	63.6							
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6							
ÖS		17	15	8	14	3	96		9	6	7	12	7	96		54	9	4	8	17	96		13	17	17	24	17	96							
HA	bior33	78.6	78.6	80.0	80.0	75.7	58.6	coif2	78.6	78.6	78.6	78.6	78.6	64.3	db5	72.9	74.3	75.7	80.0	77.1	58.6	sym3	71.4	72.9	77.1	81.4	80.0	57.1							
ÖZ		74.3	74.3	71.4	71.4	75.7	61.4		75.7	75.7	75.7	75.7	75.7	62.9		75.7	72.9	72.9	72.9	70.0	54.3		68.6	67.1	62.9	61.4	64.3	54.3							
DO		76.4	76.4	75.7	75.7	75.7	60.0		77.1	77.1	77.1	77.1	77.1	63.6		74.3	73.6	74.3	76.4	73.6	56.4		70.0	70.0	70.0	71.4	72.1	55.7							
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.8	0.7	0.6		0.7	0.7	0.7	0.7	0.7	0.6							
ÖS		3	3	15	18	9	96		1	1	1	1	1	96		16	3	21	23	6	96		9	6	17	28	10	96							

NS BM_200 (DVM-lineer)

		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL		B	E	R	T	W	DL
HA	bior13	81.4	81.4	80.0	80.0	81.4	64.3	bior35	71.4	71.4	72.9	74.3	72.9	67.1	coif3	72.9	72.9	71.4	74.3	74.3	68.6	db6	72.9	71.4	74.3	75.7	74.3	68.6	sym4	75.7	80.0	78.6	85.7	78.6	61.4
ÖZ		82.9	81.4	81.4	82.9	78.6	67.1		78.6	77.1	78.6	80.0	78.6	62.9		75.7	75.7	78.6	77.1	77.1	68.6		75.7	75.7	77.1	74.3	75.7	61.4		80.0	77.1	81.4	71.4	81.4	64.3
DO		82.1	81.4	80.7	81.4	80.0	65.7		75.0	74.3	75.7	77.1	75.7	65.0		74.3	74.3	75.0	75.7	75.7	68.6		74.3	73.6	75.7	75.0	75.0	65.0		77.9	78.6	80.0	78.6	80.0	62.9
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.7	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		6	11	9	6	22	96		7	6	3	2	3	96		5	24	16	7	2	96		24	5	10	24	12	96		2	5	2	35	2	96
HA	bior15	81.4	77.1	80.0	80.0	75.7	72.9	bior37	74.3	72.9	74.3	74.3	75.7	61.4	coif4	77.1	75.7	77.1	77.1	78.6	65.7	db7	74.3	71.4	77.1	74.3	74.3	65.7	sym5	80.0	80.0	78.6	78.6	81.4	68.6
ÖZ		77.1	80.0	77.1	78.6	81.4	67.1		78.6	78.6	77.1	80.0	75.7	62.9		77.1	75.7	74.3	75.7	78.6	62.9		78.6	81.4	77.1	77.1	77.1	70.0		80.0	80.0	80.0	81.4	77.1	64.3
DO		79.3	78.6	78.6	79.3	78.6	70.0		76.4	75.7	75.7	77.1	75.7	62.1		77.1	75.7	75.7	76.4	78.6	64.3		76.4	76.4	77.1	75.7	75.7	67.9		80.0	80.0	79.3	80.0	79.3	66.4
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		5	6	5	3	2	96		5	5	8	3	16	96		5	9	10	24	3	96		24	10	28	2	2	96		3	4	2	4	33	96
HA	bior22	77.1	77.1	77.1	80.0	78.6	67.1	bior39	74.3	78.6	74.3	74.3	74.3	65.7	coif5	72.9	71.4	77.1	74.3	77.1	65.7	db8	74.3	72.9	72.9	72.9	75.7	67.1	sym6	75.7	74.3	74.3	77.1	77.1	71.4
ÖZ		72.9	71.4	74.3	71.4	72.9	67.1		81.4	75.7	80.0	77.1	80.0	64.3		78.6	78.6	77.1	78.6	74.3	65.7		81.4	80.0	80.0	81.4	77.1	60.0		82.9	84.3	85.7	84.3	82.9	70.0
DO		75.0	74.3	75.7	75.7	75.7	67.1		77.9	77.1	77.1	75.7	77.1	65.0		75.7	75.0	77.1	76.4	75.7	65.7		77.9	76.4	76.4	77.1	76.4	63.6		79.3	79.3	80.0	80.7	80.0	70.7
AUC		0.8	0.7	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		8	13	14	15	13	96		21	30	25	3	21	96		2	7	24	10	20	96		19	8	2	7	7	96		6	10	2	6	9	96
HA	bior24	78.6	77.1	74.3	75.7	75.7	62.9	bior44	77.1	80.0	75.7	77.1	78.6	64.3	db1	75.7	74.3	78.6	72.9	74.3	67.1	db9	75.7	70.0	71.4	70.0	70.0	67.1	sym7	71.4	74.3	72.9	72.9	74.3	62.9
ÖZ		80.0	75.7	80.0	80.0	78.6	65.7		81.4	77.1	81.4	81.4	80.0	62.9		81.4	80.0	75.7	80.0	80.0	64.3		77.1	78.6	78.6	77.1	78.6	61.4		78.6	78.6	80.0	78.6	78.6	65.7
DO		79.3	76.4	77.1	77.9	77.1	64.3		79.3	78.6	78.6	79.3	79.3	63.6		78.6	77.1	77.1	76.4	77.1	65.7		76.4	74.3	75.0	73.6	74.3	64.3		75.0	76.4	76.4	75.7	76.4	64.3
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.7	0.8	0.7	0.7	0.6		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		4	9	2	3	16	96		5	5	3	3	6	96		21	14	32	10	10	96		2	11	24	6	16	96		28	10	14	3	13	96
HA	bior26	71.4	77.1	72.9	75.7	74.3	70.0	bior55	72.9	71.4	70.0	70.0	72.9	60.0	db2	74.3	74.3	75.7	72.9	74.3	64.3	haar	75.7	74.3	78.6	72.9	74.3	67.1	sym8	80.0	81.4	82.9	78.6	78.6	72.9
ÖZ		77.1	71.4	78.6	75.7	80.0	64.3		81.4	81.4	84.3	84.3	85.7	62.9		75.7	74.3	77.1	78.6	78.6	60.0		81.4	80.0	75.7	80.0	80.0	64.3		77.1	77.1	75.7	78.6	78.6	70.0
DO		74.3	74.3	75.7	75.7	77.1	67.1		77.1	76.4	77.1	77.1	79.3	61.4		75.0	74.3	76.4	75.7	76.4	62.1		78.6	77.1	77.1	76.4	77.1	65.7		78.6	79.3	79.3	78.6	78.6	71.4
AUC		0.7	0.7	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.7	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7
ÖS		5	37	5	10	4	96		5	8	10	10	19	96		2	5	9	5	3	96		21	14	32	10	10	96		3	4	48	2	2	96
HA	bior28	78.6	78.6	72.9	82.9	75.7	61.4	bior68	74.3	70.0	74.3	74.3	77.1	71.4	db3	72.9	71.4	75.7	75.7	74.3	61.4	sym1	75.7	74.3	78.6	72.9	74.3	67.1							
ÖZ		72.9	74.3	80.0	70.0	77.1	60.0		78.6	82.9	78.6	78.6	78.6	60.0		78.6	78.6	77.1	80.0	80.0	55.7		81.4	80.0	75.7	80.0	80.0	64.3							
DO		75.7	76.4	76.4	76.4	76.4	60.7		76.4	76.4	76.4	76.4	77.9	65.7		75.7	75.0	76.4	77.9	77.1	58.6		78.6	77.1	77.1	76.4	77.1	65.7							
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.7							
ÖS		22	10	5	30	7	96		4	18	7	5	3	96		14	5	9	13	10	96		21	14	32	10	10	96							
HA	bior31	77.1	75.7	74.3	75.7	75.7	65.7	coif1	80.0	75.7	78.6	80.0	78.6	64.3	db4	75.7	80.0	77.1	77.1	74.3	64.3	sym2	74.3	74.3	75.7	72.9	74.3	64.3							
ÖZ		74.3	75.7	77.1	75.7	75.7	70.0		77.1	75.7	77.1	77.1	77.1	67.1		75.7	68.6	75.7	75.7	77.1	58.6		75.7	74.3	77.1	78.6	78.6	60.0							
DO		75.7	75.7	75.7	75.7	75.7	67.9		78.6	75.7	77.9	78.6	77.9	65.7		75.7	74.3	76.4	76.4	75.7	61.4		75.0	74.3	76.4	75.7	76.4	62.1							
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.7	0.8	0.8	0.8	0.6		0.8	0.7	0.8	0.8	0.8	0.6							
ÖS		5	18	14	9	1	96		30	7	13	13	3	96		5	25	2	22	7	96		2	5	9	5	3	96							
HA	bior33	74.3	71.4	74.3	74.3	74.3	70.0	coif2	81.4	72.9	78.6	74.3	75.7	64.3	db5	71.4	72.9	71.4	75.7	71.4	58.6	sym3	72.9	71.4	75.7	75.7	74.3	61.4							
ÖZ		80.0	78.6	75.7	78.6	77.1	68.6		71.4	84.3	77.1	80.0	80.0	70.0		77.1	75.7	87.1	77.1	87.1	55.7		78.6	78.6	77.1	80.0	80.0	55.7							
DO		77.1	75.0	75.0	76.4	75.7	69.3		76.4	78.6	77.9	77.1	77.9	67.1		74.3	74.3	79.3	76.4	79.3	57.1		75.7	75.0	76.4	77.9	77.1	58.6							
AUC		0.8	0.8	0.8	0.8	0.8	0.7		0.8	0.8	0.8	0.8	0.8	0.7		0.7	0.7	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		7	13	10	11	4	96		57	9	2	6	5	96		27	5	1	2	1	96		14	5	9	13	10	96							

MNS GM (DVM-rbf)

		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR
HA	bior13	82.9	82.9	82.9	77.1	78.6	91.4	bior35	77.1	77.1	72.9	75.7	74.3	5.7	coif3	77.1	77.1	74.3	77.1	74.3	5.7	db6	75.7	75.7	77.1	75.7	74.3	4.3	sym4	81.4	81.4	78.6	81.4	78.6	20.0
ÖZ		74.3	77.1	77.1	84.3	77.1	11.4		82.9	84.3	92.9	85.7	87.1	100.0		71.4	71.4	74.3	71.4	74.3	98.6		81.4	81.4	80.0	81.4	82.9	100.0		85.7	85.7	87.1	85.7	88.6	80.0
DO		78.6	80.0	80.0	80.7	77.9	51.4		80.0	80.7	82.9	80.7	80.7	52.9		74.3	74.3	74.3	74.3	74.3	52.1		78.6	78.6	78.6	78.6	78.6	52.1		83.6	83.6	82.9	83.6	83.6	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		8	5	2	1	3	96		1	11	25	5	20	96		12	12	13	12	13	96		19	19	19	19	4	96		3	3	5	3	4	96
HA	bior15	84.3	84.3	81.4	75.7	84.3	92.9	bior37	82.9	82.9	82.9	82.9	80.0	90.0	coif4	82.9	81.4	81.4	82.9	82.9	2.9	db7	74.3	70.0	71.4	75.7	75.7	2.9	sym5	75.7	75.7	75.7	75.7	75.7	97.1
ÖZ		78.6	78.6	82.9	85.7	77.1	11.4		80.0	80.0	78.6	78.6	81.4	11.4		64.3	68.6	71.4	74.3	64.3	100.0		75.7	78.6	84.3	77.1	80.0	94.3		84.3	84.3	84.3	84.3	84.3	2.9
DO		81.4	81.4	82.1	80.7	80.7	52.1		81.4	81.4	80.7	80.7	80.7	50.7		73.6	75.0	76.4	78.6	73.6	51.4		75.0	74.3	77.9	76.4	77.9	48.6		80.0	80.0	80.0	80.0	80.0	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.8	0.8	0.8	0.7	0.5		0.8	0.7	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		6	6	6	3	3	96		5	5	3	3	4	96		2	9	9	9	2	96		24	17	39	24	28	96		20	20	20	20	20	96
HA	bior22	81.4	81.4	81.4	62.9	77.1	4.3	bior39	75.7	75.7	75.7	75.7	78.6	12.9	coif5	77.1	78.6	82.9	80.0	75.7	95.7	db8	75.7	72.9	70.0	67.1	68.6	0.0	sym6	74.3	74.3	77.1	74.3	74.3	91.4
ÖZ		70.0	70.0	70.0	90.0	72.9	98.6		85.7	85.7	85.7	85.7	82.9	88.6		74.3	75.7	65.7	74.3	74.3	4.3		77.1	77.1	78.6	82.9	78.6	100.0		81.4	81.4	78.6	81.4	81.4	10.0
DO		75.7	75.7	75.7	76.4	75.0	51.4		80.7	80.7	80.7	80.7	80.7	50.7		75.7	77.1	74.3	77.1	75.0	50.0		76.4	75.0	74.3	75.0	73.6	50.0		77.9	77.9	77.9	77.9	77.9	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.7	0.8	0.8	0.5		0.8	0.8	0.7	0.8	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	40	1	96		14	14	14	14	3	96		12	12	9	10	13	96		6	7	8	28	12	96		3	3	17	3	4	96
HA	bior24	80.0	81.4	81.4	81.4	70.0	20.0	bior44	84.3	84.3	84.3	84.3	84.3	38.6	db1	82.9	78.6	82.9	80.0	82.9	90.0	db9	78.6	78.6	81.4	75.7	80.0	5.7	sym7	71.4	71.4	71.4	71.4	74.3	81.4
ÖZ		74.3	74.3	74.3	74.3	82.9	80.0		78.6	75.7	75.7	75.7	80.0	58.6		80.0	84.3	78.6	78.6	80.0	12.9		75.7	75.7	75.7	77.1	68.6	98.6		80.0	80.0	80.0	80.0	78.6	18.6
DO		77.1	77.9	77.9	77.9	76.4	50.0		81.4	80.0	80.0	80.0	82.1	48.6		81.4	81.4	80.7	79.3	81.4	51.4		77.1	77.1	78.6	76.4	74.3	52.1		75.7	75.7	75.7	75.7	76.4	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		11	17	17	17	33	96		22	17	17	17	22	96		23	34	1	17	26	96		13	13	5	13	2	96		17	17	17	17	26	96
HA	bior26	71.4	70.0	74.3	74.3	68.6	4.3	bior55	75.7	75.7	75.7	75.7	75.7	81.4	db2	80.0	80.0	84.3	84.3	80.0	2.9	haar	82.9	78.6	82.9	80.0	82.9	90.0	sym8	75.7	74.3	75.7	75.7	74.3	5.7
ÖZ		78.6	80.0	77.1	78.6	85.7	98.6		90.0	90.0	90.0	90.0	90.0	20.0		81.4	81.4	75.7	75.7	82.9	100.0		80.0	84.3	78.6	78.6	80.0	12.9		72.9	74.3	74.3	72.9	72.9	98.6
DO		75.0	75.0	75.7	76.4	77.1	51.4		82.9	82.9	82.9	82.9	82.9	50.7		80.7	80.7	80.0	80.0	81.4	51.4		81.4	81.4	80.7	79.3	81.4	51.4		74.3	74.3	75.0	74.3	73.6	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.7	0.8	0.7	0.7	0.5
ÖS		2	6	3	10	9	96		17	17	17	17	17	96		21	21	19	19	19	96		23	34	1	17	26	96		7	7	7	7	2	96
HA	bior28	78.6	77.1	74.3	78.6	74.3	20.0	bior68	77.1	80.0	81.4	81.4	81.4	4.3	db3	75.7	77.1	75.7	74.3	75.7	98.6	sym1	82.9	78.6	82.9	80.0	82.9	90.0							
ÖZ		81.4	82.9	80.0	72.9	80.0	80.0		82.9	82.9	81.4	81.4	81.4	100.0		90.0	90.0	88.6	90.0	88.6	2.9		80.0	84.3	78.6	78.6	80.0	12.9							
DO		80.0	80.0	77.1	75.7	77.1	50.0		80.0	81.4	81.4	81.4	81.4	52.1		82.9	83.6	82.1	82.1	82.1	50.7		81.4	81.4	80.7	79.3	81.4	51.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		9	16	10	2	9	96		17	12	17	17	11	96		27	26	16	17	16	96		23	34	1	17	26	96							
HA	bior31	80.0	78.6	82.9	82.9	78.6	15.7	coif1	78.6	78.6	77.1	77.1	74.3	54.3	db4	80.0	78.6	78.6	78.6	78.6	100.0	sym2	80.0	80.0	84.3	84.3	80.0	2.9							
ÖZ		81.4	81.4	77.1	77.1	77.1	88.6		85.7	85.7	87.1	87.1	90.0	50.0		85.7	87.1	87.1	87.1	88.6	5.7		81.4	81.4	75.7	75.7	82.9	100.0							
DO		80.7	80.0	80.0	80.0	77.9	52.1		82.1	82.1	82.1	82.1	82.1	52.1		82.9	82.9	82.9	82.9	83.6	52.9		80.7	80.7	80.0	80.0	81.4	51.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		20	20	19	19	3	96		4	4	4	4	17	96		4	4	4	4	4	96		21	21	19	19	19	96							
HA	bior33	74.3	74.3	72.9	75.7	74.3	90.0	coif2	75.7	75.7	75.7	75.7	75.7	5.7	db5	75.7	75.7	75.7	75.7	75.7	78.6	sym3	75.7	77.1	75.7	74.3	75.7	98.6							
ÖZ		91.4	91.4	92.9	90.0	91.4	11.4		81.4	81.4	81.4	81.4	81.4	100.0		82.9	82.9	82.9	82.9	82.9	20.0		90.0	90.0	88.6	90.0	88.6	2.9							
DO		82.9	82.9	82.9	82.9	82.9	50.7		78.6	78.6	78.6	78.6	78.6	52.9		79.3	79.3	79.3	79.3	79.3	49.3		82.9	83.6	82.1	82.1	82.1	50.7							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		17	17	21	6	17	96		19	19	19	19	19	96		17	17	17	17	17	96		27	26	16	17	16	96							

NS GM (DVM-rbf)

		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR
HA	bior13	88.6	78.6	88.6	88.6	78.6	2.9	bior35	85.7	88.6	84.3	77.1	87.1	2.9	coif3	82.9	78.6	75.7	81.4	75.7	42.9	db6	84.3	82.9	78.6	81.4	84.3	4.3	sym4	77.1	85.7	81.4	81.4	84.3	37.1
ÖZ		80.0	91.4	80.0	80.0	90.0	100.0		81.4	82.9	81.4	85.7	81.4	97.1		81.4	84.3	90.0	85.7	90.0	60.0		82.9	81.4	85.7	84.3	84.3	100.0		85.7	82.9	84.3	84.3	85.7	70.0
DO		84.3	85.0	84.3	84.3	84.3	51.4		83.6	85.7	82.9	81.4	84.3	50.0		82.1	81.4	82.9	83.6	82.9	51.4		83.6	82.1	82.1	82.9	84.3	52.1		81.4	84.3	82.9	82.9	85.0	53.6
AUC		0.8	0.9	0.8	0.8	0.8	0.5		0.8	0.9	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.9	0.5
ÖS		1	17	1	1	13	96		7	5	17	5	12	96		4	9	27	4	23	96		10	5	5	4	15	96		27	10	17	17	13	96
HA	bior15	78.6	80.0	78.6	78.6	78.6	4.3	bior37	85.7	84.3	87.1	87.1	77.1	2.9	coif4	84.3	78.6	80.0	78.6	81.4	5.7	db7	84.3	84.3	80.0	80.0	78.6	7.1	sym5	85.7	88.6	81.4	80.0	81.4	17.1
ÖZ		87.1	85.7	88.6	85.7	84.3	100.0		82.9	84.3	82.9	82.9	91.4	100.0		82.9	87.1	85.7	87.1	85.7	100.0		82.9	84.3	84.3	84.3	85.7	98.6		81.4	84.3	87.1	87.1	87.1	90.0
DO		82.9	82.9	83.6	82.1	81.4	52.1		84.3	84.3	85.0	85.0	84.3	51.4		83.6	82.9	82.9	82.9	83.6	52.9		83.6	84.3	82.1	82.1	82.1	52.9		83.6	86.4	84.3	83.6	84.3	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.9	0.9	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.9	0.8	0.8	0.8	0.5
ÖS		24	19	11	17	13	96		3	11	1	1	21	96		4	5	8	7	1	96		10	7	1	1	3	96		11	7	7	12	7	96
HA	bior22	84.3	81.4	81.4	82.9	74.3	2.9	bior39	84.3	82.9	81.4	81.4	84.3	2.9	coif5	82.9	81.4	81.4	81.4	84.3	11.4	db8	78.6	80.0	82.9	82.9	80.0	4.3	sym6	84.3	84.3	78.6	85.7	82.9	5.7
ÖZ		88.6	87.1	87.1	85.7	91.4	100.0		82.9	87.1	82.9	82.9	84.3	100.0		82.9	85.7	84.3	85.7	81.4	98.6		88.6	85.7	84.3	84.3	84.3	100.0		87.1	88.6	87.1	82.9	84.3	100.0
DO		86.4	84.3	84.3	84.3	82.9	51.4		83.6	85.0	82.1	82.1	84.3	51.4		82.9	83.6	82.9	83.6	82.9	55.0		83.6	82.9	83.6	83.6	82.1	52.1		85.7	86.4	82.9	84.3	83.6	52.9
AUC		0.9	0.8	0.8	0.8	0.8	0.5		0.8	0.9	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.5		0.9	0.9	0.8	0.8	0.8	0.5
ÖS		11	13	17	13	29	96		16	15	1	1	16	96		2	7	7	7	1	96		6	19	10	11	17	96		12	7	16	14	12	96
HA	bior24	80.0	78.6	78.6	77.1	80.0	5.7	bior44	80.0	78.6	77.1	75.7	77.1	2.9	db1	82.9	82.9	84.3	78.6	85.7	2.9	db9	80.0	80.0	80.0	77.1	80.0	5.7	sym7	80.0	84.3	80.0	82.9	78.6	5.7
ÖZ		88.6	91.4	88.6	88.6	88.6	100.0		91.4	92.9	92.9	92.9	92.9	100.0		87.1	87.1	85.7	85.7	87.1	100.0		85.7	85.7	85.7	88.6	87.1	100.0		87.1	84.3	85.7	82.9	87.1	100.0
DO		84.3	85.0	83.6	82.9	84.3	52.9		85.7	85.7	85.0	84.3	85.0	51.4		85.0	85.0	85.0	82.1	86.4	51.4		82.9	82.9	82.9	82.9	83.6	52.9		83.6	84.3	82.9	82.9	82.9	52.9
AUC		0.8	0.9	0.8	0.8	0.8	0.5		0.9	0.9	0.9	0.8	0.9	0.5		0.9	0.9	0.9	0.8	0.9	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		11	4	15	19	11	96		25	25	29	29	14	96		10	3	14	7	5	96		12	7	8	5	10	96		5	7	5	4	7	96
HA	bior26	78.6	82.9	77.1	75.7	80.0	2.9	bior55	81.4	78.6	80.0	80.0	80.0	2.9	db2	75.7	81.4	81.4	81.4	81.4	7.1	haar	82.9	82.9	84.3	78.6	85.7	2.9	sym8	80.0	82.9	75.7	80.0	77.1	4.3
ÖZ		88.6	82.9	85.7	87.1	85.7	100.0		84.3	87.1	85.7	87.1	85.7	98.6		91.4	85.7	92.9	92.9	92.9	98.6		87.1	87.1	85.7	85.7	87.1	100.0		82.9	80.0	84.3	81.4	87.1	100.0
DO		83.6	82.9	81.4	81.4	82.9	51.4		82.9	82.9	82.9	83.6	82.9	50.7		83.6	83.6	87.1	87.1	87.1	52.9		85.0	85.0	85.0	82.1	86.4	51.4		81.4	81.4	80.0	80.7	82.1	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.9	0.9	0.9	0.5		0.9	0.9	0.9	0.8	0.9	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		6	4	19	5	6	96		10	4	7	7	7	96		36	18	23	23	23	96		10	3	14	7	5	96		5	13	1	2	5	96
HA	bior28	82.9	80.0	84.3	84.3	80.0	8.6	bior68	82.9	84.3	80.0	81.4	82.9	8.6	db3	84.3	85.7	84.3	84.3	84.3	30.0	sym1	82.9	82.9	84.3	78.6	85.7	2.9							
ÖZ		84.3	88.6	85.7	85.7	87.1	100.0		84.3	84.3	90.0	87.1	87.1	100.0		81.4	81.4	84.3	84.3	84.3	82.9		87.1	87.1	85.7	85.7	87.1	100.0							
DO		83.6	84.3	85.0	85.0	83.6	54.3		83.6	84.3	85.0	84.3	85.0	54.3		82.9	83.6	84.3	84.3	84.3	56.4		85.0	85.0	85.0	82.1	86.4	51.4							
AUC		0.8	0.8	0.9	0.9	0.8	0.5		0.8	0.8	0.9	0.8	0.9	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.9	0.9	0.9	0.8	0.9	0.5							
ÖS		12	13	16	16	17	96		15	12	19	17	15	96		8	18	15	15	15	96		10	3	14	7	5	96							
HA	bior31	81.4	82.9	81.4	82.9	81.4	1.4	coif1	84.3	84.3	84.3	82.9	85.7	12.9	db4	85.7	84.3	85.7	85.7	85.7	4.3	sym2	75.7	81.4	81.4	81.4	81.4	7.1							
ÖZ		84.3	87.1	85.7	82.9	85.7	98.6		82.9	85.7	81.4	84.3	87.1	100.0		84.3	85.7	84.3	84.3	84.3	98.6		91.4	85.7	92.9	92.9	92.9	98.6							
DO		82.9	85.0	83.6	82.9	83.6	50.0		83.6	85.0	82.9	83.6	86.4	56.4		85.0	85.0	85.0	85.0	85.0	51.4		83.6	83.6	87.1	87.1	87.1	52.9							
AUC		0.8	0.9	0.8	0.8	0.8	0.5		0.8	0.9	0.8	0.8	0.9	0.6		0.9	0.9	0.9	0.9	0.9	0.5		0.8	0.8	0.9	0.9	0.9	0.5							
ÖS		11	10	14	13	7	96		14	11	14	19	5	96		14	24	16	16	14	96		36	18	23	23	23	96							
HA	bior33	82.9	84.3	78.6	78.6	77.1	81.4	coif2	87.1	87.1	78.6	80.0	82.9	11.4	db5	84.3	82.9	84.3	80.0	80.0	2.9	sym3	84.3	85.7	84.3	84.3	84.3	30.0							
ÖZ		84.3	81.4	90.0	90.0	90.0	20.0		82.9	84.3	87.1	84.3	90.0	98.6		85.7	85.7	85.7	87.1	84.3	100.0		81.4	81.4	84.3	84.3	84.3	82.9							
DO		83.6	82.9	84.3	84.3	83.6	50.7		85.0	85.7	82.9	82.1	86.4	55.0		85.0	84.3	85.0	83.6	82.1	51.4		82.9	83.6	84.3	84.3	84.3	56.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.9	0.9	0.8	0.8	0.9	0.6		0.9	0.8	0.9	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		17	4	2	2	5	96		11	6	18	4	25	96		16	20	16	17	14	96		8	18	15	15	15	96							

MNS BM (DVM-rbf)

		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR
HA	bior13	75.7	72.9	78.6	78.6	80.0	18.6	bior35	80.0	65.7	71.4	65.7	71.4	18.6	coif3	77.1	78.6	77.1	74.3	74.3	2.9	db6	81.4	80.0	80.0	80.0	81.4	20.0	sym4	61.4	44.3	65.7	44.3	64.3	18.6
ÖZ		77.1	82.9	75.7	75.7	72.9	74.3		70.0	71.4	70.0	72.9	72.9	80.0		67.1	71.4	74.3	75.7	77.1	100.0		74.3	72.9	74.3	72.9	74.3	80.0		78.6	90.0	70.0	90.0	71.4	80.0
DO		76.4	77.9	77.1	77.1	76.4	46.4		75.0	68.6	70.7	69.3	72.1	49.3		72.1	75.0	75.7	75.0	75.7	51.4		77.9	76.4	77.1	76.4	77.9	50.0		70.0	67.1	67.9	67.1	67.9	49.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.7	0.7	0.7	0.7	0.5		0.7	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		12	6	11	11	7	96		3	20	21	20	13	96		21	23	10	7	3	96		2	6	2	6	2	96		4	6	5	6	5	96
HA	bior15	67.1	71.4	70.0	67.1	70.0	74.3	bior37	78.6	78.6	82.9	80.0	82.9	20.0	coif4	74.3	71.4	71.4	74.3	71.4	20.0	db7	70.0	70.0	71.4	62.9	72.9	64.3	sym5	64.3	72.9	70.0	62.9	70.0	2.9
ÖZ		77.1	82.9	80.0	82.9	81.4	20.0		71.4	71.4	68.6	68.6	70.0	81.4		68.6	71.4	70.0	72.9	75.7	80.0		74.3	74.3	72.9	75.7	74.3	28.6		81.4	70.0	71.4	75.7	68.6	98.6
DO		72.1	77.1	75.0	75.0	75.7	47.1		75.0	75.0	75.7	74.3	76.4	50.7		71.4	71.4	70.7	73.6	73.6	50.0		72.1	72.1	72.1	69.3	73.6	46.4		72.9	71.4	70.7	69.3	69.3	50.7
AUC		0.7	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.7	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		11	26	13	18	13	96		2	3	2	3	2	96		16	35	23	11	18	96		34	34	26	18	24	96		21	23	9	2	20	96
HA	bior22	80.0	81.4	81.4	81.4	80.0	10.0	bior39	71.4	72.9	71.4	67.1	71.4	21.4	coif5	61.4	62.9	67.1	68.6	67.1	78.6	db8	65.7	60.0	71.4	64.3	62.9	18.6	sym6	77.1	75.7	82.9	75.7	82.9	21.4
ÖZ		74.3	74.3	72.9	72.9	74.3	90.0		82.9	77.1	75.7	74.3	75.7	78.6		78.6	77.1	78.6	71.4	75.7	18.6		78.6	81.4	74.3	77.1	80.0	81.4		70.0	70.0	68.6	71.4	68.6	78.6
DO		77.1	77.9	77.1	77.1	77.1	50.0		77.1	75.0	73.6	70.7	73.6	50.0		70.0	70.0	72.9	70.0	71.4	48.6		72.1	70.7	72.9	70.7	71.4	50.0		73.6	72.9	75.7	73.6	75.7	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.8	0.7	0.8	0.5
ÖS		3	4	3	3	6	96		2	10	3	12	3	96		40	38	31	21	21	96		24	20	17	45	37	96		5	11	2	9	2	96
HA	bior24	68.6	68.6	77.1	78.6	78.6	20.0	bior44	80.0	82.9	80.0	80.0	80.0	18.6	db1	71.4	74.3	62.9	71.4	78.6	91.4	db9	70.0	70.0	78.6	72.9	72.9	87.1	sym7	75.7	75.7	71.4	67.1	60.0	94.3
ÖZ		81.4	84.3	72.9	71.4	71.4	78.6		71.4	71.4	72.9	72.9	72.9	81.4		80.0	72.9	78.6	80.0	72.9	11.4		72.9	72.9	71.4	74.3	74.3	10.0		65.7	65.7	67.1	77.1	80.0	2.9
DO		75.0	76.4	75.0	75.0	75.0	49.3		75.7	77.1	76.4	76.4	76.4	50.0		75.7	73.6	70.7	75.7	75.7	51.4		71.4	71.4	75.0	73.6	73.6	48.6		70.7	70.7	69.3	72.1	70.0	48.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.7	0.7	0.8	0.8	0.5		0.7	0.7	0.8	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		21	21	11	2	2	96		10	8	2	2	2	96		18	5	31	18	9	96		34	34	20	17	17	96		18	18	9	31	7	96
HA	bior26	77.1	75.7	82.9	80.0	77.1	80.0	bior55	71.4	70.0	61.4	61.4	61.4	20.0	db2	62.9	67.1	57.1	62.9	57.1	98.6	haar	71.4	74.3	62.9	71.4	78.6	91.4	sym8	58.6	62.9	71.4	68.6	62.9	18.6
ÖZ		72.9	77.1	70.0	71.4	74.3	18.6		68.6	70.0	74.3	74.3	75.7	81.4		74.3	71.4	80.0	70.0	80.0	2.9		80.0	72.9	78.6	80.0	72.9	11.4		80.0	77.1	74.3	71.4	81.4	81.4
DO		75.0	76.4	76.4	75.7	75.7	49.3		70.0	70.0	67.9	67.9	68.6	50.7		68.6	69.3	68.6	66.4	68.6	50.7		75.7	73.6	70.7	75.7	75.7	51.4		69.3	70.0	72.9	70.0	72.1	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.8	0.7	0.7	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		17	15	3	2	3	96		16	18	1	1	2	96		22	34	1	28	1	96		18	5	31	18	9	96		10	17	17	24	35	96
HA	bior28	74.3	74.3	82.9	80.0	81.4	100.0	bior68	80.0	80.0	80.0	80.0	80.0	20.0	db3	58.6	62.9	51.4	51.4	60.0	100.0	sym1	71.4	74.3	62.9	71.4	78.6	91.4							
ÖZ		72.9	72.9	68.6	68.6	68.6	5.7		71.4	71.4	70.0	70.0	71.4	80.0		78.6	78.6	85.7	85.7	80.0	5.7		80.0	72.9	78.6	80.0	72.9	11.4							
DO		73.6	73.6	75.7	74.3	75.0	52.9		75.7	75.7	75.0	75.0	75.7	50.0		68.6	70.7	68.6	68.6	70.0	52.9		75.7	73.6	70.7	75.7	75.7	51.4							
AUC		0.7	0.7	0.8	0.7	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.8	0.7	0.7	0.8	0.8	0.5							
ÖS		17	17	3	6	3	96		17	17	2	2	3	96		3	6	1	1	10	96		18	5	31	18	9	96							
HA	bior31	70.0	68.6	75.7	58.6	75.7	20.0	coif1	70.0	70.0	72.9	70.0	72.9	92.9	db4	61.4	65.7	64.3	65.7	71.4	100.0	sym2	62.9	67.1	57.1	62.9	57.1	98.6							
ÖZ		81.4	75.7	72.9	77.1	75.7	80.0		74.3	75.7	74.3	74.3	75.7	4.3		78.6	78.6	71.4	74.3	68.6	2.9		74.3	71.4	80.0	70.0	80.0	2.9							
DO		75.7	72.1	74.3	67.9	75.7	50.0		72.1	72.9	73.6	72.1	74.3	48.6		70.0	72.1	67.9	70.0	70.0	51.4		68.6	69.3	68.6	66.4	68.6	50.7							
AUC		0.8	0.7	0.7	0.7	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5							
ÖS		19	10	6	1	6	96		1	10	2	11	2	96		2	3	5	31	23	96		22	34	1	28	1	96							
HA	bior33	72.9	74.3	64.3	64.3	72.9	5.7	coif2	72.9	70.0	81.4	72.9	81.4	74.3	db5	62.9	54.3	74.3	70.0	74.3	92.9	sym3	58.6	62.9	51.4	51.4	60.0	100.0							
ÖZ		74.3	75.7	72.9	72.9	71.4	98.6		78.6	77.1	70.0	77.1	71.4	21.4		84.3	82.9	72.9	75.7	72.9	1.4		78.6	78.6	85.7	85.7	80.0	5.7							
DO		73.6	75.0	68.6	68.6	72.1	52.1		75.7	73.6	75.7	75.0	76.4	47.9		73.6	68.6	73.6	72.9	73.6	47.1		68.6	70.7	68.6	68.6	70.0	52.9							
AUC		0.7	0.8	0.7	0.7	0.7	0.5		0.8	0.7	0.8	0.8	0.8	0.5		0.7	0.7	0.7	0.7	0.7	0.5		0.7	0.7	0.7	0.7	0.7	0.5							
ÖS		10	20	35	35	22	96		5	6	7	6	7	96		24	17	11	21	11	96		3	6	1	1	10	96							

NS BM (DVM-rbf)

		B	E	R	T	W	DR
HA	bior13	81.4	80.0	80.0	80.0	78.6	12.9
ÖZ		81.4	80.0	77.1	77.1	77.1	98.6
DO		81.4	80.0	78.6	78.6	77.9	55.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		4	5	3	2	6	96
HA	bior15	71.4	81.4	72.9	80.0	78.6	15.7
ÖZ		87.1	78.6	84.3	77.1	81.4	90.0
DO		79.3	80.0	78.6	78.6	80.0	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		31	4	28	2	14	96
HA	bior22	65.7	65.7	78.6	71.4	78.6	4.3
ÖZ		85.7	87.1	77.1	81.4	77.1	98.6
DO		75.7	76.4	77.9	76.4	77.9	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		38	34	13	3	13	96
HA	bior24	78.6	81.4	82.9	80.0	78.6	7.1
ÖZ		77.1	72.9	75.7	77.1	77.1	100.0
DO		77.9	77.1	79.3	78.6	77.9	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		4	3	3	9	5	96
HA	bior26	67.1	68.6	67.1	64.3	77.1	4.3
ÖZ		81.4	85.7	84.3	84.3	78.6	100.0
DO		74.3	77.1	75.7	74.3	77.9	52.1
AUC		0.7	0.8	0.8	0.7	0.8	0.5
ÖS		2	3	3	37	3	96
HA	bior28	78.6	77.1	75.7	75.7	67.1	4.3
ÖZ		71.4	77.1	78.6	78.6	82.9	100.0
DO		75.0	77.1	77.1	77.1	75.0	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		9	13	3	2	33	96
HA	bior31	67.1	67.1	70.0	70.0	72.9	27.1
ÖZ		87.1	87.1	84.3	84.3	78.6	78.6
DO		77.1	77.1	77.1	77.1	75.7	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		34	24	18	18	3	96
HA	bior33	74.3	72.9	70.0	70.0	70.0	2.9
ÖZ		77.1	80.0	82.9	85.7	82.9	100.0
DO		75.7	76.4	76.4	77.9	76.4	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		6	9	22	22	14	96

		B	E	R	T	W	DR
HA	bior35	75.7	72.9	70.0	72.9	75.7	18.6
ÖZ		77.1	80.0	82.9	82.9	78.6	81.4
DO		76.4	76.4	76.4	77.9	77.1	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		5	9	18	15	11	96
HA	bior37	70.0	70.0	74.3	74.3	72.9	11.4
ÖZ		87.1	84.3	78.6	80.0	81.4	100.0
DO		78.6	77.1	76.4	77.1	77.1	55.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		28	3	9	1	11	96
HA	bior39	72.9	72.9	71.4	72.9	74.3	7.1
ÖZ		81.4	81.4	81.4	81.4	80.0	97.1
DO		77.1	77.1	76.4	77.1	77.1	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	2	1	15	10	96
HA	bior44	82.9	80.0	82.9	82.9	81.4	7.1
ÖZ		78.6	77.1	78.6	78.6	77.1	98.6
DO		80.7	78.6	80.7	80.7	79.3	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	7	2	2	3	96
HA	bior55	70.0	70.0	70.0	67.1	71.4	11.4
ÖZ		82.9	85.7	84.3	87.1	85.7	98.6
DO		76.4	77.9	77.1	77.1	78.6	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		12	9	3	23	7	96
HA	bior68	75.7	75.7	82.9	78.6	81.4	5.7
ÖZ		80.0	80.0	72.9	77.1	77.1	100.0
DO		77.9	77.9	77.9	77.9	79.3	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		17	17	5	2	2	96
HA	coif1	74.3	75.7	71.4	75.7	71.4	5.7
ÖZ		78.6	77.1	82.9	77.1	81.4	98.6
DO		76.4	76.4	77.1	76.4	76.4	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		9	8	13	10	13	96
HA	coif2	72.9	80.0	72.9	71.4	74.3	8.6
ÖZ		77.1	74.3	82.9	84.3	84.3	100.0
DO		75.0	77.1	77.9	77.9	79.3	54.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	10	24	28	28	96

		B	E	R	T	W	DR
HA	coif3	68.6	75.7	72.9	75.7	70.0	5.7
ÖZ		81.4	78.6	80.0	81.4	81.4	98.6
DO		75.0	77.1	76.4	78.6	75.7	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		41	25	15	27	6	96
HA	coif4	77.1	71.4	74.3	74.3	74.3	2.9
ÖZ		75.7	81.4	77.1	75.7	80.0	98.6
DO		76.4	76.4	75.7	75.0	77.1	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		5	27	12	1	3	96
HA	coif5	77.1	77.1	72.9	71.4	72.9	7.1
ÖZ		77.1	80.0	77.1	82.9	78.6	95.7
DO		77.1	78.6	75.0	77.1	75.7	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		14	13	5	26	20	96
HA	db1	75.7	74.3	74.3	75.7	75.7	12.9
ÖZ		80.0	80.0	81.4	80.0	78.6	97.1
DO		77.9	77.1	77.9	77.9	77.1	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		8	9	29	7	7	96
HA	db2	70.0	77.1	72.9	72.9	72.9	10.0
ÖZ		81.4	77.1	80.0	78.6	78.6	97.1
DO		75.7	77.1	76.4	75.7	75.7	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		15	7	14	8	8	96
HA	db3	74.3	65.7	71.4	71.4	77.1	20.0
ÖZ		75.7	84.3	81.4	81.4	75.7	95.7
DO		75.0	75.0	76.4	76.4	76.4	57.9
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		8	37	14	14	2	96
HA	db4	77.1	68.6	71.4	71.4	72.9	11.4
ÖZ		75.7	81.4	81.4	81.4	77.1	91.4
DO		76.4	75.0	76.4	76.4	75.0	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		9	27	1	1	10	96
HA	db5	75.7	74.3	70.0	72.9	70.0	8.6
ÖZ		74.3	74.3	81.4	77.1	81.4	100.0
DO		75.0	74.3	75.7	75.0	75.7	54.3
AUC		0.8	0.7	0.8	0.8	0.8	0.5
ÖS		11	5	1	5	1	96

		B	E	R	T	W	DR
HA	db6	67.1	74.3	72.9	75.7	74.3	8.6
ÖZ		78.6	75.7	77.1	75.7	75.7	100.0
DO		72.9	75.0	75.0	75.7	75.0	54.3
AUC		0.7	0.8	0.8	0.8	0.8	0.5
ÖS		5	15	2	5	9	96
HA	db7	72.9	74.3	71.4	71.4	71.4	5.7
ÖZ		80.0	80.0	81.4	81.4	81.4	100.0
DO		76.4	77.1	76.4	76.4	76.4	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		27	14	1	1	1	96
HA	db8	71.4	75.7	65.7	72.9	71.4	10.0
ÖZ		81.4	82.9	85.7	80.0	80.0	100.0
DO		76.4	79.3	75.7	76.4	75.7	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		27	14	4	2	5	96
HA	db9	74.3	72.9	70.0	68.6	74.3	8.6
ÖZ		77.1	74.3	78.6	80.0	72.9	100.0
DO		75.7	73.6	74.3	74.3	73.6	54.3
AUC		0.8	0.7	0.7	0.7	0.7	0.5
ÖS		5	15	10	2	10	96
HA	haar	75.7	74.3	74.3	75.7	75.7	12.9
ÖZ		80.0	80.0	81.4	80.0	78.6	97.1
DO		77.9	77.1	77.9	77.9	77.1	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		8	9	29	7	7	96
HA	sym1	75.7	74.3	74.3	75.7	75.7	12.9
ÖZ		80.0	80.0	81.4	80.0	78.6	97.1
DO		77.9	77.1	77.9	77.9	77.1	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		8	9	29	7	7	96
HA	sym2	70.0	77.1	72.9	72.9	72.9	10.0
ÖZ		81.4	77.1	80.0	78.6	78.6	97.1
DO		75.7	77.1	76.4	75.7	75.7	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		15	7	14	8	8	96
HA	sym3	74.3	65.7	71.4	71.4	77.1	20.0
ÖZ		75.7	84.3	81.4	81.4	75.7	95.7
DO		75.0	75.0	76.4	76.4	76.4	57.9
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		8	37	14	14	2	96

		B	E	R	T	W	DR
HA	sym4	75.7	80.0	78.6	78.6	78.6	2.9
ÖZ		77.1	75.7	77.1	77.1	77.1	98.6
DO		76.4	77.9	77.9	77.9	77.9	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		10	9	2	2	2	96
HA	sym5	78.6	78.6	74.3	74.3	72.9	11.4
ÖZ		78.6	81.4	82.9	82.9	84.3	100.0
DO		78.6	80.0	78.6	78.6	78.6	55.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		4	4	3	4	27	96
HA	sym6	78.6	72.9	80.0	82.9	81.4	7.1
ÖZ		80.0	85.7	78.6	75.7	78.6	98.6
DO		79.3	79.3	79.3	79.3	80.0	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	26	7	1	9	96
HA	sym7	77.1	72.9	71.4	74.3	77.1	4.3
ÖZ		78.6	81.4	80.0	77.1	77.1	100.0
DO		77.9	77.1	75.7	75.7	77.1	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		8	13	5	5	12	96
HA	sym8	77.1	78.6	80.0	80.0	80.0	4.3
ÖZ		81.4	80.0	75.7	77.1	75.7	98.6
DO		79.3	79.3	77.9	78.6	77.9	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		14	15	2	16	2	96

MNS GM_200 (DVM-rbf)

		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR
HA	bior13	81.4	84.3	81.4	70.0	77.1	91.4	bior35	72.9	74.3	74.3	74.3	74.3	90.0	coif3	80.0	82.9	78.6	80.0	80.0	2.9	db6	81.4	82.9	82.9	82.9	81.4	14.3	sym4	74.3	74.3	70.0	74.3	70.0	90.0
ÖZ		75.7	75.7	80.0	85.7	80.0	11.4		88.6	87.1	87.1	87.1	87.1	11.4		70.0	70.0	72.9	68.6	72.9	100.0		75.7	74.3	74.3	75.7	75.7	87.1		85.7	85.7	88.6	85.7	88.6	12.9
DO		78.6	80.0	80.7	77.9	78.6	51.4		80.7	80.7	80.7	80.7	80.7	50.7		75.0	76.4	75.7	74.3	76.4	51.4		78.6	78.6	78.6	79.3	78.6	50.7		80.0	80.0	79.3	80.0	79.3	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.7	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		3	5	4	6	4	96		11	10	11	11	6	96		8	12	17	12	12	96		6	3	3	3	3	96		27	27	17	27	17	96
HA	bior15	78.6	75.7	75.7	75.7	74.3	100.0	bior37	70.0	77.1	77.1	70.0	71.4	90.0	coif4	81.4	82.9	72.9	81.4	81.4	70.0	db7	82.9	78.6	72.9	81.4	68.6	10.0	sym5	77.1	77.1	77.1	77.1	77.1	98.6
ÖZ		81.4	84.3	84.3	85.7	87.1	4.3		88.6	84.3	84.3	88.6	88.6	11.4		68.6	64.3	75.7	68.6	67.1	28.6		70.0	72.9	78.6	70.0	84.3	85.7		78.6	78.6	78.6	78.6	78.6	2.9
DO		80.0	80.0	80.0	80.7	80.7	52.1		79.3	80.7	80.7	79.3	80.0	50.7		75.0	73.6	74.3	75.0	74.3	49.3		76.4	75.7	75.7	75.7	76.4	47.9		77.9	77.9	77.9	77.9	77.9	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.7	0.7	0.8	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		11	11	11	6	11	96		15	1	1	15	15	96		8	2	27	8	9	96		7	5	10	5	30	96		3	10	10	10	10	96
HA	bior22	81.4	75.7	75.7	74.3	74.3	4.3	bior39	75.7	72.9	78.6	72.9	75.7	90.0	coif5	84.3	82.9	82.9	82.9	82.9	97.1	db8	80.0	78.6	74.3	67.1	70.0	10.0	sym6	80.0	82.9	82.9	80.0	81.4	77.1
ÖZ		80.0	81.4	81.4	80.0	75.7	100.0		84.3	88.6	81.4	87.1	85.7	11.4		71.4	68.6	68.6	68.6	68.6	5.7		72.9	71.4	74.3	82.9	81.4	90.0		75.7	74.3	74.3	75.7	75.7	20.0
DO		80.7	78.6	78.6	77.1	75.0	52.1		80.0	80.7	80.0	80.0	80.7	50.7		77.9	75.7	75.7	75.7	75.7	51.4		76.4	75.0	74.3	75.0	75.7	50.0		77.9	78.6	78.6	77.9	78.6	48.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.7	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		12	17	17	17	1	96		4	13	1	9	7	96		10	1	1	1	1	96		8	6	10	28	24	96		6	3	3	6	3	96
HA	bior24	75.7	78.6	75.7	75.7	81.4	2.9	bior44	78.6	80.0	80.0	80.0	75.7	2.9	db1	78.6	78.6	82.9	78.6	78.6	91.4	db9	74.3	77.1	78.6	82.9	75.7	2.9	sym7	81.4	81.4	81.4	81.4	78.6	81.4
ÖZ		74.3	70.0	80.0	80.0	71.4	98.6		75.7	70.0	70.0	68.6	74.3	98.6		78.6	78.6	75.7	78.6	78.6	11.4		78.6	74.3	75.7	64.3	81.4	100.0		70.0	70.0	71.4	70.0	74.3	20.0
DO		75.0	74.3	77.9	77.9	76.4	50.7		77.1	75.0	75.0	74.3	75.0	50.7		78.6	78.6	79.3	78.6	78.6	51.4		76.4	75.7	77.1	73.6	78.6	51.4		75.7	75.7	76.4	75.7	76.4	50.7
AUC		0.8	0.7	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.7	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.7	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		11	2	12	12	1	96		7	2	2	15	16	96		17	17	1	17	17	96		9	6	5	2	8	96		7	5	5	7	22	96
HA	bior26	72.9	74.3	78.6	72.9	80.0	4.3	bior55	78.6	77.1	77.1	78.6	77.1	82.9	db2	78.6	78.6	72.9	77.1	78.6	1.4	haar	78.6	78.6	82.9	78.6	78.6	91.4	sym8	77.1	72.9	72.9	72.9	72.9	78.6
ÖZ		80.0	78.6	72.9	80.0	70.0	100.0		87.1	85.7	85.7	88.6	85.7	20.0		78.6	78.6	85.7	81.4	80.0	100.0		78.6	78.6	75.7	78.6	78.6	11.4		72.9	78.6	78.6	78.6	78.6	20.0
DO		76.4	76.4	75.7	76.4	75.0	52.1		82.9	81.4	81.4	83.6	81.4	51.4		78.6	78.6	79.3	79.3	79.3	50.7		78.6	78.6	79.3	78.6	78.6	51.4		75.0	75.7	75.7	75.7	75.7	49.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		7	7	1	6	2	96		14	17	17	10	17	96		8	8	22	23	8	96		17	17	1	17	17	96		10	16	16	16	16	96
HA	bior28	81.4	80.0	81.4	81.4	70.0	2.9	bior68	75.7	77.1	77.1	77.1	74.3	2.9	db3	72.9	72.9	71.4	71.4	70.0	100.0	sym1	78.6	78.6	82.9	78.6	78.6	91.4							
ÖZ		75.7	74.3	75.7	77.1	81.4	100.0		75.7	78.6	78.6	78.6	77.1	100.0		87.1	88.6	90.0	90.0	90.0	2.9		78.6	78.6	75.7	78.6	78.6	11.4							
DO		78.6	77.1	78.6	79.3	75.7	51.4		75.7	77.9	77.9	77.9	75.7	51.4		80.0	80.7	80.7	80.7	80.0	51.4		78.6	78.6	79.3	78.6	78.6	51.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		10	9	10	10	16	96		8	3	2	3	9	96		27	24	24	24	17	96		17	17	1	17	17	96							
HA	bior31	77.1	72.9	75.7	74.3	74.3	18.6	coif1	71.4	71.4	71.4	71.4	71.4	97.1	db4	70.0	70.0	70.0	70.0	70.0	100.0	sym2	78.6	78.6	72.9	77.1	78.6	1.4							
ÖZ		84.3	90.0	82.9	85.7	82.9	81.4		88.6	88.6	88.6	88.6	88.6	4.3		88.6	88.6	88.6	88.6	88.6	8.6		78.6	78.6	85.7	81.4	80.0	100.0							
DO		80.7	81.4	79.3	80.0	78.6	50.0		80.0	80.0	80.0	80.0	80.0	50.7		79.3	79.3	79.3	79.3	79.3	54.3		78.6	78.6	79.3	79.3	79.3	50.7							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		22	21	20	21	3	96		17	17	17	17	17	96		17	17	17	17	17	96		8	8	22	23	8	96							
HA	bior33	75.7	72.9	75.7	75.7	77.1	91.4	coif2	81.4	80.0	75.7	81.4	81.4	81.4	db5	81.4	81.4	77.1	80.0	77.1	80.0	sym3	72.9	72.9	71.4	71.4	70.0	100.0							
ÖZ		80.0	88.6	90.0	90.0	81.4	11.4		75.7	77.1	80.0	75.7	75.7	20.0		74.3	74.3	78.6	77.1	78.6	20.0		87.1	88.6	90.0	90.0	90.0	2.9							
DO		77.9	80.7	82.9	82.9	79.3	51.4		78.6	78.6	77.9	78.6	78.6	50.7		77.9	77.9	77.9	78.6	77.9	50.0		80.0	80.7	80.7	80.7	80.0	51.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		5	24	26	26	3	96		5	1	17	5	3	96		1	1	10	1	10	96		27	24	24	24	17	96							

NS GM_200 (DVM-rbf)

		B	E	R	T	W	DR
HA	bior13	75.7	77.1	77.1	77.1	77.1	2.9
ÖZ		87.1	87.1	85.7	87.1	90.0	100.0
DO		81.4	82.1	81.4	82.1	83.6	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		16	11	23	23	19	96
HA	bior15	84.3	84.3	78.6	78.6	77.1	20.0
ÖZ		78.6	78.6	84.3	84.3	84.3	81.4
DO		81.4	81.4	81.4	81.4	80.7	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		5	5	10	10	17	96
HA	bior22	72.9	80.0	82.9	82.9	78.6	1.4
ÖZ		94.3	87.1	87.1	87.1	88.6	98.6
DO		83.6	83.6	85.0	85.0	83.6	50.0
AUC		0.8	0.8	0.9	0.9	0.8	0.5
ÖS		29	17	18	16	13	96
HA	bior24	77.1	75.7	77.1	77.1	78.6	80.0
ÖZ		90.0	91.4	90.0	90.0	91.4	20.0
DO		83.6	83.6	83.6	83.6	85.0	50.0
AUC		0.8	0.8	0.8	0.8	0.9	0.5
ÖS		7	13	25	29	24	96
HA	bior26	81.4	84.3	81.4	77.1	82.9	5.7
ÖZ		87.1	85.7	84.3	87.1	85.7	98.6
DO		84.3	85.0	82.9	82.1	84.3	52.1
AUC		0.8	0.9	0.8	0.8	0.8	0.5
ÖS		11	7	13	20	5	96
HA	bior28	85.7	85.7	87.1	81.4	81.4	80.0
ÖZ		84.3	84.3	81.4	84.3	87.1	20.0
DO		85.0	85.0	84.3	82.9	84.3	50.0
AUC		0.9	0.9	0.8	0.8	0.8	0.5
ÖS		4	4	15	17	20	96
HA	bior31	80.0	81.4	81.4	82.9	80.0	4.3
ÖZ		90.0	87.1	84.3	82.9	87.1	97.1
DO		85.0	84.3	82.9	82.9	83.6	50.7
AUC		0.9	0.8	0.8	0.8	0.8	0.5
ÖS		19	10	18	16	13	96
HA	bior33	84.3	81.4	75.7	77.1	77.1	80.0
ÖZ		87.1	88.6	87.1	87.1	87.1	20.0
DO		85.7	85.0	81.4	82.1	82.1	50.0
AUC		0.9	0.9	0.8	0.8	0.8	0.5
ÖS		14	16	20	18	18	96

		B	E	R	T	W	DR
HA	bior35	84.3	85.7	82.9	81.4	77.1	80.0
ÖZ		81.4	80.0	82.9	81.4	84.3	20.0
DO		82.9	82.9	82.9	81.4	80.7	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		6	4	17	17	7	96
HA	bior37	80.0	80.0	84.3	78.6	84.3	7.1
ÖZ		82.9	84.3	81.4	88.6	81.4	98.6
DO		81.4	82.1	82.9	83.6	82.9	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		4	9	1	18	1	96
HA	bior39	80.0	78.6	81.4	80.0	84.3	20.0
ÖZ		81.4	84.3	82.9	85.7	82.9	80.0
DO		80.7	81.4	82.1	82.9	83.6	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		16	12	16	18	8	96
HA	bior44	81.4	82.9	82.9	80.0	80.0	80.0
ÖZ		91.4	88.6	88.6	90.0	91.4	20.0
DO		86.4	85.7	85.7	85.0	85.7	50.0
AUC		0.9	0.9	0.9	0.9	0.9	0.5
ÖS		5	5	24	25	25	96
HA	bior55	80.0	80.0	77.1	74.3	77.1	2.9
ÖZ		82.9	82.9	82.9	84.3	82.9	98.6
DO		81.4	81.4	80.0	79.3	80.0	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		19	22	14	7	19	96
HA	bior68	81.4	81.4	84.3	78.6	78.6	4.3
ÖZ		82.9	82.9	82.9	87.1	82.9	97.1
DO		82.1	82.1	83.6	82.9	80.7	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		10	10	17	19	15	96
HA	coif1	81.4	81.4	81.4	78.6	80.0	4.3
ÖZ		87.1	87.1	87.1	87.1	87.1	100.0
DO		84.3	84.3	84.3	82.9	83.6	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		18	23	15	18	11	96
HA	coif2	78.6	74.3	72.9	72.9	77.1	2.9
ÖZ		84.3	87.1	87.1	84.3	84.3	97.1
DO		81.4	80.7	80.0	78.6	80.7	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		23	18	7	11	23	96

		B	E	R	T	W	DR
HA	coif3	75.7	78.6	78.6	75.7	78.6	10.0
ÖZ		84.3	85.7	85.7	85.7	85.7	98.6
DO		80.0	82.1	82.1	80.7	82.1	54.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		9	5	5	7	5	96
HA	coif4	75.7	75.7	75.7	77.1	75.7	4.3
ÖZ		87.1	87.1	85.7	84.3	85.7	100.0
DO		81.4	81.4	80.7	80.7	80.7	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		8	8	10	1	10	96
HA	coif5	72.9	75.7	77.1	77.1	77.1	5.7
ÖZ		85.7	84.3	82.9	84.3	85.7	100.0
DO		79.3	80.0	80.0	80.7	81.4	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		24	24	5	5	3	96
HA	db1	84.3	81.4	81.4	78.6	84.3	4.3
ÖZ		87.1	90.0	87.1	87.1	87.1	100.0
DO		85.7	85.7	84.3	82.9	85.7	52.1
AUC		0.9	0.9	0.8	0.8	0.9	0.5
ÖS		4	10	13	16	4	96
HA	db2	74.3	74.3	78.6	78.6	78.6	38.6
ÖZ		88.6	90.0	88.6	88.6	88.6	57.1
DO		81.4	82.1	83.6	83.6	83.6	47.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		17	16	23	23	23	96
HA	db3	81.4	80.0	81.4	81.4	81.4	5.7
ÖZ		82.9	87.1	82.9	82.9	82.9	100.0
DO		82.1	83.6	82.1	82.1	82.1	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		21	13	21	21	21	96
HA	db4	84.3	84.3	84.3	84.3	84.3	5.7
ÖZ		87.1	87.1	87.1	87.1	87.1	100.0
DO		85.7	85.7	85.7	85.7	85.7	52.9
AUC		0.9	0.9	0.9	0.9	0.9	0.5
ÖS		21	21	20	20	20	96
HA	db5	81.4	82.9	82.9	78.6	81.4	2.9
ÖZ		87.1	87.1	87.1	85.7	87.1	100.0
DO		84.3	85.0	85.0	82.1	84.3	51.4
AUC		0.8	0.9	0.9	0.8	0.8	0.5
ÖS		20	20	20	20	20	96

		B	E	R	T	W	DR
HA	db6	72.9	72.9	77.1	77.1	77.1	7.1
ÖZ		85.7	85.7	81.4	81.4	82.9	98.6
DO		79.3	79.3	79.3	79.3	80.0	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		3	3	15	15	20	96
HA	db7	74.3	77.1	74.3	80.0	75.7	2.9
ÖZ		87.1	84.3	87.1	81.4	88.6	100.0
DO		80.7	80.7	80.7	80.7	82.1	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		7	3	7	10	10	96
HA	db8	84.3	84.3	81.4	80.0	82.9	5.7
ÖZ		84.3	84.3	80.0	81.4	77.1	100.0
DO		84.3	84.3	80.7	80.7	80.0	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		17	17	8	10	13	96
HA	db9	77.1	71.4	77.1	77.1	77.1	2.9
ÖZ		85.7	90.0	87.1	85.7	84.3	97.1
DO		81.4	80.7	82.1	81.4	80.7	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		7	24	10	8	1	96
HA	haar	84.3	81.4	81.4	78.6	84.3	4.3
ÖZ		87.1	90.0	87.1	87.1	87.1	100.0
DO		85.7	85.7	84.3	82.9	85.7	52.1
AUC		0.9	0.9	0.8	0.8	0.9	0.5
ÖS		4	10	13	16	4	96
HA	sym1	84.3	81.4	81.4	78.6	84.3	4.3
ÖZ		87.1	90.0	87.1	87.1	87.1	100.0
DO		85.7	85.7	84.3	82.9	85.7	52.1
AUC		0.9	0.9	0.8	0.8	0.9	0.5
ÖS		4	10	13	16	4	96
HA	sym2	74.3	74.3	78.6	78.6	78.6	38.6
ÖZ		88.6	90.0	88.6	88.6	88.6	57.1
DO		81.4	82.1	83.6	83.6	83.6	47.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		17	16	23	23	23	96
HA	sym3	81.4	80.0	81.4	81.4	81.4	5.7
ÖZ		82.9	87.1	82.9	82.9	82.9	100.0
DO		82.1	83.6	82.1	82.1	82.1	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		21	13	21	21	21	96

		B	E	R	T	W	DR
HA	sym4	82.9	81.4	81.4	81.4	81.4	4.3
ÖZ		85.7	87.1	84.3	84.3	87.1	97.1
DO		84.3	84.3	82.9	82.9	84.3	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		20	21	17	17	21	96
HA	sym5	80.0	77.1	77.1	78.6	77.1	7.1
ÖZ		85.7	84.3	84.3	81.4	84.3	100.0
DO		82.9	80.7	80.7	80.0	80.7	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		14	9	9	10	8	96
HA	sym6	74.3	78.6	78.6	78.6	78.6	8.6
ÖZ		85.7	85.7	84.3	84.3	87.1	98.6
DO		80.0	82.1	81.4	81.4	82.9	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		29	18	20	20	20	96
HA	sym7	75.7	78.6	77.1	77.1	77.1	82.9
ÖZ		82.9	80.0	82.9	81.4	82.9	18.6
DO		79.3	79.3	80.0	79.3	80.0	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	15	1	6	1	96
HA	sym8	72.9	72.9	72.9	72.9	72.9	8.6
ÖZ		85.7	85.7	85.7	85.7	87.1	98.6
DO		79.3	79.3	79.3	79.3	80.0	53.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		7	5	7	6	5	96

MNS BM_200 (DVM-rbf)

		B	E	R	T	W	DR
HA	bior13	67.1	67.1	67.1	67.1	72.9	20.0
ÖZ		78.6	78.6	78.6	78.6	78.6	78.6
DO		72.9	72.9	72.9	72.9	75.7	49.3
AUC		0.7	0.7	0.7	0.7	0.8	0.5
ÖS		17	18	18	18	11	96
HA	bior15	68.6	68.6	70.0	68.6	71.4	95.7
ÖZ		78.6	80.0	77.1	80.0	78.6	2.9
DO		73.6	74.3	73.6	74.3	75.0	49.3
AUC		0.7	0.7	0.7	0.7	0.8	0.5
ÖS		13	17	10	17	11	96
HA	bior22	82.9	82.9	82.9	82.9	82.9	98.6
ÖZ		70.0	70.0	70.0	70.0	70.0	4.3
DO		76.4	76.4	76.4	76.4	76.4	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	bior24	82.9	82.9	77.1	82.9	82.9	18.6
ÖZ		68.6	68.6	74.3	68.6	68.6	80.0
DO		75.7	75.7	75.7	75.7	75.7	49.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	12	1	1	96
HA	bior26	82.9	82.9	82.9	82.9	82.9	98.6
ÖZ		70.0	70.0	70.0	70.0	70.0	4.3
DO		76.4	76.4	76.4	76.4	76.4	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	bior28	82.9	82.9	82.9	82.9	82.9	95.7
ÖZ		72.9	72.9	72.9	72.9	72.9	4.3
DO		77.9	77.9	77.9	77.9	77.9	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	bior31	77.1	88.6	74.3	75.7	75.7	100.0
ÖZ		74.3	68.6	75.7	75.7	75.7	2.9
DO		75.7	78.6	75.0	75.7	75.7	51.4
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		3	3	4	3	3	96
HA	bior33	81.4	81.4	75.7	70.0	75.7	81.4
ÖZ		72.9	72.9	74.3	80.0	72.9	20.0
DO		77.1	77.1	75.0	75.0	74.3	50.7
AUC		0.8	0.8	0.8	0.8	0.7	0.5
ÖS		4	4	6	20	6	96

		B	E	R	T	W	DR
HA	bior35	80.0	81.4	78.6	71.4	72.9	7.1
ÖZ		70.0	71.4	65.7	71.4	71.4	100.0
DO		75.0	76.4	72.1	71.4	72.1	53.6
AUC		0.8	0.8	0.7	0.7	0.7	0.5
ÖS		4	6	2	15	3	96
HA	bior37	78.6	71.4	84.3	81.4	84.3	82.9
ÖZ		65.7	75.7	64.3	65.7	64.3	20.0
DO		72.1	73.6	74.3	73.6	74.3	51.4
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		3	20	3	2	3	96
HA	bior39	67.1	75.7	72.9	72.9	78.6	81.4
ÖZ		74.3	68.6	78.6	78.6	74.3	22.9
DO		70.7	72.1	75.7	75.7	76.4	52.1
AUC		0.7	0.7	0.8	0.8	0.8	0.5
ÖS		14	5	8	8	6	96
HA	bior44	84.3	84.3	84.3	84.3	84.3	5.7
ÖZ		68.6	68.6	68.6	68.6	68.6	100.0
DO		76.4	76.4	76.4	76.4	76.4	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	bior55	62.9	62.9	61.4	61.4	61.4	70.0
ÖZ		84.3	74.3	72.9	75.7	75.7	30.0
DO		73.6	68.6	67.1	68.6	68.6	50.0
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		8	2	1	2	1	96
HA	bior68	78.6	78.6	78.6	78.6	78.6	77.1
ÖZ		75.7	75.7	75.7	75.7	75.7	18.6
DO		77.1	77.1	77.1	77.1	77.1	47.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	coif1	80.0	80.0	81.4	81.4	81.4	97.1
ÖZ		71.4	71.4	70.0	70.0	71.4	2.9
DO		75.7	75.7	75.7	75.7	76.4	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	2	2	3	96
HA	coif2	82.9	82.9	82.9	82.9	82.9	94.3
ÖZ		70.0	70.0	70.0	70.0	70.0	4.3
DO		76.4	76.4	76.4	76.4	76.4	49.3
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96

		B	E	R	T	W	DR
HA	coif3	81.4	81.4	81.4	81.4	81.4	8.6
ÖZ		71.4	71.4	71.4	71.4	71.4	88.6
DO		76.4	76.4	76.4	76.4	76.4	48.6
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		1	1	1	1	1	96
HA	coif4	72.9	72.9	72.9	72.9	72.9	95.7
ÖZ		77.1	77.1	80.0	77.1	77.1	4.3
DO		75.0	75.0	76.4	75.0	75.0	50.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		13	3	9	3	3	96
HA	coif5	74.3	67.1	65.7	74.3	67.1	8.6
ÖZ		74.3	81.4	81.4	74.3	81.4	88.6
DO		74.3	74.3	73.6	74.3	74.3	48.6
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	3	10	2	3	96
HA	db1	62.9	62.9	61.4	62.9	70.0	100.0
ÖZ		78.6	78.6	77.1	78.6	70.0	4.3
DO		70.7	70.7	69.3	70.7	70.0	52.1
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		1	1	27	1	10	96
HA	db2	64.3	60.0	68.6	55.7	68.6	98.6
ÖZ		81.4	82.9	71.4	82.9	71.4	4.3
DO		72.9	71.4	70.0	69.3	70.0	51.4
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		5	18	34	17	34	96
HA	db3	57.1	64.3	58.6	55.7	67.1	98.6
ÖZ		81.4	75.7	84.3	84.3	77.1	4.3
DO		69.3	70.0	71.4	70.0	72.1	51.4
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	10	23	24	11	96
HA	db4	55.7	60.0	48.6	48.6	48.6	50.0
ÖZ		84.3	85.7	90.0	90.0	90.0	50.0
DO		70.0	72.9	69.3	69.3	69.3	50.0
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	10	6	6	6	96
HA	db5	68.6	78.6	78.6	78.6	78.6	97.1
ÖZ		72.9	68.6	68.6	68.6	68.6	7.1
DO		70.7	73.6	73.6	73.6	73.6	52.1
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		3	2	2	2	2	96

		B	E	R	T	W	DR
HA	db6	70.0	75.7	75.7	75.7	74.3	20.0
ÖZ		77.1	71.4	71.4	71.4	72.9	80.0
DO		73.6	73.6	73.6	73.6	73.6	50.0
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		4	8	8	8	18	96
HA	db7	62.9	62.9	72.9	72.9	72.9	11.4
ÖZ		81.4	81.4	70.0	70.0	70.0	88.6
DO		72.1	72.1	71.4	71.4	71.4	50.0
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		3	3	1	1	1	96
HA	db8	67.1	80.0	78.6	58.6	78.6	82.9
ÖZ		87.1	80.0	75.7	81.4	75.7	20.0
DO		77.1	80.0	77.1	70.0	77.1	51.4
AUC		0.8	0.8	0.8	0.7	0.8	0.5
ÖS		30	17	9	29	9	96
HA	db9	75.7	71.4	65.7	65.7	62.9	12.9
ÖZ		65.7	71.4	81.4	81.4	78.6	88.6
DO		70.7	71.4	73.6	73.6	70.7	50.7
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	9	25	25	15	96
HA	haar	62.9	62.9	61.4	62.9	70.0	100.0
ÖZ		78.6	78.6	77.1	78.6	70.0	4.3
DO		70.7	70.7	69.3	70.7	70.0	52.1
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		1	1	27	1	10	96
HA	sym1	62.9	62.9	61.4	62.9	70.0	100.0
ÖZ		78.6	78.6	77.1	78.6	70.0	4.3
DO		70.7	70.7	69.3	70.7	70.0	52.1
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		1	1	27	1	10	96
HA	sym2	64.3	60.0	68.6	55.7	68.6	98.6
ÖZ		81.4	82.9	71.4	82.9	71.4	4.3
DO		72.9	71.4	70.0	69.3	70.0	51.4
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		5	18	34	17	34	96
HA	sym3	57.1	64.3	58.6	55.7	67.1	98.6
ÖZ		81.4	75.7	84.3	84.3	77.1	4.3
DO		69.3	70.0	71.4	70.0	72.1	51.4
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	10	23	24	11	96

		B	E	R	T	W	DR
HA	sym4	67.1	64.3	70.0	60.0	70.0	80.0
ÖZ		78.6	84.3	81.4	85.7	81.4	21.4
DO		72.9	74.3	75.7	72.9	75.7	50.7
AUC		0.7	0.7	0.8	0.7	0.8	0.5
ÖS		6	24	16	2	15	96
HA	sym5	70.0	70.0	65.7	65.7	65.7	94.3
ÖZ		74.3	74.3	81.4	81.4	81.4	1.4
DO		72.1	72.1	73.6	73.6	73.6	47.9
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	2	6	6	6	96
HA	sym6	71.4	77.1	71.4	77.1	71.4	80.0
ÖZ		80.0	71.4	75.7	71.4	75.7	20.0
DO		75.7	74.3	73.6	74.3	73.6	50.0
AUC		0.8	0.7	0.7	0.7	0.7	0.5
ÖS		9	5	2	5	2	96
HA	sym7	60.0	54.3	51.4	51.4	55.7	97.1
ÖZ		78.6	81.4	80.0	80.0	77.1	2.9
DO		69.3	67.9	65.7	65.7	66.4	50.0
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		5	2	6	6	9	96
HA	sym8	70.0	72.9	72.9	65.7	70.0	2.9
ÖZ		77.1	75.7	75.7	81.4	78.6	98.6
DO		73.6	74.3	74.3	73.6	74.3	50.7
AUC		0.7	0.7	0.7	0.7	0.7	0.5
ÖS		2	5	5	20	21	96

NS BM_200 (DVM-rbf)

		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR		B	E	R	T	W	DR
HA	bior13	81.4	80.0	80.0	80.0	74.3	11.4	bior35	71.4	72.9	72.9	72.9	75.7	18.6	coif3	70.0	72.9	72.9	75.7	70.0	5.7	db6	64.3	72.9	72.9	75.7	74.3	10.0	sym4	75.7	80.0	77.1	77.1	77.1	2.9
ÖZ		80.0	80.0	77.1	77.1	80.0	100.0		81.4	80.0	80.0	82.9	78.6	81.4		81.4	81.4	80.0	81.4	81.4	98.6		84.3	77.1	77.1	75.7	75.7	100.0		77.1	75.7	80.0	80.0	80.0	98.6
DO		80.7	80.0	78.6	78.6	77.1	55.7		76.4	76.4	76.4	77.9	77.1	50.0		75.7	77.1	76.4	78.6	75.7	52.1		74.3	75.0	75.0	75.7	75.0	55.0		76.4	77.9	78.6	78.6	78.6	50.7
AUC		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.7	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		4	8	3	2	8	96		2	6	22	15	11	96		28	21	15	27	6	96		46	14	2	5	9	96		10	9	1	1	1	96
HA	bior15	80.0	81.4	77.1	80.0	77.1	14.3	bior37	70.0	70.0	74.3	74.3	72.9	80.0	coif4	77.1	70.0	74.3	61.4	74.3	2.9	db7	75.7	74.3	71.4	71.4	71.4	4.3	sym5	75.7	77.1	67.1	74.3	72.9	10.0
ÖZ		78.6	78.6	78.6	77.1	81.4	90.0		85.7	82.9	78.6	78.6	81.4	20.0		75.7	81.4	77.1	88.6	80.0	98.6		77.1	80.0	81.4	81.4	81.4	100.0		81.4	82.9	90.0	82.9	84.3	100.0
DO		79.3	80.0	77.9	78.6	79.3	52.1		77.9	76.4	76.4	76.4	77.1	50.0		76.4	75.7	75.7	75.0	77.1	50.7		76.4	77.1	76.4	76.4	76.4	52.1		78.6	80.0	78.6	78.6	78.6	55.0
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6
ÖS		6	4	4	2	14	96		28	3	9	9	11	96		5	27	12	49	3	96		15	14	1	1	1	96		3	4	38	4	27	96
HA	bior22	65.7	65.7	78.6	70.0	78.6	5.7	bior39	72.9	72.9	71.4	72.9	74.3	80.0	coif5	77.1	75.7	68.6	71.4	72.9	8.6	db8	74.3	75.7	70.0	74.3	71.4	11.4	sym6	78.6	74.3	80.0	82.9	81.4	7.1
ÖZ		85.7	85.7	77.1	81.4	77.1	98.6		81.4	81.4	81.4	81.4	80.0	20.0		77.1	80.0	82.9	82.9	78.6	98.6		80.0	82.9	81.4	77.1	80.0	90.0		80.0	85.7	78.6	74.3	78.6	98.6
DO		75.7	75.7	77.9	75.7	77.9	52.1		77.1	77.1	76.4	77.1	77.1	50.0		77.1	77.9	75.7	77.1	75.7	53.6		77.1	79.3	75.7	75.7	75.7	50.7		79.3	80.0	79.3	78.6	80.0	52.9
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		38	38	13	3	13	96		2	2	1	15	10	96		14	14	2	26	20	96		30	14	5	5	5	96		2	21	7	1	9	96
HA	bior24	80.0	74.3	82.9	80.0	77.1	7.1	bior44	82.9	78.6	82.9	82.9	81.4	7.1	db1	75.7	75.7	75.7	75.7	75.7	12.9	db9	71.4	71.4	68.6	67.1	71.4	8.6	sym7	77.1	75.7	74.3	74.3	74.3	4.3
ÖZ		77.1	75.7	75.7	77.1	77.1	100.0		78.6	75.7	78.6	78.6	77.1	98.6		80.0	80.0	78.6	80.0	78.6	97.1		77.1	71.4	80.0	81.4	74.3	100.0		78.6	78.6	75.7	77.1	82.9	100.0
DO		78.6	75.0	79.3	78.6	77.1	53.6		80.7	77.1	80.7	80.7	79.3	52.9		77.9	77.9	77.1	77.9	77.1	55.0		74.3	71.4	74.3	74.3	72.9	54.3		77.9	77.1	75.0	75.7	78.6	52.1
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.7	0.7	0.7	0.7	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		4	4	3	9	10	96		2	5	2	2	3	96		8	9	7	7	7	96		25	5	12	2	14	96		8	10	5	5	15	96
HA	bior26	67.1	68.6	67.1	71.4	81.4	4.3	bior55	70.0	70.0	70.0	67.1	71.4	11.4	db2	71.4	75.7	72.9	72.9	72.9	11.4	haar	75.7	75.7	75.7	75.7	75.7	12.9	sym8	77.1	80.0	80.0	80.0	80.0	5.7
ÖZ		80.0	84.3	84.3	78.6	70.0	100.0		82.9	85.7	84.3	87.1	85.7	98.6		81.4	77.1	78.6	78.6	78.6	97.1		80.0	80.0	78.6	80.0	78.6	97.1		78.6	77.1	75.7	77.1	75.7	98.6
DO		73.6	76.4	75.7	75.0	75.7	52.1		76.4	77.9	77.1	77.1	78.6	55.0		76.4	76.4	75.7	75.7	75.7	54.3		77.9	77.9	77.1	77.9	77.1	55.0		77.9	78.6	77.9	78.6	77.9	52.1
AUC		0.7	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.5
ÖS		2	3	3	7	1	96		12	9	7	23	7	96		14	7	8	8	8	96		8	9	7	7	7	96		10	5	2	16	2	96
HA	bior28	78.6	77.1	75.7	75.7	74.3	4.3	bior68	77.1	77.1	77.1	78.6	81.4	4.3	db3	74.3	72.9	71.4	71.4	77.1	15.7	sym1	75.7	75.7	75.7	75.7	75.7	12.9							
ÖZ		71.4	77.1	78.6	77.1	74.3	100.0		77.1	77.1	75.7	77.1	77.1	100.0		75.7	78.6	81.4	81.4	75.7	97.1		80.0	80.0	78.6	80.0	78.6	97.1							
DO		75.0	77.1	77.1	76.4	74.3	52.1		77.1	77.1	76.4	77.9	79.3	52.1		75.0	75.7	76.4	76.4	76.4	56.4		77.9	77.9	77.1	77.9	77.1	55.0							
AUC		0.8	0.8	0.8	0.8	0.7	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		9	13	4	2	5	96		13	12	5	2	2	96		4	5	14	14	2	96		8	9	7	7	7	96							
HA	bior31	67.1	68.6	70.0	70.0	72.9	80.0	coif1	72.9	75.7	71.4	71.4	71.4	5.7	db4	77.1	70.0	71.4	72.9	72.9	11.4	sym2	71.4	75.7	72.9	72.9	72.9	11.4							
ÖZ		85.7	84.3	84.3	84.3	78.6	21.4		78.6	77.1	82.9	82.9	81.4	98.6		75.7	80.0	80.0	77.1	77.1	91.4		81.4	77.1	78.6	78.6	78.6	97.1							
DO		76.4	76.4	77.1	77.1	75.7	50.7		75.7	76.4	77.1	77.1	76.4	52.1		76.4	75.0	75.7	75.0	75.0	51.4		76.4	76.4	75.7	75.7	75.7	54.3							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5							
ÖS		24	22	18	18	1	96		10	8	13	2	13	96		9	29	1	5	10	96		14	7	8	8	8	96							
HA	bior33	74.3	72.9	70.0	70.0	74.3	80.0	coif2	72.9	71.4	72.9	71.4	74.3	8.6	db5	75.7	71.4	70.0	72.9	70.0	11.4	sym3	74.3	72.9	71.4	71.4	77.1	15.7							
ÖZ		78.6	80.0	84.3	87.1	78.6	20.0		77.1	81.4	82.9	84.3	84.3	100.0		74.3	77.1	81.4	77.1	81.4	90.0		75.7	78.6	81.4	81.4	75.7	97.1							
DO		76.4	76.4	77.1	78.6	76.4	50.0		75.0	76.4	77.9	77.9	79.3	54.3		75.0	74.3	75.7	75.0	75.7	50.7		75.0	75.7	76.4	76.4	76.4	56.4							
AUC		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.5		0.8	0.7	0.8	0.8	0.8	0.5		0.8	0.8	0.8	0.8	0.8	0.6							
ÖS		9	14	22	19	2	96		2	2	24	28	28	96		6	5	1	5	1	96		4	5	14	14	2	96							

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	Muhammet Üsame ÖZİÇ
Uyruğu	**:**	T.C.
Doğum Yeri ve Tarihi	**:**	Muğla 19.12.1984
Telefon	**:**	
Faks	**:**	
e-mail	**:**	muozic@selcuk.edu.tr, muozic@gmail.com

EĞİTİM

Derece		**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	:	**TEV Anadolu Lisesi, Denizli**	**2005**
Üniversite	:	**Uludağ Üniversitesi Elektronik Mühendisliği**	**2010**
Yüksek Lisans	:	**Selçuk Üniversitesi Elektrik-Elektronik Müh.**	**2013**
Doktora	:	**Selçuk Üniversitesi Elektrik-Elektronik Müh.**	**2018**

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**
2010-2012	**Karabük Üniversitesi**	**Arş. Gör.**
2012-	**Selçuk Üniversitesi**	**Arş. Gör.**

UZMANLIK ALANI

Elektronik, Biyomedikal Görüntü ve Sinyal İşleme, Yapay Zeka, Veri Madenciliği, Makina Öğrenmesi

YABANCI DİLLER

İngilizce (YÖKDİL 2017: 85)

YAYINLAR

Öziç, M.Ü., & Özsen, S., (2017), 3D Electronic Brain Atlas Model For The Detection of Neurological Disorders, *Electronics World*, *123*(1973), 26-29

Acer, N., Bastepe-Gray, S., Sagiroglu, A., Gumus, K. Z., Degirmencioglu, L., Zararsiz, G., & Ozic, M. U. (2018). Diffusion tensor and volumetric magnetic resonance imaging findings in the brains of professional musicians. *Journal of chemical neuroanatomy*, *88*, 33-40.

Ekmekci, H. A., Yılmaz, A. S., Öziç, M. Ü., Özbay, Y., Kerimoğlu, Ö. S., Çelik, Ç., & Öztürk, Ş., (2016). Hyperemesis Gravidarum and Cerebral Electrophysiology Determination of Cerebral Localization through Electroencephalography Signal Processing. *Turkish Journal of Neurology*, *22*(2)

Özic, M. Ü., Ekmekci, A. H., & Özşen, S., (2017), Creation of 3D Volume Loss Mask and Mean Performance Analysis on 3d MR Images. *Journal of Biomedical Engineering and Medical Imaging*, *4*(3), 36.

Ekmekci, H., Öziç, M. Ü., Öztürk, Ş., (2016), The Role and Effect of Modafinil on Normal-Physilological Night Sleep, *International Journal of Clinical Neurosciences and Mental Health*, 2016

Öziç, M. Ü., Özşen, S., & Ekmekci, A. H., (2017), A Novel Feature Extraction Approach with VBM 3D ROI Masks on MRI. In *CMBEBIH 2017* (pp. 523-530). Springer, Saraybosna, Bosna Hersek.

Öziç, M. Ü., & Özşen, S., (2017), T-test feature ranking based 3D MR classification with VBM mask., 2nd International Workshop on Machine Learning For Understanding the Brain, *In Signal Processing and Communications Applications Conference (SIU)*, 2017 25th (pp. 1-4). IEEE, Antalya

Öziç, M. Ü., & Özşen, S., (2017), Analysis of Limbic System Volume with Atlas Based Volume Measurement Pipeline on Alzheimer Disease, *International Conference on Advences and Innovations in Engineering, ICAIE*, (pp. 34-38), Elazığ

Öziç, M. Ü., & Özşen, S., (2017), A New Model to Determine Asymmetry Coefficients on MR Images Using PSNR and SSIM, *International Artificial Intelligence and Data Processing Symposium'17, IEEE*, Eylül 2017, Malatya

Öziç, M. Ü., Özşen, S., Ekmekci, A., H., (2017), Voxel Based Morphometric Analysis on MR Images, *International Artificial Intelligence and Data Processing Symposium'17, IEEE,* Eylül 2017, Malatya

Öziç, M. Ü., Özşen, S., Ekmekci, A., H., (2018), Atlas-Based Segmentation Pipelines on 3D Brain MR Images: A Preliminary Study, *BRAIN, Broad Research in Artificial Intelligence and Neuroscience*, Vol.9, Issue 4