

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ BİLİŞİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DEMANS TAHMİNİ

YÜKSEK LİSANS TEZİ

Tuğba TUNA

Hesaplamalı Bilim ve Mühendislik Anabilim Dalı

Hesaplamalı Bilim ve Mühendislik Programı

ARALIK 2019

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ BİLİŞİM ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DEMANS TAHMİNİ

YÜKSEK LİSANS TEZİ

**Tuğba TUNA
(702161010)**

Hesaplamalı Bilim ve Mühendislik Anabilim Dalı

Hesaplamalı Bilim ve Mühendislik Programı

**Tez Danışmanı: Prof. Dr. F. Aylin SUNGUR
Eş Danışman: Prof. Dr. Mustafa Ersel KAMAŞAK**

ARALIK 2019

İTÜ, Bilişim Enstitüsü'nün 702161010 numaralı Yüksek Lisans Öğrencisi Tuğba TUNA, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DEMANS TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. F. Aylin SUNGUR**
İstanbul Teknik Üniversitesi

Eş Danışman : **Prof. Dr. Mustafa Ersel KAMAŞAK**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Adem TEKİN**
İstanbul Teknik Üniversitesi

Doç. Dr. Gökhan BİLGİN
Yıldız Teknik Üniversitesi

Doç. Dr. Songül ALBAYRAK
Yıldız Teknik Üniversitesi

Teslim Tarihi : **15 Kasım 2019**
Savunma Tarihi : **12 Aralık 2019**





Sevgili aileme,



ÖNSÖZ

Tez çalışmam boyunca öneri ve ilgilerini eksik etmeyerek, bilgi ve deneyimleriyle her zaman yardımcı olan danışmanım Prof. Dr. F. Aylin SUNGUR'a ve eş danışmanım Prof. Dr. Mustafa Ersel KAMAŞAK'a teşekkürlerimi sunarım.

Ayrıca bugüne kadar desteklerini hiçbir zaman esirgemeyen aileme teşekkür ederim.

Aralık 2019

Tuğba TUNA
Matematik Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1 Demans.....	1
1.1.1 Demansın belirtileri ve evreleri.....	2
1.1.1.1 Erken evre	2
1.1.1.2 Orta evre.....	2
1.1.1.3 Geç evre	2
1.1.2 Demansın risk faktörleri.....	2
1.1.2.1 Yaş	3
1.1.2.2 Cinsiyet	3
1.1.2.3 Etnik köken	3
1.1.2.4 Genetik	4
1.1.2.5 Diğer tıbbi durum ve hastalıklar	4
1.1.3 Demansın görülme sıklığı	5
1.1.4 Demansın teşhis edilmesinde nöropsikolojik testler ve ölçekler	5
1.1.4.1 Mini mental durum muayenesi.....	5
1.2 Makine Öğrenmesi	6
1.3 Literatür Araştırması	8
1.4 Tezin Amacı	10
2. YÖNTEM.....	11
2.1 Veri Ön İşleme Yöntemleri	11
2.1.1 Veri temizleme	11
2.1.2 Veri dönüştürme.....	11
2.2 Algoritmalar	12
2.2.1 K-en yakın komşuluk	12
2.2.2 Destek vektör makineleri	13
2.2.2.1 Doğrusal destek vektör makineleri.....	14
2.2.2.2 Doğrusal olmayan destek vektör makineleri.....	17
2.2.3 Karar ağaçları	19
2.2.3.1 CART	20
2.2.4 Rastgele orman.....	21
3. BULGULAR	25
3.1 Veri Seti ve Hazırlanması	25
3.2 Sınıflandırma Sonuçları.....	27

3.2.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları	27
3.2.2 Destek vektör makineleri algoritması sınıflandırma sonuçları	28
3.2.3 Karar ağaçları algoritması sınıflandırma sonuçları	28
3.2.4 Rastgele orman algoritması sınıflandırma sonuçları	29
3.3 Veri Seti Bölünmesi ile Elde Edilen Sınıflandırma Sonuçları	30
3.3.1 Grup I	30
3.3.1.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları	30
3.3.1.2 Destek vektör makineleri algoritması sınıflandırma sonuçları	30
3.3.1.3 Karar ağaçları algoritması sınıflandırma sonuçları	31
3.3.1.4 Rastgele orman algoritması sınıflandırma sonuçları	31
3.3.2 Grup II	32
3.3.2.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları	32
3.3.2.2 Destek vektör makineleri algoritması sınıflandırma sonuçları	33
3.3.2.3 Karar ağaçları algoritması sınıflandırma sonuçları	33
3.3.2.4 Rastgele orman algoritması sınıflandırma sonuçları	34
3.3.3 Grup III	34
3.3.3.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları	34
3.3.3.2 Destek vektör makineleri algoritması sınıflandırma sonuçları	35
3.3.3.3 Karar ağaçları algoritması sınıflandırma sonuçları	35
3.3.3.4 Rastgele orman algoritması sınıflandırma sonuçları	36
3.3.4 Grup IV	36
3.3.4.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları	36
3.3.4.2 Destek vektör makineleri algoritması sınıflandırma sonuçları	37
3.3.4.3 Karar ağaçları algoritması sınıflandırma sonuçları	37
3.3.4.4 Rastgele orman algoritması sınıflandırma sonuçları	38
3.4 Bölünmemiş Veri Seti için Özniteliklerin Önem Sıralaması	38
3.5 Mini Mental Durum Muayenesi Başarısı	39
4. TARTIŞMA	41
5. SONUÇ	47
KAYNAKLAR.....	48
ÖZGEÇMİŞ.....	53

KISALTMALAR

APOE	: Apolipoprotein E
BOMC	: Blessed Oryantasyon Bellek Konsantrasyon Testi
CDR	: Klinik Demans Değerlendirme Ölçeği
CDR-SOB	: Kutu Toplamları Skoru
DVM	: Destek Vektör Makineleri
FAQ	: Fonksiyonel Aktiviteler Ölçeği
FN	: False Negative
FP	: False Positive
GDS	: Global Detoriasyon Skalası
ICP	: Ishihara Color Plates
KA	: Karar Ağaçları
KKT	: Karush-Kuhn-Tucker
KNN	: K-En Yakın Komşuluk
MMSE	: Mini Mental Durum Muayenesi
MRI	: Manyetik Rezonans Görüntüleme
OASIS	: Open Access Series of Imaging Studies
RO	: Rastgele Orman
TN	: True Negative
TP	: True Positive
YNO	: Yanlış negatif oranı



SEMBOLLER

x_i	: Öznitelik vektörü
μ	: Ortalama
σ	: Standart sapma
y_i	: Sınıf değeri
Q_1	: 1.Kartil
Q_3	: 3.Kartil
w	: Hiper düzlemin normali
b	: Sapma değeri
ξ_i	: Gevşek değişken
C	: Ceza parametresi
a_i, μ_i	: Lagrange parametreleri
K	: Kernel fonksiyonu
$\varphi(x)$	: Haritalama fonksiyonu
γ	: Gamma değeri
p_i	: Katışıklık ölçümü için olasılık değeri
$\theta(s, t)$	: Twoing kriteri için en iyi bölünme fonksiyonu
s	: Twoing kriteri için bölünme sınıfı
t	: Twoing kriteri için düğüm
p_R, p_L	: Twoing kriteri için sağ ve sol bölünme
j	: t düğümündeki sınıflar
p	: Sınıf bölünmeleri
C_1, C_2	: Twoing kriteri için süper sınıflar



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : MMSE skorları ve değerlendirme sonucu.....	6
Çizelge 3.1 : Veri setinin istatistiksel analizi.	26
Çizelge 3.2 : Karmaşıklık matrisi örneği.	27
Çizelge 3.3 : KNN karmaşıklık matrisi.	28
Çizelge 3.4 : KNN performans ölçümleri.....	28
Çizelge 3.5 : DVM karmaşıklık matrisi.....	28
Çizelge 3.6 : DVM performans ölçümleri.	28
Çizelge 3.7 : KA karmaşıklık matrisi.	29
Çizelge 3.8 : KA performans ölçümleri.....	29
Çizelge 3.9 : RO karmaşıklık matrisi.	29
Çizelge 3.10 : RO performans ölçümleri.....	29
Çizelge 3.11 : Grup I için KNN karmaşıklık matrisi.....	30
Çizelge 3.12 : Grup I için KNN performans ölçümleri.	30
Çizelge 3.13 : Grup I için DVM karmaşıklık matrisi.	31
Çizelge 3.14 : Grup I için DVM performans ölçümleri.....	31
Çizelge 3.15 : Grup I için KA karmaşıklık matrisi.....	31
Çizelge 3.16 : Grup I için KA performans ölçümleri.	31
Çizelge 3.17 : Grup I için RO karmaşıklık matrisi.	32
Çizelge 3.18 : Grup I için RO performans ölçümleri.	32
Çizelge 3.19 : Grup II için KNN karmaşıklık matrisi.	32
Çizelge 3.20 : Grup II için KNN performans ölçümleri.....	32
Çizelge 3.21 : Grup II için DVM karmaşıklık matrisi.....	33
Çizelge 3.22 : Grup II için DVM performans ölçümleri.	33
Çizelge 3.23 : Grup II için KA karmaşıklık matrisi.	33
Çizelge 3.24 : Grup II için KA performans ölçümleri.....	33
Çizelge 3.25 : Grup II için RO karmaşıklık matrisi.....	34
Çizelge 3.26 : Grup II için RO performans ölçümleri.	34
Çizelge 3.27 : Grup III için KNN karmaşıklık matrisi.	34
Çizelge 3.28 : Grup III için KNN performans ölçümleri.....	35
Çizelge 3.29 : Grup III için DVM karmaşıklık matrisi.	35
Çizelge 3.30 : Grup III için DVM performans ölçümleri.....	35
Çizelge 3.31 : Grup III için KA karmaşıklık matrisi.	35
Çizelge 3.32 : Grup III için KA performans ölçümleri.	36
Çizelge 3.33 : Grup III için RO karmaşıklık matrisi.	36
Çizelge 3.34 : Grup III için RO performans ölçümleri.....	36
Çizelge 3.35 : Grup IV için KNN karmaşıklık matrisi.....	37
Çizelge 3.36 : Grup IV için KNN performans ölçümleri.	37
Çizelge 3.37 : Grup IV için DVM karmaşıklık matrisi.	37
Çizelge 3.38 : Grup IV için DVM performans ölçümleri.....	37
Çizelge 3.39 : Grup IV için KA karmaşıklık matrisi.....	38
Çizelge 3.40 : Grup IV için KA performans ölçümleri.	38
Çizelge 3.41 : Grup IV için RO karmaşıklık matrisi.	38

Çizelge 3.42 : Grup IV için RO performans ölçümleri.....	38
Çizelge 3.43 : Özniteliklerin önem sıralaması.	39
Çizelge 3.44 : MMSE karmaşıklık matrisi.	39
Çizelge 3.45 : MMSE performans ölçümleri.....	39



ŞEKİL LİSTESİ

Sayfa

ŞEKİL 2.1 : Doğrusal ayrılabilen DVM.	15
ŞEKİL 2.2 : Tam ayrılamayan DVM.	17
ŞEKİL 2.3 : Doğrusal olmayan DVM.	17
ŞEKİL 2.4 : Derinliği üç olan bir karar ağacı yapısı.	19
ŞEKİL 2.5 : Rastgele orman yapısı.	22
ŞEKİL 4.1 : Doğruluk karşılaştırması.	43
ŞEKİL 4.2 : Duyarlılık karşılaştırması.	43
ŞEKİL 4.3 : YNO karşılaştırması.	44
ŞEKİL 4.4 : Özgüllük karşılaştırması.	44



MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DEMANS TAHMİNİ

ÖZET

Demans, bilişsel işlevde normal yaşlanmanın sebep olduğu etkinin ötesinde bir bozulma yaratan, birçok farklı beyin hastalığı içeren bir sendromdur. Hafıza fonksiyonunun bozulması demansın en kabul edilen tanımlarından biridir. Ayrıca bilişsel işlevdeki bozulmaya genelde sosyal davranışlarda, motivasyonda veya duygusal kontrolde bozulma da eşlik etmektedir.

Yaşlanmanın en ciddi risk faktörü olduğu demans hastalığı, sağlık ve sosyal bakım açısından 21.yüzyılın en büyük küresel zorluğu olarak görülmekte ve gün geçtikçe dünya çapında daha da yaygınlaşarak sebebiyet verdiği ölüm oranları artmaktadır.

Demans başlangıç belirtileri kademeli olarak ilerlediği için erken evre genellikle göz ardı edilmektedir. Nöropsikolojik tarama testleri kişinin bilişsel, davranışsal ve psikolojik işleyişinin incelenmesi için kullanılan özellikle hafif bilişsel bozukluk ve demansın erken evrelerindeki hastaları değerlendirebilmek açısından oldukça önemli tanı araçlarıdır.

Çalışmada, Open Access Series of Imaging Studies (OASIS) veri tabanından alınan OASIS-3 veri seti kullanılarak makine öğrenmesi yöntemleri ile Mini Mental Durum Muayenesi (MMSE) nöropsikolojik tarama testinin başarısını arttırmak ve demansın varlığına yönelik çıkarım amaçlanmıştır. Çalışma kapsamında 6179 hasta kaydıyla çalışılmış ve çalışmada kullanılacak öznitelikler belirlenmiştir. Veri setine uygulanan veri ön işleme yöntemleri sonrası k-en yakın komşuluk, destek vektör makineleri, karar ağaçları ve rastgele orman algoritmaları ile sınıflandırma yapılarak modellerin 10-katlamalı çapraz doğrulamadan elde edilen başarıları ölçülmüştür. Ayrıca sınıflandırma performansını arttırmak amacıyla 65 yaş ve 16 eğitim yılı eşik değeri olarak baz alınarak veri seti dört gruba bölünerek yeniden sınıflandırma yapılmıştır. Modellerin dört gruptaki başarı ölçümleri yapılmış ve ortalama performansları hesaplanmıştır.

Yapılan sınıflandırmaların ardından veri setinde yer alan özniteliklerin önem sıralamaları hesaplanmış, MMSE nöropsikolojik testi sınıflandırma için en önemli öznitelik olarak belirlenmiştir. MMSE test skorları, literatürde kabul edilen puanlama sistemi dahilinde veri setindeki teşhislerle karşılaştırılarak testin başarısı ölçülmüş ve modellerin başarılarıyla kıyaslanmıştır.

Çalışma sonucunda, MMSE nöropsikolojik testi için ölçülen doğruluk, duyarlılık, yanlış negatif oranı ve özgüllük değerleri, makine öğrenmesi yöntemleri ile elde edilen sonuçlarla kıyaslanmış, nöropsikolojik test başarısının arttırıldığı gözlemlenmiştir. K-en yakın komşuluk, destek vektör makineleri ve rastgele orman algoritmalarının tüm veri seti üzerinde birbirine yakın performanslar sergiledikleri, yaş ve eğitime göre bölünen veri seti üzerinde başarılarını daha da arttırarak çalışma için uygun yöntemler oldukları görülmüştür.



PREDICTION OF DEMENTIA BY MACHINE LEARNING METHODS

SUMMARY

Dementia is a syndrome that include a lot of different brain diseases, creating a deformation more than the effects of normal aging, in cognitive function. Deterioration of the function of the memory is one of the most acceptable definitions of dementia. Besides, deterioration in social behaviors, motivation or emotional control accompanies the impairment in cognitive function, generally.

While the aging is the most serious factor of dementia; gender, ethnicity, genetic factors and other individual diseases are also considered as risk factors. Dementia is considered as the hardest global problem of twenty first century in terms of health and social care and the death rates caused by dementia are increasing day by day.

The symptoms of dementia are handled in three stage as early stage, middle stage and late stage. The early stage is dismissed because the starting symptoms progress gradually in general.

The story of the progress of the disease is listened and neuropsychological screening tests are applied firstly at the clinical evaluation stage of dementia. In addition to these, laboratory tests, magnetic resonance imaging (MRI) for differential diagnosis and computed tomography are applied too. Neuropsychological screening tests are very significant diagnosis tools used to examine the cognitive, behavioral and psychological progress and to evaluate the patients in early stages of dementia and mild cognitive impairment but screening tests are not enough to definitive diagnosis, nevertheless.

Machine learning is to program the computer to optimize performance using past experiences or data available. Identification of the information from real world by computers and improvement of performance based on this new information for certain tasks are to be provided.

Nowadays, in the field of health, artificial intelligence supported systems have become widespread and play an active role in the diagnosis and treatment of many diseases. It is also used in applications such as medical data collection, drug discovery, robotic surgery.

In this study, OASIS-3 data set obtained from Open Access Series of Imaging Studies (OASIS) database was used. The data set consisted of 609 adult individuals considered to be cognitively normal and 6224 records containing doctor control reports at different time intervals of 489 persons diagnosed at various stages of dementia ranging in age from 42 to 99 years.

The aim of this study was to increase the success of neuropsychological tests in the data set by using machine learning methods and to determine the presence of dementia by means of the test.

In the scope of the study, data pre-processing methods were applied to the data and the success of the models was measured with 10-fold cross validation. Firstly, records containing missing diagnostic information were removed from the data set and the information obtained without the need for medical examination was determined as an attribute.

Data pre-processing methods were applied to the data within the scope of the study and the success of the models was measured with 10-fold cross validation. Firstly, records containing missing diagnostic information were removed from the data set and the information obtained without the need for medical examination was determined as an attribute. The missing data in 6179 records used in the study were completed according to the median or average for numerical attributes and mode value for categorical attributes. Then, the categorical attributes were converted to numeric attributes.

The normalization methods and parameters were determined for the models and the classification was made with k-nearest neighborhood, support vector machines, decision tree and random forest algorithms. Then, the accuracy, recall, false negative ratio and specificity values of the models were measured by the complexity matrix obtained from 10-fold cross-validation. In addition, the data set was divided into four groups based on the age of 65 and 16 years of education, and the success of the models in the population under/above 65 years of age was examined considering the educational status. Mini Mental State Examination (MMSE) neuropsychological screening test scores in the data set were compared with patient diagnoses within the scoring system accepted in the literature and the success of the test was measured and compared with the success of the models.

After the classifications, the importance of the attributes used in the study was made with random forest algorithm. Random forest algorithm is used to predict the importance of attributes as well as predictions. With the necessary calculations made on the trees that make up the random forest, the importance of the attribute is determined by looking at the increase in prediction error of the model. MMSE test, age and body mass index were determined as the three most important features for the study.

After the measurements, approximately 79% accuracy, 26% recall, 74% false negative rate and over 99% specificity values were obtained for MMSE test. In the first classification applied to the data set, all models were more successful than MMSE test for accuracy, sensitivity and false negative rate measurements. Support vector machines algorithm had an accuracy of over 85%, recall over 58%, specificity over 95% and false negative rate of approximately 42%. The k-closest neighbor algorithm had approximately 85% accuracy, recall above 60%, specificity above 94% and false negative rate of approximately 40%. Random forest algorithm had approximately 85% accuracy, approximately 58% recall, approximately 95% specificity and false negative rate of approximately 42%. These three methods have been more successful than the decision tree algorithm.

When the average success of the models on the data set divided by age and education were examined, the accuracy was reached to approximately 89% with k-nearest neighborhood, support vector machines and random forest, and the accuracy of decision trees was reached to 88%. The k-nearest neighborhood algorithm had recall over 60%, specificity over 96%, and false negative rate of about 40%. Support vector machines algorithm had recall over 59%, specificity over 96%, and false negative rate of approximately 41%. Random forest algorithm had recall over 58%, specificity over 96% and false negative rate of approximately 42%. These methods were again the most successful methods.

In this study, considering the accuracy, sensitivity and false negative rate, it was observed that all classifiers used increased the success of MMSE neuropsychological test. In particular, k-nearest neighbor, support vector machines and random forest algorithms have been the three most successful methods, performing close to each other. In the data set divided by age and education, the performance of the models increased further and k-nearest neighborhood, support vector machines and random forest algorithms became again the most successful methods. It has been found that these methods can be used to improve accuracy, sensitivity and false negative rate for more successful dementia prediction by MMSE neuropsychological test.



1. GİRİŞ

1.1 Demans

Demans, bir dizi ilerleyen nörolojik bozukluğu, daha genel bir ifade ile beyni etkileyen durumları tanımlayan bir terimdir. Beyin, nöronlardan yani mesaj yoluyla birbirleriyle irtibat kuran sinir hücrelerinden oluşur. Demans, beyindeki bu sinir hücrelerine hasar vererek beynin mesaj iletiminde aksamalara, sonuç olarak da vücudun çalışma mekanizmasında problemlere yol açar [1].

Demans, bilişsel işlevde normal yaşlanmanın sebep olduğu etkinin ötesinde bir bozulma yaratan, birçok farklı beyin hastalığı içeren bir sendromdur. Hafıza fonksiyonunun bozulması demansın en kabul edilen tanımlarından biridir. Ancak hafızanın kısmen korunduğu durumlar da görülür. Bu gibi vakalarda konuşma ve yürütme işlevlerindeki bozulmalar bilişsel bozulmanın yıkıcı etkileri olarak kabul edilir. Bilişsel işlevdeki bozulmaya genelde duygusal kontrol, sosyal davranış veya motivasyonda bozulma da eşlik etmektedir [2,3].

Demansın literatürde tanımlanan iki yüzden fazla alt tipi vardır. En bilinen demans türleri ise ‘Alzheimer hastalığı’, ‘Lewy cisimcikli demans’, ‘Vasküler demans’, ‘Frontotemporal demans’, ‘Parkinson hastalığı demansı’ ve demans türlerinin farklı kombinasyonlarla birarada görülebildiği ‘karışık demans’ olarak sayılabilir.

Hafif bilişsel bozulma (MCI) ise, normal yaşlanmanın sebep olduğu zihinsel değişiklikler ile demansın bilişsel semptomlarının arasında geçiş aşaması olarak tanımlanabilir. Bilişsel gerileme yaşayan her bireyde, ileri yaşlarda olsa da, Alzheimer hastalığı görülmeyebilir; hatta MCI tanısı konulsa bile demans gelişmeyebilir. Bu kişilerin genelde depresyon, anksiyete, ilaç kullanımı vb durumlardan dolayı bilişsel gerileme yaşadığı düşünülür [4].

DSM-V (Diagnostic and Statistical Manual for Mental Disorders- fifth edition)’e göre MCI tanı kriterleri:

- Kişinin kendisinden veya bilgi veren kişi tarafından bilişsel şikayetlerin olması,

- Nesnel bilişsel bozukluk,
- Bağımsız işlevsel yeteneklerde korunma ve kişide demans görülmemesidir.

1.1.1 Demansın belirtileri ve evreleri

Demansın semptomları üç aşamada ele alınabilir.

1.1.1.1 Erken evre

Demansta başlangıç belirtileri kademeli olarak ilerlediği için erken evre genellikle göz ardı edilmektedir. Bu evrede yaygın olarak görülen belirtiler unutkanlık, zamana ve mekana uyum sorunu, kişilikte değişimler ve gündelik görevleri yerine getirmede zorluklar yaşamak olarak sayılabilir.

1.1.1.2 Orta evre

Demans bu evreye ilerledikçe semptomlar daha şiddetli ve kısıtlayıcı hale gelir. Bu evrede yaygın olarak görülen belirtiler arasında yaşanan son olayları ve insanların isimlerini unutmak, iletişim konusunda karşılaşılan zorlukların artması, kişisel bakım konusunda yardıma ihtiyaç duymaya başlamak, hijyende zayıflama, evde kaybolmak ve davranışlarda değişimlerin başlaması sayılabilir.

1.1.1.3 Geç evre

Bu evrede dışa bağımlılık ve hareketsizlik oldukça ilerler. Hafızada ciddi bozulmalar ve fiziksel semptomlar daha belirgin hale gelir. Geç evrede yaygın olarak görülen belirtiler ise zaman ve mekandan habersiz olmak, akrabaları ve arkadaşları tanımak ile yürümekte zorlanmak, hareketlerde kontrol bozukluğu görülmesi, saldırganlığı arttırabilen davranış değişiklikleri yaşamak ve kişisel bakımda yardıma ihtiyaç duymaktır [2].

1.1.2 Demansın risk faktörleri

Bireyde demans gelişme ihtimalini etkileyen birçok faktör mevcuttur. Yaş, cinsiyet, etnik köken, genetik ve kişide görülen diğer hastalık ve tıbbi durumlar olarak ele alınan bu faktörler aşağıda detaylandırılmıştır.

1.1.2.1 Yaş

Yaş, demans için bilinen en ciddi risk faktörü olsa da yaşlanmanın kesin olarak demansa sebep olduğu söylenemez. Sadece yaşlılarda değil; 65 yaş altı bireylerde de, her 20 kişiden en az birinde olmak üzere, ‘genç başlangıçlı bunama’ olarak adlandırılan vakalar görülür. Demans aynı zamanda 65 yaş üzeri her 14 kişiden birinde ve 80 yaş üzeri her 6 kişiden birinde görülmektedir. 65 yaşın üzerindeki bir kişide Alzheimer hastalığı veya vasküler demans görülme riskinin ise her 5 yılda yaklaşık olarak iki katına çıktığı düşünülmektedir.

Yaşlanma ile ilişkili diğer faktörlerin de demans görülme olasılığını etkilediği düşünülmektedir. Bunlar yüksek tansiyon, bağışıklık sisteminde görülen değişimler, orta yaş sonrası hormonal değişimler, kalp-damar hastalıkları, sinir hücrelerinde görülen değişimler olarak sıralanabilir.

1.1.2.2 Cinsiyet

Alzheimer hastalığı dışındaki birçok demans türü için cinsiyet etkileyici bir faktör değildir. Fakat kadınlarda Alzheimer hastalığı görülme riski erkeklerden daha yüksektir. Bunun nedeni tam olarak bilinmemekle beraber özellikle menopoz sonrası dönemde östrojen hormonunun azalmasının etkili olabileceği düşünülmektedir. Ancak kontrol altında yapılan hormon tedavilerinin Alzheimer hastalığı riskini azalttığı saptanmamıştır. Vasküler demans ise erkeklerde, vasküler ve karma demansa sebep olabilen felç ve kalp hastalıkları riskinin daha fazla olmasına bağlı olarak, kadınlara kıyasla daha yüksek oranda görülür.

1.1.2.3 Etnik köken

Demans ve özelleştirmek gerekirse vasküler demans, Güney Asya halkında beyaz Avrupalılara oranla daha sık görülmektedir. Güney Asyalılarda da demans riskini arttıran inme, kalp hastalıkları ve diyabet gibi hastalıkların görülme tehlikesi yüksek olduğundan demans da yüksek oranda görülür. Aynı şekilde Afrika veya Afrika-Karayip kökenli olan bireylerde de diyabet ve felç riski demans görülme oranını etkilemektedir.

1.1.2.4 Genetik

Demans oluşumunda gen faktörünün etkisi tam olarak bilinmemektedir. Ancak son yıllarda genlerin demansı nasıl etkilediğinin anlaşılmasında kayda değer gelişmeler görülmüştür. Buna apolipoprotein E (APOE) geni örnek olarak verilebilir. Bu genin varyantlarının genetik olarak aileden aktarılması Alzheimer hastalığı riskini artırır. APOE gibi genlerden daha nadir görülmesine rağmen doğrudan demansa sebep olan genlerin aktarılma riski de vardır. Bu duruma genetik frontotemporal demansı ve ailevi Alzheimer hastalığı (nadir görülen ve genelde 60 yaş öncesi belirti veren Alzheimer hastalığı türü) olan ailelerde rastlanmaktadır. Bir insan hatalı genlerden birini taşıyorsa bu gen % 50 ihtimalle çocuklarına aktarılır ve çocuklarda demansa rastlanır.

1.1.2.5 Diğer tıbbi durum ve hastalıklar

Demans ve kardiyovasküler hastalıklar için risk faktörleri olarak orta yaşlarda görülen yüksek tansiyon, tip 2 diyabet, kolesterol ve obezite sayılabilir. Bir kişide kardiyovasküler hastalık ve tip 2 diyabet görülmesi demans riskini iki kat arttırmaktadır. Bunun nedeni vasküler demansın kardiyovasküler hastalıklar ile ilişkili olmasıdır. Ancak yapılan son çalışmalara göre kardiyovasküler hastalıklar yalnızca vasküler demansa değil, karışık demansa da sebep olmaktadır. Hatta bazı durumlarda diyabet ve yüksek kolesterol ile beraber Alzheimer hastalığı riskini arttırdığı da bilinmektedir.

Depresyon ise eğer orta yaşta görülüyorsa ilerleyen yaşlarda demans riskine yol açabilir. Fakat 60 yaş üzerinde görülen depresyon risk faktörü değil, erken evre demans belirtisi olabilmektedir.

Parkinson hastalığı, HIV, multipl skleroz, down sendromu ve bunun gibi öğrenme zorluğuna sebep olan diğer hastalıklar da demans riskini arttırmaktadır.

Tüm bu risk faktörlerine ek olarak yaşam tarzı da kişide demans görülme riskini etkiler. Bunun için en önemli örnek fiziksel aktivite eksikliğidir. Hareket eksikliği kalp hastalıkları, felç, tip 2 diyabet gibi hastalıklarla ve aynı zamanda beyin fonksiyonları üzerindeki olumsuz etkilerle ilişkilendirilebilir.

Sigara içmek de beyin kan damarları, akciğer, kalp ve damarlar için oldukça olumsuz etkilere sahiptir. Tip 2 diyabet, kalp hastalıkları ve Alzheimer hastalığı sigaranın olumsuz etkilerinin sebep olduğu başlıca hastalıklardandır.

Sağlıksız beslenme alışkanlığı ise kolesterolü yükseltir, damarların daralmasına ve kilo alımına sebep olur. Demans, kardiyovasküler ve tip 2 diyabet gibi hastalıklara zemin hazırlar. Bunun yanında aşırı dozda alkol tüketimi de Alzheimer hastalığı ve vasküler demans gelişme riskini artırır. Ayrıca geçirilen kafa travmasının da başta Alzheimer hastalığı olmak üzere demansa yakalanma riski oluşturduğu söylenebilir [5].

1.1.3 Demansın görülme sıklığı

Demans, sağlık ve sosyal bakım açısından 21.yüzyılın en büyük küresel zorluğudur. Gün geçtikçe dünya çapında daha da yaygınlaşmakta ve dolayısıyla sebebiyet verdiği ölüm oranları da artmaktadır. 2015 yılında dünya çapında yaklaşık 47 milyon olan demans tanılı hastanın 2030'da 66 milyona, 2050'de ise 115 milyona ulaşması öngörülmektedir [6].

1.1.4 Demansın teşhis edilmesinde nöropsikolojik testler ve ölçekler

Demansın klinik değerlendirme aşamasında öncelikle hastalığın gelişim öyküsü dinlenir ve nöropsikolojik testler uygulanır. Bunlara ek olarak laboratuvar testlerine ve ayırıcı tanı için manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi gibi yöntemlere de başvurulur [7].

Nöropsikolojik testler kişinin bilişsel, davranışsal, psikolojik işleyişinin incelenmesi için kullanılan özellikle hafif bilişsel bozukluk ve demansın erken evrelerindeki hastaları değerlendirebilmek açısından oldukça önemli tanı araçlarıdır. Bu araçlar sayesinde beyindeki fonksiyon bozukluklarına bağlı ortaya çıkan zihinsel bozulmalar objektif olarak değerlendirilip puanlanır.

Mini Mental Durum Muayenesi (MMSE), Blessed Oryantasyon Bellek Konsantrasyon Testi (BOMC), Kısa Mental Durum Testi, Yenilenmiş-Addenbrook Kognitif Muayenesi ve Montreal Kognitif Değerlendirme Testi dünyada ve ülkemizde yaygın olarak kullanılan testlerden bazılarıdır [8].

1.1.4.1 Mini mental durum muayenesi

İyi bir şekilde kurgulanmış, tanınırlığı yüksek bir bilişsel tarama testi olan MMSE, 1975 yılında Folstein ve arkadaşları tarafından geliştirilmiştir. Oryantasyon, kayıt hafızası, dikkat ve hesap yapma, hatırlama ve lisan kategorilerden oluşan test 11

sorudan oluşmakta ve toplam 30 puan üzerinden değerlendirilmektedir. Puan aralıkları ve değerlendirme sonuçları Çizelge 1.1’de gösterilmiştir [9].

Çizelge 1.1 : MMSE skorları ve değerlendirme sonucu.

Puan	Değerlendirme Sonucu
24-30	Normal
18-23	Hafif demans
17 ve altı	Ciddi demans

Hastalık öyküsü ile beraber sorgulamaların sayısal olarak ifade edilebilmesi için kullanılan ölçekler de mevcuttur. Klinik Demans Değerlendirme Ölçeği (CDR), Global Detoriasyon Skalası (GDS), Hachinski İskemik Skorlaması, Geriatrik Depresyon Skalası, Hamilton Depresyon Ölçeği ve Fonksiyonel Aktiviteler Ölçeği (FAQ) bu ölçeklerden bazılarıdır.

Yaygın olarak kullanılan CDR’de, hasta ve hasta yakınıyla yapılan görüşmeler ve muayene sonucunda bellek, oryantasyon, yargılama-problem çözme, ev yaşamı – hobiler, ev dışı işlevsellik ve kişisel bakım değerlendirilir. Bu altı bilişsel ve işlevsel eksen 0, 0.5, 1, 2, 3 değerleri arasında puanlandırılır. 0 normal yaşlanma, 0.5 kuşku / çok hafif demans, 1 hafif demans, 2 orta demans, 3 ise ağır demans anlamına gelir.

CDR ile ilişkilendirilen bir diğer terim kutu toplamı skoru (CDR–SOB) ise değerlendirilen bu altı eksenin puan toplamı ile ifade edilir [10].

1.2 Makine Öğrenmesi

‘Makine öğrenmesi’ terimi ilk kez 1959’da Arthur Samuel tarafından kullanılmış fakat yapay zekadan ayrı bir alan olarak esas gelişimi 1990’lı yıllara denk gelmiştir.

Makine öğrenmesi, geçmişte edinilen deneyimleri ya da eldeki verileri kullanarak performansı en iyi hale getirmek için bilgisayar programlamaktır [11]. Bilgisayarların gerçek dünyadan bilgileri tanımlaması ve bu yeni bilgilere dayanarak bazı görevler için performansını arttırması sağlanır. Makine öğrenmesinde insanın öğrenme yeteneğinin benzerine ulaşmak için bilgisayarlar kullanılır. Bilgisayarlar insanlar gibi muhakeme yeteneği aracılığı ile değil algoritmalar ile öğrenirler [12]. Makine öğrenmesinde kullanılan algoritmalar kullanıldıkları öğrenme süreci yaklaşımlarına

göre dört ana sınıfa ayrılırlar. Bunlar denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenmedir [11].

Denetimli öğrenme bilinen bir çıktı veya hedefi öngörme amacı ile başlar; yeni bir veri örneğini ve tahmini en iyi şekilde tanımlamak için alt gruplar arasında seçim yapmayı ve bilinmeyen bir parametreyi tahmin etmeyi içeren sınıflandırma üzerine odaklanır [13]. Denetimli öğrenmede her örnek, bir giriş nesnesi ve istenen bir çıkış değerinden oluşur. Bu sınıflandırma yönteminde algoritma eğitim verilerinden öğrenir ve öğrendiği bilgiyi yeni örnekler üzerine uygular.

Denetimsiz öğrenmede ise algoritmalar için bir eğitim seti yoktur. Algoritmaların kullanılan gerçek verilerden kendilerinin öğrenmesi sağlanır. Denetimsiz öğrenmede algoritmalar daha çok verilerdeki gizli örüntüleri bulmaya odaklanır. Bu öğrenme türüne örnek olarak sosyal medya kullanıcılarının profillerine erişebilen algoritmaların, reklam stratejisi gereği doğru hedeflere ulaşabilmek için kişileri sınıflandırmasını verilebilir.

Yarı denetimli öğrenmede denetimli öğrenmeden farklı olarak algoritma eksik veri içeren bir eğitim seti ile çalışır ve algoritmanın bu setten öğrenmesi beklenir. Örneğin film derecelendirmesi yapan kullanıcıların olduğu bir grupta değerlendirme yapmayan kişiler olsa da, yani eksik veri bulunması durumunda, yarı denetimli öğrenme algoritması çalışır ve bu verilerden öğrenerek sonuç çıkarabilir [12].

Yarı denetimli öğrenme bizlere birkaç avantaj da sağlar. Denetimli öğrenmedeki etiketli eğitim verisi için gereken etiketleme işlemi zaman alıcı ve bazı durumlarda pahalı olabilmektedir. Yarı denetimli öğrenmede ise etiketlenmemiş çok sayıda veriyi eğitim sürecine dahil edebiliyor olmak modelin doğruluğunu artırıp zaman ve maliyette azalma sağlar.

Takviyeli öğrenmede algoritmalar ortamı algılayarak hedefe yönelik belirli bir boyutta en iyi şekilde kararlar almayı öğrenebilir. Bu sınıflandırmada her girdi için üretilmesi gerekli olan çıktı sisteme gösterilmez; sistemin girdilere karşılık gelen çıktılarını üretmesi beklenir. Bu çıktının doğru ya da yanlış olması durumuna göre bir sinyal üretilir. Bu sinyale göre öğrenme süreci devam eder [14]. Takviyeli öğrenmenin doğası gereği algoritmalar yanlış kararda cezalandırılıp doğru kararda ödüllendirilirler. Takviyeli öğrenmeye örnek olarak oyun programlama gösterilebilir. Oyun sırasında

bir hareket tek başına önemli değildir; önemli olan doğru hamleleri bir araya getirebilmektir.

Makine öğrenmesinde tahmin için üretilen çıktılar türlerine göre ayrılabilir. Hedef kategorik bir çıktıysa buna ‘sınıflandırma’, nümerik bir değerse ‘regresyon’ denir. Regresyonda amaç ayırık değil sürekli çıktılar üretmektir. Sınıflandırma ve regresyon denetimli öğrenme yaklaşımlarıdır. ‘Kümeleme’ ise denetimsiz öğrenme yaklaşımı olup, veri kümesini küme gruplarına ayırır. Kümeleme yönteminde etiketlenmemiş veriler ile çalışılır ve amaç benzer gözlemleri aynı kümelere bölmektir [11].

1.3 Literatür Araştırması

Literatürde demansın makine öğrenmesi yöntemleri kullanılarak saptanması ile ilgili birçok çalışma mevcuttur [15-25]. Bu çalışmalar incelendiğinde demans tahmini için görüntüleme yöntemleri ile elde edilen verilerin kullanıldığı çalışmalar [15-20] ve nöropsikolojik testlerin kullanıldığı çalışmalar [21-24] olduğu saptanmıştır. Bu çalışmalar şu şekildedir:

Cuignet ve arkadaşları ADNI veri tabanından alınan MRI verileri ile Alzheimer hastalığı ve hafif bilişsel bozukluk görülen hastalar için kontrol gruplarıyla destek vektör makineleri algoritmasını kullanarak sınıflandırmalar yapmış ve Alzheimer hastaları ile kontrol grubu arasında yapılan sınıflandırmada yüksek doğruluk ve %81 duyarlılık ile %95 özgüllüğe ulaşmışlardır [15].

Bansal ve arkadaşları demans hastalığı teşhisi için kullandıkları OASIS veri setinin MRI verilerine dört farklı makine öğrenmesi yöntemi uygulamış ve J48 algoritmasının en iyi sonucu verdiğini bildirmişlerdir [16].

Demirhan, OASIS veri setinin MRI taramalarını kullanarak Alzheimer ve hafif Alzheimer sınıflandırması yaptığı çalışmasında destek vektör makineleri, en yakın komşuluk ve geri yayımlı sinir ağıları algoritmalarının performanslarını ölçmüş, %82 üzeri başarıyla destek vektör makinelerinin en iyi sınıflandırıcı olduğunu belirtmiştir [17].

Aruna ve Chitra çalışmalarında demans tanısı için OASIS veri seti MRI sonuçlarını sınıflandırmayı amaçlamışlardır. Çeşitli görüntüleme ve bileşen analiz yöntemleri de kullanılarak destek vektör makineleri algoritması ile sınıflandırma yapılmış, özellik füzyon sınıflandırıcısı ile %90 başarıya ulaşılmıştır [18].

Miller ve arkadaşları, OASIS veri seti MRI taramalarında demans saptamak için görüntüleme yöntemleri ve temel bileşen analizi uygulayarak destek vektör makineleri ve Naïve Bayes algoritmalarını kullanmış, Naïve Bayes için %87 üzeri doğrulukla sınıflandırma başarısı elde etmişlerdir [19].

Chen ve Herskovits çalışmalarında Washington Üniversitesi Alzheimer Hastalığı Araştırma Merkezi'nden alınan MRI verilerine dayalı hafif demans tanısı için Naïve Bayes, Karar Ağacı, Destek Vektör Makineleri , Çok Katmanlı Algılayıcı (MLP) ve ters ağaç yapılı-Bayes Ağ Sınıflandırıcısı (BNCIT) algoritmalarını kullanmış ve bu yaklaşımları istatistiksel yöntemler olan Lojistik Regresyon ve Diskriminant Analizi ile karşılaştırmışlardır. Çalışma sonucunda BNCIT ve DVM'nin daha yüksek öngörü gücüne sahip oldukları saptanmıştır [20].

Shankle ve arkadaşları demans taramasını iyileştirmek amacıyla Kaliforniya Üniversitesi Alzheimer Hastalığı Araştırma Merkezi'nden alınan FAQ ve BOMC basit bilişsel ve fonksiyonel beceri testlerinden elde edilen sonuçları test etmişlerdir. 609 kişiden oluşan veri setine C4.5 kuralları, C4.5, Naive Bayes, IB1 algoritmaları uygulanmıştır [21].

Shankle ve arkadaşları Kaliforniya Üniversitesi Alzheimer Hastalığı Araştırma Merkezi'nden alınan 198 sağlıklı ve 244 bilişsel bozulma/hafif demans görülen bireyden elde edilen veriler ile demansı erken aşamada tespit etmeyi amaçlamışlardır. Yaş, eğitim, cinsiyet bilgilerinin yanında FAQ, MMSEPLUS ve Ishihara Color Plates (ICP) test sonuçlarına Naïve Bayes, CART, C4.5, C45Rules ve FOCL algoritmaları uygulanmış ve testler birbirleri ile karşılaştırılmıştır [22].

Wang ve arkadaşları NACC aracılığıyla elde ettikleri veri seti ile Alzheimer hastalığının doktor kontrolleri arasındaki ilerleme aşamalarını öngörmeyi amaçlamışlardır. Veriler hastaların demografik, sağlık öyküsü, fiziksel bilgiler, CDR ölçeklendirmesi, GDS ve FAQ skorlarını içermektedir. 5432 Alzheimer hastası ile yapılan çalışmada tekrarlayan sinir ağları algoritması kullanılmış, % 99 ' un üzerinde doğrulukla sonraki doktor ziyaretleri tahmin edilebilmiştir [23].

Maroco ve arkadaşları çalışmalarında Santa Maria Hastanesi, Memoclinica ve Coimbra Üniversite Hastanesi'nden aldıkları 921 sağlıklı ve demans hastası bireyin kayıtlarını kullanmışlardır. Çalışmada demansın tahmini için on farklı nöropsikolojik

test kullanılmış, rastgele orman algoritması ve doğrusal ayırmacılık analizinin yüksek doğruluk, özgüllük ve hassasiyet gösterdiği kanıtlanmıştır [24].

So ve arkadaşları çalışmalarında MMSE-K ve CERAD-K test sonuçları ile yaş, cinsiyet ve eğitim bilgilerinin yer aldığı Gangbuk-Gu demans merkezinden alınan veri setini kullanmışlardır. Çalışmada demans teşhisi olan bireyler ile sağlıklı bireyleri ayırmak ve hafif bilişsel bozukluk görülen bireyler ile demans hastası bireyleri ayırmak için iki ayrı sınıflandırma uygulanmıştır [25].

1.4 Tezin Amacı

Bu çalışma kapsamında Open Access Series of Imaging Studies (OASIS) veri tabanından alınan OASIS-3 veri seti kullanılmıştır. Bireylerin cinsiyet, yaş, vücut kitle indeksi, eğitim seviyesi, kullandıkları el, etnik köken bilgileri ve MMSE test sonucundan oluşan verilerle demans hastalığının tespitine dayalı bir sınıflandırma yapılmış olup; yöntem olarak k-en yakın komşuluk, destek vektör makineleri, karar ağaçları ve rastgele orman algoritmaları kullanılmıştır. Görüntüleme yöntemlerine başvurmadan, uygulanan nöropsikolojik testin demans taramasındaki başarısını ölçmek ve arttırmak amacıyla çalışmalar gerçekleştirilmiştir. Başarı ölçeğini daha da arttırmak için, yaş ve eğitim kriterleri göz önüne alınarak veri setinde bölünme yapılmış olup, yöntemlerin sınıflandırma performansları ölçülerek nöropsikolojik testin başarı değişimi incelenmiştir.

2. YÖNTEM

2.1 Veri Ön İşleme Yöntemleri

Veri ön işleme yöntemleri veri setini eksik, gürültülü ve tutarsız verilerden temizleyerek kurulan model için uygun hale getirip daha kaliteli ve yüksek başarımlı sonuçlara ulaşmak amacıyla uygulanır [26]. Veri ön işlemedeki başlıca görevler veri temizleme, veri birleştirme, veri indirgeme ve veri dönüştürme olarak sıralanabilir.

2.1.1 Veri temizleme

Veri setindeki eksik verileri tamamlama, gürültülü ve tutarsız verileri düzeltme veri temizleme aşamasında ele alınır. Eksik verileri tamamlamak için kullanılan yöntemlerden bazıları aşağıda verilmiştir:

- Sınıf etiketi eksik olan kayıtlar veri setinden silinir.
- Sayısal değişkenler için medyan ya da ortalama, kategorik değişkenler için ise mod değerine göre tamamlanır.
- Aynı sınıfa ait değişkenler ortalama, medyan ya da mod değerine göre tamamlanır.
- Eksik değerler öğrenme algoritmalarıyla (regresyon, karar ağacı gibi) tahmin edilerek tamamlanır.

2.1.2 Veri dönüştürme

Bu aşamada veriler model için uygun formlara dönüştürülür. Veri dönüşümü; düzeltme, birleştirme, normalleştirme, genelleme, ayrıştırma ve özellik oluşturma gibi işlemler ile yapılır. Normalleştirme; verilerin daha küçük aralıkta ölçeklendirilmesi işlemidir [27]. Normalleştirme yöntemleri aşağıda verilmiştir:

Min Max Ölçeklendirme (ing: Min Max Scaler): Verileri tüm öznitelikler 0 ile 1 arasında olacak şekilde ölçeklendirir (Denklem 2.1).

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.1)$$

Standart Ölçeklendirme (ing: Standard Scaler): Her öznitelik için ortalama değerin 0, varyansın ise 1 olmasını sağlar. Tüm öznitelikler aynı büyüklüğe dönüştürülür (Denklem 2.2).

$$x' = \frac{x - \mu}{\sigma} \quad (2.2)$$

Gürbüz Ölçeklendirme (ing: Robust Scaler): Her özniteliğin aynı ölçekte olmasını sağlar. Ortalama ve varyans yerine medyan ve kartilleri kullanarak çalışır. Bu durum ise diğerlerinden farklı olan veri noktaları için ölçüm hatalarına sebep olabilir (Denklem 2.3).

$$x' = \frac{x - Q_1(x)}{Q_3(x) - Q_1(x)} \quad (2.3)$$

2.2 Algoritmalar

2.2.1 K-en yakın komşuluk

Denetimli öğrenme algoritmalarından olan k-en yakın komşuluk (KNN) algoritmasında model, eğitim verilerinden öğrenir. Yeni bir verinin tahminini gerçekleştirmek için tahmin edilecek veriye eğitim setindeki en yakın noktalar, yani en yakın komşular bulunur. Sonuç olarak bilinmeyen girdinin sınıfı, komşularının çoğunlukta olduğu sınıf olarak hesaplanmaktadır. En basit haliyle ele alındığında bu komşu tahmin edilecek veriye en yakın olan tek komşu olarak kabul edilir [28,29]. KNN oldukça tercih edilen basit bir algoritmadır. Ancak sınıflandırma sırasında mesafe hesabı yapılması sebebiyle bu algoritma eğitim setinin büyük olduğu veriler için yavaş çalışan bir sınıflandırıcıdır [30].

Örnekler arasındaki mesafeyi hesaplamak için farklı hesaplama yöntemleri kullanılmaktadır. Öklid uzaklığı, Manhattan uzaklığı, Chebyshev uzaklığı, Minkowski uzaklığı yararlanılan hesaplama yöntemlerindendir. Farklı uzaklık ölçümleri ile farklı sonuçlar ortaya çıkarken, farklı veriler için de farklı uzaklık ölçümleri gerekir [31].

Öklid Uzaklığı: Düzlemdeki iki nokta arasındaki mesafeyi ölçer. En yakın komşuluk algoritması için en sık tercih edilen yöntemdir.

$$Dist_{xy} = \sqrt{\sum_{k=1}^m (x_{ik} - y_{jk})^2} \quad (2.4)$$

Manhattan Uzaklığı: N boyutta iki noktanın mutlak farklarının toplamıdır.

$$Dist_{xy} = \sum_{i=1}^n |x_i - y_i| \quad (2.5)$$

Minkowski Uzaklığı: p = 1 durumu için Manhattan uzaklığına eşittir ve p = 2 için Öklid uzaklığına eşittir.

$$Dist_{xy} = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (2.6)$$

Chebyshev Uzaklığı: İki noktanın mutlak farklarının en büyük değeridir.

$$Dist_{xy} = \max_{i=1}^n |x_i - y_i| \quad (2.7)$$

2.2.2 Destek vektör makineleri

Destek vektör makineleri (DVM), sınıflandırma ve regresyon için kullanılan, yüksek boyutlu problemlerde de kullanılabilen güçlü ve esnek bir algoritmadır [32]. DVM, Vapnik tarafından geliştirilen istatistiksel öğrenme teorisinden ilham alan bir denetimli öğrenme algoritmasıdır. İstatistiksel öğrenme teorisi 1960'ların sonlarına doğru ortaya çıkmış, 1990'ların ortalarında ise bu teoriye dayanarak öğrenme algoritmaları geliştirilmiştir. Bu geliştirilen algoritma 'destek vektör makineleri' olarak adlandırılmıştır. Bu sayede istatistiksel öğrenme teorisi sadece teori olarak kalmamış, çok boyutlu fonksiyonları da tahmin edebilen algoritmalara alt yapı oluşturmuştur [33].

DVM ile veriler iki sınıfa ayrılır; asıl amaç ise bu sınıfları birbirinden ayıran optimum

ayırıcı düzlemi bulmaktır. Sınıfları birbirinden ayırabilecek bir çok doğrusal sınıflandırıcı vardır. Fakat sınıfların en yakın noktalarının arasındaki mesafeyi maksimum yapan tek bir doğrusal sınıflandırıcı vardır. Buna ‘optimum ayırma hiper düzlemi’ denir [34]. Bu düzleme en yakın olan farklı sınıf noktalarına ise ‘destek vektörleri’ denir.

Destek vektör makineleri veri setinin doğrusal olarak ayrılabilme durumuna göre incelenebilir.

2.2.2.1 Doğrusal destek vektör makineleri

Ayrılabilme durumu

Eğitim setinin $\{x_i, y_i\}$, $i = 1, \dots, l$, $y_i \in \{-1, 1\}$, $x_i \in R^d$ olduğu varsayalım. Pozitif ve negatif verileri birbirinden ayıran bir hiper düzlem olduğu düşünüldüğünde, hiper düzlemde yer alan x noktaları $w \cdot x + b = 0$ denklemini sağlar. Burada w hiper düzlemin normali, $|b| / \|w\|$ hiper düzlemden orijine olan dik mesafe, $\|w\|$ ise w ’nin öklid normudur. d_+ pozitif örneğin hiper düzleme en kısa mesafesi, d_- ise negatif örneğin hiper düzleme olan en kısa mesafesi olsun.

Hiper düzlemin “marjin” i $d_+ + d_-$ ile hesaplanır. Doğrusal olarak ayrılan veri setleri için DVM marjinin en büyük olduğu hiper düzlemi bulmaya çalışır.

$$\begin{aligned} x_i \cdot w + b &\geq 1 ; \quad y_i = 1 \\ x_i \cdot w + b &\leq -1 ; \quad y_i = -1 \end{aligned} \quad (2.8)$$

Eğitim verilerinin denklem 2.8’da verilen kısıtlamaları sağladığı düşünüldüğünde bu kısıtlamalar denklem 2.9’da görülen tek eşitsizlikte birleştirilebilir.

$$y_i(x_i \cdot w + b) - 1 \geq 0 ; \quad \forall i \quad (2.9)$$

Optimal hiper düzlem denklem 2.9’u sağlayarak $\Phi(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} (w, w)$ denklemini minimize etmelidir. Bunun için ‘Lagrange formülasyonu’na başvurulur.

$L_\rho \equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^l a_i y_i (x_i \cdot w + b) + \sum_{i=1}^l a_i$ denkleminin karmaşıklığından dolayı çözümü için ‘Karush-Kuhn-Tucker’ (KKT) koşullarına başvurulur w ve b ’ye göre kısmi türevler alınır.

$$\frac{\partial L_p}{\partial w} = w - \sum_i a_i x_i y_i = 0 \rightarrow w = \sum_i a_i x_i y_i \quad (2.10)$$


$$\frac{\partial L_p}{\partial b} = 0 \rightarrow - \sum_i a_i y_i = 0 \quad (2.11)$$

Denklem 2.10 ve 2.11'deki koşullar sonrası denklem 2.12'de verilen yeni eşitlik elde edilir.

$$L_D = \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i \cdot x_j \quad (2.12)$$

Denklem 2.12 çözüldüğünde $a_i > 0$ olan noktalara 'destek vektörleri' denir ve hiper düzlemlerden birinin üzerinde bulunur.

DVM'nin doğrusal olarak ayrılabilme durumu Şekil 2.1'de gösterilmiştir.



Şekil 2.1 : Doğrusal ayrılabilen DVM.

Tam ayrılamama durumu

Doğrusal olarak ayrılabilen verilerde kullanılan algoritma, ayrılamayan veriler için uygun bir çözüm bulamaz. Bunun için algoritma üzerinde değişiklikler yapılması gerekir. Kısıtlamaları rahatlatmak amacıyla pozitif gevşek değişkenler (ξ_i , $i = 1, \dots, l$) dahil edilerek denklem 2.13'te verilen yeni kısıtlamalar elde edilir.

$$\begin{aligned}
x_i \cdot w + b &\geq 1 - \xi_i \quad ; \quad y_i = 1 \\
x_i \cdot w + b &\leq -1 + \xi_i \quad ; \quad y_i = -1 \\
\xi_i &\geq 0 \quad ; \quad \forall i
\end{aligned} \tag{2.13}$$

Verilerin ayrılamama durumunda $0 < \xi_i < 1$; yanlış sınıflandırma olması durumunda ise $\xi_i \geq 1$ olur. Tam ayrılamama durumu için C ; ceza parametresi tanımlanır. Bu parametre Lagrange çarpanının alabileceği maksimum değeri belirtir. Bu durumda Lagrange denklemi aşağıdaki halini alır:

$$Lp = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i a_i \{y_i(x_i \cdot w + b) - 1 + \xi_i\} - \sum_i \mu_i \xi_i \tag{2.14}$$

μ_i parametresi ξ_i parametresinin pozitif olmasını sağlayan yeni Lagrange parametresidir. Bu denklemin çözülebilmesi için yine değişkenlerin kısmi türevleri alınarak KKT koşullarına başvurulur.

i 'nin 1'den eğitim verisi büyüklüğüne kadar, v 'nin ise 1'den tüm veri boyutuna kadar olduğu düşünüldüğünde;

$$\frac{\partial Lp}{\partial w_v} = w_v - \sum_i a_i y_i x_{iv} = 0 \tag{2.15}$$

$$\frac{\partial Lp}{\partial b} = - \sum_i a_i y_i = 0 \tag{2.16}$$

$$\frac{\partial Lp}{\partial \xi_i} = C - a_i - \mu_i = 0 \tag{2.17}$$

$$y_i(x_i w + b) - 1 + \xi_i \geq 0 \tag{2.18}$$


$$\xi_i \geq 0; \quad a_i \geq 0; \quad \mu_i \geq 0 \tag{2.19}$$

$$a_i \{y_i(x_i \cdot w + b) - 1 + \xi_i\} = 0 \tag{2.20}$$

$$\mu_i \xi_i = 0 \tag{2.21}$$

Hesaplamaları yapıldığında b eşik değerini belirlemek için $0 < a_i < C$ aralığında olan herhangi bir eğitim noktasını baz alarak denklem 2.20, $\xi_i = 0$ koşulu ile kullanılır [33,35].


DVM'nin doğrusal olarak tam ayrılamama durumu Şekil 2.2'de gösterilmiştir.



Şekil 2.2 : Tam ayrılamayan DVM.

2.2.2.2 Doğrusal olmayan destek vektör makineleri

Eğer veri seti tam olarak ya da belirli bir hata oranıyla da olsa doğrusal olarak ayrılamıyorsa temel fonksiyonlar yardımıyla dönüşümler yapılarak veri seti daha yüksek boyutlu bir uzaya taşınabilir. Gerçek dünya verileri genellikle doğrusal olarak ayrılamazlar ve bu durumda veriyi yeni uzaya taşıyarak burada doğrusal bir modele karşılık gelmesi sağlanır [36]. Bunun için $\Phi: x \rightarrow \varphi(x)$ dönüşümleri yapılarak her veri yüksek boyutlu bir alana eşlenir (Şekil 2.3).



Şekil 2.3 : Doğrusal Olmayan DVM.

Bu eşleme ile oluşan iç çarpım denklem 2.22’de görülmektedir.

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (2.22)$$

K fonksiyonuna ‘kernel (çekirdek) fonksiyonu’ adı verilir. Bir çekirdek işlevi, örnekler arasındaki iç ürüne eşdeğer olan benzerlik ölçüsü türüdür.

İki boyutlu olarak ele alındığında $x = [x_1, x_2]$ ve $K(x_i, x_j) = (1 + x_i^T x_j)^2$ için,

denklem 2.22’teki eşitlik sağlanmalıdır. Bu durum aşağıda incelenmiş ve denklem 2.23 ile gösterilmiştir:

$$\begin{aligned} K(x_i, x_j) &= (1 + x_i^T x_j)^2 = 1 + x_{i1}^2 x_{j1}^2 + 2x_{i1} x_{j1} x_{i2} x_{j2} + x_{i2}^2 x_{j2}^2 + 2x_{i1} x_{j1} + 2x_{i2} x_{j2} \\ &= [1, x_{i1}^2, \sqrt{2}x_{i1}x_{i2}, x_{i2}^2, \sqrt{2}x_{i1}, \sqrt{2}x_{i2}]^T [1, x_{j1}^2, \sqrt{2}x_{j1}x_{j2}, x_{j2}^2, \sqrt{2}x_{j1}, \sqrt{2}x_{j2}] \\ &= \varphi(x_i)^T \varphi(x_j) \end{aligned} \quad (2.23)$$

Bu durumda iç çarpan fonksiyonu denklem 2.24 ile ifade edilir.

$$\varphi(x) = [1, x_1^2, \sqrt{2}x_1x_2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2] \quad (2.24)$$

Aşağıda en çok tercih edilen kernel fonksiyonlarından bazıları tanımlanmıştır:

- **Lineer Kernel**

$$K(x_i, x_j) = x_i^T x_j \quad (2.25)$$

- **Polinom Kernel**

$$K(x_i, x_j) = (1 + x_i^T x_j)^p \quad (2.26)$$

- **Gaussian Kernel (Radyal Tabanlı Kernel)**

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} = e^{-(\gamma \|x_i - x_j\|^2)} ; \quad \gamma > 0 \quad (2.27)$$


- **Sigmoid Kernel**

$$K(x_i, x_j) = \tanh(ax_i^T x_j + c) \quad (2.28)$$

2.2.3 Karar ağaçları

Denetimli öğrenme yöntemlerinden biri olan karar ağaçları algoritması, sınıflandırma ve regresyon için kullanılan bir öngörü modelidir. Karar ağaçları böl ve fethet stratejisi uygulayan, parametrik olmayan hiyerarşik veri yapılarıdır. Bu algorithmada amaç, veriden basit karar kurallarını öğrenerek yeni değişkenin değerini tahmin edebilmektir. Karar ağaçları kategorik ve sayısal verileri çeşitli özelliklere dayanarak sınıflandırabilen bir yöntemi temsil eder. Büyük boyuttaki verileri işleyebildiği, öncesinde fazla veri hazırlığı gerektirmediği ve anlaşılması kolay olduğu için oldukça tercih edilen bir algoritmadır. Bunun yanı sıra çeşitli veri türleri için uygundur ve gereken hesaplama uğraşına göre yüksek öngörücü performans sağlar.

Karar ağacı, örnek uzayın özyinelemeli bir bölümü olarak ifade edilebilir. Bir karar ağacının yapısı incelendiğinde düğüm, dal ve yapraklardan oluştuğu görülür. Düğümler öznitelikleri temsil eder. Girdisi olmayan düğümlere 'kök düğüm' denir. Diğer bütün düğümlerin girdisi vardır. Çıktısı olan düğümlere ise 'iç düğüm' veya 'test düğümü' denir. Geriye kalanlar yani, çıktıları başka düğümlerin girdisi olmayan düğümler 'yaprak düğümler' (terminal düğüm) olarak adlandırılır. Bu yapılar Şekil 2.1' te gösterilmiştir.



Şekil 2.4 : Derinliği üç olan bir karar ağacı yapısı.

Örnek uzay her iç düğüm tarafından girdi nitelik değerlerinin tanımlanmış bir fonksiyonu ile iki veya daha fazla alt uzaya bölünür. En basit ve karşılaşılan haliyle, her test tek bir nitelik olarak değerlendirilir. Böylece örnek uzay nitelik değerine göre bölünür. Sayısal niteliklerde koşul bir aralığa işaret eder.

Her yaprak optimum hedef değeri temsil eden sınıfa atanır. Her bir düğüm iki ya da daha fazla dala ayrılabilir. Bir düğümden inen her dal, öznelik için olası değerlerden birine karşılık gelir.

Sınıflandırma ağacın kökünden yaprağa gidilerek yapılır. Öncelikle ağacın kökü ile başlanır. Köke karşılık gelen özellik dikkate alınarak bu özelliğin hangi dalı karşıladığı belirlenir. Ardından bu dalın görüldüğü düğüme bakılır. Bir yaprağa ulaşana kadar bu düğüm için işlemler tekrarlanır. Her bir düğüm test ettiği özellik ile, düğümün dalları ise ilgili değerler ile etiketlenir [37].

Literatüre baktığımızda karar ağacı öğrenmesinde kullanılan farklı algoritmalar olduğu görülür. ID3, C4.5, C5.0, CART, MARS bunlardan bazılarıdır.

2.2.3.1 CART

CART, 1984 yılında Breiman ve arkadaşları tarafından geliştirilen, ‘sınıflandırma ve regresyon ağaçları’ anlamına gelen bir algoritmadır [38]. İkili ağaç ile temsil edilen bir model olup, her iç düğüm iki çıkış kenarına sahiptir. Öznelik seçerken bölünmeler için Gini ve Twoing kriterleri kullanılır. CART, kullanıcılara önceden olasılık dağılımlarını hesaplama fırsatı sağlar. Özel bir veri hazırlığı gerektirmeyen, hızlı ve esnek bir algoritmadır.

Gini İndeksi

CART algoritması ile kullanılan Gini indeksi, hedef nitelik değerlerinin olasılık dağılımları arasındaki farka dayalı katışıklık esaslı bir kriterdir. Tahmin edici değişkenlerin alt gruplarının göreceli sıklığına dayanır [38].

- **Katışıklık ölçümü**

$$\text{Gini}(S) = 1 - \sum_i p_i^2 \quad (2.29)$$

- **Ortalama Gini İndeksi**

$$\text{Gini}(S,A) = \sum_i \frac{|S_i|}{|S|} \cdot \text{Gini}(S_i) \quad (2.30)$$

Twoing Kriteri

Twoing için temel fikir, tüm j sınıflarının iki süper sınıfa ayrılmasının iki sınıflı bir problem olarak görülmesidir. Bu sayede düğüm katışıklığında en büyük düşüş gerçekleşmiş olur. Formülde, Gini katışıklık ölçüsü kullanılan iki sınıflı bir problem

için, bir düğümde gerçekleşen en iyi Twoing kriteri bölünmesinin maksimize edildiği gösterilmiştir [38].

$\{s\}$ bölünmeler sınıfı, t ise düğüm olarak kabul edilsin. Denklem 2.33 ile gösterilen $\theta(s, t)$ fonksiyonu maksime edici olarak kabul edilen en iyi bölünme fonksiyonu olsun. j ; t düğümündeki sınıfları , $p = p_1, \dots, p_j$ ise sınıf bölünmelerini gösterir. p_L sol bölünme, p_R ise sağ bölünmeyi temsil eder. $p_R = 1 - p_L$ 'dir.

$$\theta(s, t) = p_L p_R \left[\sum_j |p(j / t_L) - p(j / t_R)| \right]^2 \quad (2.31)$$

Formül kullanıldığında maksimize olan bölünme ile oluşan iki süper sınıf aşağıda tanımlanmıştır:

$$\begin{aligned} C_1 &= \{j; p(j / t_L) \geq p(j / t_R)\} \\ C_2 &= \{j; p(j / t_L) < p(j / t_R)\} \end{aligned} \quad (2.32)$$

2.2.4 Rastgele orman

Rastgele orman (RO) 2001 yılında Breiman tarafından önerilen, sınıflandırma ve regresyon problemlerinde kullanılabilen bir denetimli öğrenme algoritmasıdır. Birbirinden ayrı olarak eğitilmiş ağaçların tahminlerinin birleşimiyle oluşan RO, bu tahminlerin ortalaması alınarak yeni tahminlerde bulunan bir topluluk öğrenmesi yöntemidir [39]. Topluluktaki her bir karar ağacı, sınıflandırılacak her durum için oy kullanır. Bu algoritmanın öngörüsü ağaçların oy çokluğu ile elde edilir [40,41].


Topluluktaki ağaçların geliştirilmesini yöneten rastgele vektörlerin üretilmesiyle toplulukların büyümesi de sağlanır. RO algoritması, 'rastgele alt uzaylar' ve 'torbalama' (ing: bagging) yöntemlerinin birleşiminden oluşmuştur [42].

Bagging; ağaçların nerede üretileceğini eğitim setindeki örneklerden rastgele seçen bir yöntemdir [44]. Rastgele alt uzaylar yöntemi ise, ağaçların üretilmesi için kullanılacak özellik alt kümesinin rastgele seçilmesine dayanır [43].

Bu modele göre k bir pozitif tam sayı olsun. k . ağaç için önceden üretilen rastgele vektörler olan $\theta_1, \dots, \theta_{k-1}$ 'den bağımsız olarak fakat aynı dağılımda rastgele bir θ_k vektörü üretilir. Ağaç, eğitim seti ve θ_k kullanılarak üretilir ve x 'in bir girdi vektörü

olduğu $h(x, \theta_k)$ sınıflandırıcısı ile sonuçlanır. Ağaç oluşumunda kullanılmasına bağlı olarak θ , yapı ve boyut olarak değişiklik gösterebilir. Çok sayıda ağaç oluşturulduktan sonra bu ağaçlar sınıflandırma için en uygun sınıfa karar verirler. Rastgele ormanların oluşumu bu şekilde açıklanabilir [42].

Rastgele ormanın yapısı Şekil 2.5'te gösterilmiştir.



Şekil 2.5 : Rastgele orman yapısı.

RO algoritmasının avantajları arasında büyük boyutlu ve çok değişkenli veri setleri ile çalışabilmesi sınıflandırma yaparken oldukça yüksek doğruluğa ulaşabilmesi, eksik verileri ele alırken sağlam bir yöntemi olması ve oldukça hızlı çalışabilmesi sayılabilir.

RO algoritması, adını toplulukta bulunan her ağacın birbirinden farklı olması amacıyla ağaçların yapısına rastgelelik katılmasından almıştır. Ağaçların rastgeleleştirilmesi iki şekilde sağlanır. Bunlar ağaçların oluşturulması için veri noktalarının seçilmesi ve her bölünmüş test için özelliklerin seçilmesidir [28,41].

RO algoritmasında ağaçların üretilmesi aşamasındaki adımlar şunlardır:

1. Durum sayısının rastgele bir örneği alınır. Diğer ağaçlar için sonraki örnekler değiştirme ile yapılır.
2. Değişken alt kümesi (m ile gösterilsin), değişken sayısından çok daha az olacak şekilde seçilir ve en iyi bölünme bu değişken alt kümesinde saptanır (Gini indeksi kullanılır). m değerinin artması, ağaçlar arasındaki korelasyonu artırırken, aynı zamanda ağacın tahmin hata oranını azaltır. m değerinin azalması durumunda ise ters etkiler beklenir. Bu m değişkeni algoritmanın

model oluşturulurken hassas olduđu tek ayardır.

3. Durumların yaklaşık olarak üçte biri örneklerde olmayan test veri kümesini oluşturmak için kullanılır. Bu test seti ile tahmin hata oranı hesaplanır. Ortalama hata oranı ise üretilen tüm ağaçlar ile hesaplanır.
4. Değişkenin önemi ağacı oluşturan örnek dışı verileri kullanarak hesaplanır ve öngörülen sınıf için verilen karar (oy) sayısına bakılır. Ardından değişkenlerin değerleri rastgele olacak şekilde değiştirilir ve ağaçtan bağımsız olarak çalıştırılır. Değişkeni değiştirilen ağaç için verilen oyların sayısı, değişkenleri değişmeyen diğer ağaçlara etkisi olmaması açısından yok sayılır. Son olarak ise değişken önem değeri için tüm ağaçlardaki ortalama etki hesaplanır.





3. BULGULAR

Çalışma kapsamında nöropsikolojik test aracılığıyla demans tahmini için kullanılan OASIS-3 veri seti çalışmaya uygun olarak hazırlanmış, k-en yakın komşuluk, destek vektör makineleri, karar ağaçları ve rastgele orman algoritmaları kullanılarak sınıflandırma yapılmıştır. Sınıflandırma sonrası modellerin karmaşıklık matrisleri oluşturularak doğruluk, duyarlılık, özgüllük ve yanlış negatif oranı ölçümleri yapılmıştır.

3.1 Veri Seti ve Hazırlanması

Çalışmada kullanılan OASIS-3 veri seti yaşları 42 ile 99 arasında değişen bilişsel olarak normal kabul edilen 609 birey ve demansın çeşitli aşamalarında oldukları teşhis edilmiş 489 bireyin farklı zaman aralıklarındaki doktor kontrol raporlarını içeren 6224 kayıttan oluşmaktadır. OASIS-3, 30 yılı aşkın süredir WUSTL Knight ADRC aracılığıyla devam eden birkaç projeden derlenerek oluşturulmuştur. Veri seti içerisinde bireylere ait demografik bilgiler, uygulanan MMSE test skoru ile klinik muayane sonuçları, hastalık teşhis bilgileri ve bunlara ek olarak hastaların MRI ve PET görüntüleri bulunmaktadır.

Klinik muayenede hastaların ev dışı işlevsellik, ev yaşamı ve hobi, bellek, kişisel bakım, oryantasyon, yargılama ve problem çözme durumlarının doktor tarafından değerlendirilip puanlandırılmasıyla elde edilen CDR ve CDR-SOB değerleri, kan testi ile belirlenen ApoE değeri ve görüntüleme sonuçları çalışmaya dahil edilmemiştir.

Veri setinde bulunan özniteliklerden klinik muayene gerekmeden edinilebilen verilere dayanan öznitelikler seçilmiş olup, kişilerin boy ve kilo bilgilerinden vücut kitle indeksleri hesaplanarak boy ve kilo bilgileri yerine yeni bir öznitelik olarak kullanılmıştır.

Özniteliklerin belirlenmesinin ardından veri setine sınıflandırma performansını arttırmak amacıyla veri ön işleme yöntemleri uygulanmıştır. Teşhis bilgisi eksik veriler veri setinden silinmiş, çalışmada 6179 kayıt kullanılmıştır. Diğer eksik veriler ise sayısal değişkenler için medyan ya da ortalama, kategorik değişkenler için ise mod

değerine göre tamamlanmıştır. Ardından kategorik olan cinsiyet, kullanılan el ve etnik köken değişkenleri sayısal değişkenlere dönüştürülmüştür. Çalışma için hazırlanan veri seti istatistiksel olarak analiz edilmiştir (Çizelge 3.1).

Çizelge 3.1 : Veri Setinin İstatistiksel Analizi.

Öznitelikler	Sağlıklı Sınıf		Demans Sınıfı	
	Aralık	Tanımlayıcı İstatistik	Aralık	Tanımlayıcı İstatistik
MMSE	20-30	$\mu = 29.07$ $\sigma = 1.23$	0-30	$\mu = 25.28$ $\sigma = 4.53$
Yaş	42-98	$\mu = 72.45$ $\sigma = 8.61$	50-99	$\mu = 77.17$ $\sigma = 8.10$
Eğitim	8-29	$\mu = 15.82$ $\sigma = 2.54$	7-29	$\mu = 15.17$ $\sigma = 2.93$
Cinsiyet	Kadın/Erkek	K: 2656 E: 1838	Kadın/Erkek	K: 685 E: 1000
Vücut Kitle İndeksi	14-60	$\mu = 27.52$ $\sigma = 5.16$	15-47	$\mu = 26.70$ $\sigma = 4.40$
Kullanılan El	Sağ/ Sol/ Her ikisi	Sağ : 4006 Sol : 392 H : 96	Sağ/ Sol/ Her ikisi	Sağ : 1524 Sol : 128 H : 33
Etnik Köken	AfroAmerikan/ Kafkas/Asyalı	AA : 524 K : 3955 A : 15	AfroAmerikan/ Kafkas/Asyalı	AA : 178 K : 1505 A : 2

Veri ön işleme yöntemleri uygulanan veri seti sınıflandırma için k-katlamalı çapraz doğrulama yöntemi ile eğitim ve test verisi olarak ayrılmıştır. K-katlamalı çapraz doğrulamada veri seti belirlenen k sayısına göre eşit katlara bölünür. Algoritma k kez çalıştırılarak her katın bir kez test seti olarak kullanılması sağlanır, geriye kalan k-1 kat ise eğitim seti olarak kullanılır. Algoritmanın başarısı ise elde edilen k adet sonucun ortalaması alınarak hesaplanır. Çalışmada K sayısı 10 olarak seçilmiştir. Modeller için uygun normalleştirme yöntemleri ve optimum parametreler belirlenerek 10-katlamalı çapraz doğrulama ile başarımları hesaplanmıştır.

Sınıflandırmada kullanılan algoritmaların performanslarını ölçmek amacıyla modellerin karmaşıklık matrisleri oluşturularak doğruluk, duyarlılık, özgüllük ve

yanlış negatif oranı (YNO) hesaplamaları yapılmıştır. Karmaşıklık matrisi öngörülen ve gerçek sınıfları sınıf sayısına bağlı olarak LxL boyutlarında gösteren bir matristir [45]. Çizelge 3.2 'de 2x2 boyutunda karmaşıklık matrisi gösterilmiştir.

Çizelge 3.2 : Karmaşıklık matrisi örneği.

		Tahmin Edilen Sınıf	
		Hastalık Yok	Hastalık Var
Gerçek Sınıf	Hastalık Yok	True Negative (TN)	False Positive (FP)
	Hastalık Var	False Negative (FN)	True Positive (TP)

Karmaşıklık matrisi ile hesaplanan terimler aşağıda verilmiştir:

- Doğruluk = $\frac{TP+TN}{TP+TN+FP+FN}$
- Doğru Pozitif Oranı / Duyarlılık / Hassasiyet = $\frac{TP}{TP+FN}$
- Doğru Negatif Oranı / Seçicilik (Özgüllük) = $\frac{TN}{TN+FP}$
- Yanlış Negatif Oranı (YNO) = $\frac{FN}{FN+TP}$

3.2 Sınıflandırma Sonuçları

Veri setine uygulanan makine öğrenmesi yöntemleri ile demans tahmini için sınıflandırma sonuçları elde edilmiştir. Modellerin başarımları ölçümleri için oluşturulan karmaşıklık matrisleri ve karmaşıklık matrisi bileşenleri ile hesaplanan doğruluk, duyarlılık, özgüllük ve YNO değerleri bu bölümde verilmiştir (Çizelge 3.3 - Çizelge 3.10).

3.2.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları

K-en yakın komşuluk algoritması için verilere Min Max ölçeklendirici uygulanmıştır. k parametresi 10 olarak belirlenmiş olup, uzaklık ölçüsü olarak Manhattan uzaklığı kullanılmıştır. Sınıflandırma sonucunda KNN algoritması ile % **84.93 ± 1.47** doğruluğa ulaşılmıştır.

Çizelge 3.3 : KNN karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	4236	258
	Demans Var	673	1012

Çizelge 3.4 : KNN performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8493	0.6006	0.9426	0.3994

3.2.2 Destek vektör makineleri algoritması sınıflandırma sonuçları

Çalışmadaki tüm DVM modellerinde kernel fonksiyonlarından radyal tabanlı kernel kullanılmıştır. Model için verilere standart ölçeklendirici uygulanmış olup, modelin ceza parametresi (C) ve fonksiyonun gamma katsayısı 1 olarak belirlenmiştir. Sınıflandırma sonucunda $\%85.24 \pm 1.30$ doğruluğa ulaşılmıştır.

Çizelge 3.5 : DVM karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	4285	209
	Demans Var	703	982

Çizelge 3.6 : DVM performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8524	0.5828	0.9535	0.4172

3.2.3 Karar ağaçları algoritması sınıflandırma sonuçları

Karar ağaçları algoritması için veriler Standart ölçeklendirici ile ölçeklendirilmiştir. Maksimum ağaç derinliği ise 7 olarak belirlenmiştir. Çalışmadaki tüm KA

modellerinde CART algoritması kullanılmış ve Gini kriteri uygulanmıştır. Sınıflandırma sonucunda % 83.83 ± 1.07 doğruluğa ulaşılmıştır.

Çizelge 3.7 : KA karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	4296	198
	Demans Var	801	884

Çizelge 3.8 : KA performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8383	0.5246	0.9559	0.4754

3.2.4 Rastgele orman algoritması sınıflandırma sonuçları

RO algoritması için veriler Standart ölçeklendirici ile ölçeklendirilmiş, ağaç sayısı 200 olarak belirlenmiş ve maksimum ağaç derinliği 15 olarak ayarlanmıştır. Çalışmadaki tüm RO modellerine Gini kriteri uygulanmıştır. Sınıflandırma sonucunda % 84.66 ± 1.10 doğruluğa ulaşılmıştır.

Çizelge 3.9 : RO karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	4256	238
	Demans Var	710	975

Çizelge 3.10 : RO performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8466	0.5786	0.9470	0.4214

3.3 Veri Seti Bölünmesi ile Elde Edilen Sınıflandırma Sonuçları

Performans değişimini incelemek amacıyla veri seti yaş ve eğitim öznitelikleri için belirlenen eşik değerler baz alınarak dört gruba bölünmüş ve her grup için modellerin sınıflandırma performansları ölçülmüştür.

Yaş özniteliği için 65 yaş, eğitim özniteliği için ise 16 yıl eşik değer olarak belirlenmiş olup veri seti bu değerlere göre dört gruba ayrılmıştır.

3.3.1 Grup I

3285 kişiden oluşan, 65 yaş ve üzerindeki en az 16 yıl eğitim görmüş bireylere ait olan kayıtların dahil olduğu verilere uygulanan yöntemlerin performans ölçümleri için karmaşıklık matrisleri oluşturulmuş, karmaşıklık matrisi bileşenleri ile doğruluk, duyarlılık, özgüllük ve YNO değerleri hesaplanmıştır (Çizelge 3.11 - Çizelge 3.18).

3.3.1.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları

Veriler gürbüz ölçeklendirici ile ölçeklenmiş, modelin k parametresi 14 olarak belirlenmiştir. Uzaklık ölçümü için Manhattan Uzaklığı kullanılmıştır. Sınıflandırma sonucunda doğruluk $\%84.14 \pm 1.99$ olarak hesaplanmıştır.

Çizelge 3.11 : Grup I için KNN karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	2264	134
	Demans Var	387	500

Çizelge 3.12 : Grup I için KNN performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8414	0.5637	0.9441	0.4363

3.3.1.2 Destek vektör makineleri algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanmış, C değeri 1.4 ve gamma katsayısı 1.1 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk $\% 84.29 \pm 1.85$ olarak hesaplanmıştır.

Çizelge 3.13 : Grup I için DVM karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	2288	110
	Demans Var	406	481

Çizelge 3.14 : Grup I için DVM performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8429	0.5423	0.9541	0.4577

3.3.1.3 Karar ağaçları algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanmış, maksimum ağaç derinliği 6 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk % **83.20 $\pm$ 2.32** olarak hesaplanmıştır.

Çizelge 3.15 : Grup I için KA karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	2287	111
	Demans Var	441	446

Çizelge 3.16 : Grup I için KA performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8320	0.5028	0.9537	0.4972

3.3.1.4 Rastgele orman algoritması sınıflandırma sonuçları

Veriler Standart ölçeklendirici ile ölçeklenmiş, ağaç sayısı 400 ve maksimum ağaç derinliği 15 olarak ayarlanmıştır. Sınıflandırma sonucunda % **83.71 $\pm$ 1.94** doğruluğa ulaşılmıştır.

Çizelge 3.17 : Grup I için RO karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	2261	137
	Demans Var	398	489

Çizelge 3.18 : Grup I için RO performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8371	0.5513	0.9429	0.4487

3.3.2 Grup II

525 kişiden oluşan, 65 yaşın altında ve en az 16 yıl eğitim görmüş bireylere ait olan kayıtların dahil olduğu verilere uygulanan yöntemlerin performans ölçümleri için karmaşıklık matrisleri oluşturulmuş, karmaşıklık matrisi bileşenleri ile doğruluk, duyarlılık, özgüllük ve YNO değerleri hesaplanmıştır (Çizelge 3.19 - Çizelge 3.26).

3.3.2.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları

Model için verilere standart ölçeklendirici uygulanmıştır. Algoritmanın k parametresi 5 olarak belirlenmiş ve uzaklık ölçümü için Minkowski Uzaklığı kullanılmıştır. Sınıflandırma sonucunda doğruluk % **95.05 ± 1.50** olarak hesaplanmıştır.

Çizelge 3.19 : Grup II için KNN karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	464	6
	Demans Var	20	35

Çizelge 3.20 : Grup II için KNN performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9505	0.6364	0.9872	0.3636

3.3.2.2 Destek vektör makineleri algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanmış olup, C değeri 10 ve gamma katsayısı 1 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk $\% 93.90 \pm 2.39$ olarak hesaplanmıştır.

Çizelge 3.21 : Grup II için DVM karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	459	11
	Demans Var	21	34

Çizelge 3.22 : Grup II için DVM performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9390	0.6182	0.9766	0.3818

3.3.2.3 Karar ağaçları algoritması sınıflandırma sonuçları

Model için verilere standart ölçeklendirici uygulanmış, maksimum ağaç derinliği 4 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk $\%94.48 \pm 1.58$ olarak hesaplanmıştır.

Çizelge 3.23 : Grup II için KA karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	467	3
	Demans Var	26	29

Çizelge 3.24 : Grup II için KA performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9448	0.5273	0.9936	0.4727

3.3.2.4 Rastgele orman algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanan modelin ağaç sayısı 300 olarak belirlenmiş ve maksimum ağaç derinliği 15 olarak ayarlanmıştır. Sınıflandırma sonucunda doğruluk % 94.67 ± 1.65 olarak hesaplanmıştır.

Çizelge 3.25 : Grup II için RO karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	466	4
	Demans Var	24	31

Çizelge 3.26 : Grup II için RO performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9467	0.5636	0.9915	0.4364

3.3.3 Grup III

277 kişiden oluşan, 65 yaşın altında ve 16 yıldan az eğitim görmüş bireylere ait olan kayıtların dahil olduğu verilere uygulanan yöntemlerin performans ölçümleri için karmaşıklık matrisleri oluşturulmuş, karmaşıklık matrisi bileşenleri ile doğruluk, duyarlılık, özgüllük ve YNO değerleri hesaplanmıştır (Çizelge 3.27 - Çizelge 3.34).

3.3.3.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları

Model için verilere standart ölçeklendirici uygulanmıştır. k parametresi 2 olarak belirlenmiş ve uzaklık ölçümü için Minkowski Uzaklığı kullanılmıştır. Sınıflandırma sonucunda doğruluk % 91.70 ± 2.63 olarak hesaplanmıştır.

Çizelge 3.27 : Grup III için KNN karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	231	0
	Demans Var	23	23

Çizelge 3.28 : Grup III için KNN performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9170	0.50	1.00	0.50

3.3.3.2 Destek vektör makineleri algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanan modelde C değeri 1, gamma değeri ise 0.1 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk **%91.34 ± 2.37** olarak hesaplanmıştır.

Çizelge 3.29 : Grup III için DVM karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	230	1
	Demans Var	23	23

Çizelge 3.30 : Grup III için DVM performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9134	0.50	0.9957	0.50

3.3.3.3 Karar ağaçları algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanmış olup, maksimum derinlik 7 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk **%91.70 ± 4.12** olarak hesaplanmıştır.

Çizelge 3.31 : Grup III için KA karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	226	5
	Demans Var	18	28

Çizelge 3.32 : Grup III için KA performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9170	0.6087	0.9784	0.3913

3.3.3.4 Rastgele orman algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanan modelin ağaç sayısı 100 olarak belirlenmiş ve maksimum ağaç derinliği 15 olarak ayarlanmıştır. Sınıflandırma sonucunda doğruluk % 91.34 ± 1.69 olarak hesaplanmıştır.

Çizelge 3.33 : Grup III için RO karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	229	2
	Demans Var	22	24

Çizelge 3.34 : Grup III için RO performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.9134	0.5217	0.9913	0.4783

3.3.4 Grup IV

2092 kişiden oluşan, 65 yaş ve üzerindeki 16 yıldan az eğitim görmüş bireylere ait olan kayıtların dahil olduğu verilere uygulanan yöntemlerin performans ölçümleri için karmaşıklık matrisleri oluşturulmuş, karmaşıklık matrisi bileşenleri ile doğruluk, duyarlılık, özgüllük ve YNO değerleri hesaplanmıştır (Çizelge 3.35 - Çizelge 3.42).

3.3.4.1 K-en yakın komşuluk algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanan modelde k parametresi 5 olarak belirlenmiş ve uzaklık ölçümü için Minkowski Uzaklığı kullanılmıştır. Sınıflandırma sonucunda doğruluk % 84.51 ± 2.45 olarak hesaplanmıştır.

Çizelge 3.35 : Grup IV için KNN karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	1278	117
	Demans Var	207	490

Çizelge 3.36 : Grup IV için KNN performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8451	0.7030	0.9161	0.2970

3.3.4.2 Destek vektör makineleri algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanmış olup C değeri ve gamma değeri 1 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk **%85.71 ± 1.49** olarak hesaplanmıştır.

Çizelge 3.37 : Grup IV için DVM karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	1295	100
	Demans Var	199	498

Çizelge 3.38 : Grup IV için DVM performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8571	0.7145	0.9283	0.2855

3.3.4.3 Karar ağaçları algoritması sınıflandırma sonuçları

Karar ağaçları algoritması için veriler standart ölçeklendirici yöntemi ile ölçeklendirilmiş, maksimum derinlik 4 olarak belirlenmiştir. Sınıflandırma sonucunda doğruluk **%82.41 ± 2.54** olarak hesaplanmıştır.

Çizelge 3.39 : Grup IV için KA karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	1294	101
	Demans Var	267	430

Çizelge 3.40 : Grup IV için KA performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8241	0.6169	0.9276	0.3831

3.3.4.4 Rastgele orman algoritması sınıflandırma sonuçları

Verilere standart ölçeklendirici uygulanan modelde ağaç sayısı 300 olarak belirlenmiş ve maksimum ağaç derinliği 15 olarak ayarlanmıştır. Sınıflandırma sonucunda doğruluk % **84.32 ± 2.74** olarak hesaplanmıştır.

Çizelge 3.41 : Grup IV için RO karmaşıklık matrisi.

		Tahmin Edilen Sınıf	
		Demans Yok	Demans Var
Gerçek Sınıf	Demans Yok	1284	111
	Demans Var	217	480

Çizelge 3.42 : Grup IV için RO performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.8432	0.6887	0.9204	0.3113

3.4 Bölünmemiş Veri Seti için Özniteliklerin Önem Sıralaması

Rastgele orman algoritması öngöründe bulunmanın yanında özniteliklerin önemlerini saptama amacıyla da kullanılır. Rastgele ormanı oluşturan ağaçlar üzerinde yapılan gerekli hesaplamalar ile modelin öngörü hatasındaki artışa bakarak özneliğin önemi belirlenir [43]. Çalışmada kullanılan özniteliklerin RO algoritmasıyla belirlenen önem

sıralamaları Çizelge 3.43'te verilmiştir.

Çizelge 3.43 : Özniteliklerin önem sıralaması.

Öznitelik	Skor
MMSE	0.3402
Yaş	0.2670
Vücut Kitle İndeksi	0.2432
Eğitim	0.0931
Cinsiyet	0.0242
Kullanılan El	0.0190
Etnik Köken	0.0133

3.5 Mini Mental Durum Muayenesi Başarısı

Veri setinde yer alan MMSE test skorları ve teşhisler ile MMSE tarama testinin kabul edilen puanlandırma sistemi (Çizelge 1.1) dahilindeki skorlara karşılık gelen değerlendirme sonuçları karşılaştırılmış, yapılan ölçümlerle testin veri seti üzerindeki başarısı incelenmiştir (Çizelge 3.44, Çizelge 3.45).

Çizelge 3.44 : MMSE karmaşıklık matrisi.

		MMSE Skoruna Göre Tahmin	
		Demans Yok	Demans Var
Gerçek Teşhis	Demans Yok	4478	16
	Demans Var	1252	433

Çizelge 3.45 : MMSE performans ölçümleri.

Doğruluk	Duyarlılık	Özgüllük	YNO
0.7948	0.2570	0.9964	0.7430



4. TARTIŞMA

Çalışmada kullanılan veri seti istatistiksel olarak incelendiğinde (Çizelge 3.1) MMSE test skorları ortalaması sağlıklı bireylerde 29 puan, demans hastalarında ise 25 puan olarak hesaplanmıştır. Demans sınıfının MMSE skor ortalamasının kabul edilen değerlendirme sistemine göre (Çizelge 1.1) yüksek olduğu görülmektedir. Yaş ortalaması sağlıklı bireylerden oluşan sınıfta 72, demans sınıfında 77 olarak hesaplanmıştır. Eğitim yılı değerlerine baktığımızda ise testin okuma yazma bilmeyen bireylere uygulanamaması sebebiyle, sağlıklı bireylerden oluşan sınıfta en düşük eğitim yılının 8, demans sınıfında ise 7 olduğu ve sınıflar arası eğitim ortalamalarının birbirine yakın olduğu görülmektedir.

Veri setine uygulanan sınıflandırma ile elde edilen doğruluk, duyarlılık, özgüllük ve yanlış negatif oranı (YNO) performans metrikleri hastalık tanısı koymaya yardımcı olarak geliştirilen sınıflandırma modellerinde oldukça önemlidir. Bu terimleri çalışmadaki anlamları açısından kısaca açıklamak gerekirse; doğruluk testin hasta bireyler ile sağlıklı bireyleri ayırma yeteneği, duyarlılık testin hasta bireyi doğru şekilde sınıflandırma kabiliyeti, özgüllük testin hastalığı olmayan (sağlıklı) bireyleri doğru bir şekilde sınıflandırma kabiliyeti ve YNO ise test ile sağlıklı olarak tahmin edilen ancak hasta olan bireylerin oranı olarak ifade edilebilir.

Veri setine uygulanan ilk sınıflandırma sonucunda elde edilen bulgulara baktığımızda (Çizelge 3.3 - Çizelge 3.10) DVM, KNN ve RO yöntemlerinin birbirine yakın performans sergiledikleri görülmektedir. KNN algoritması ile en yüksek duyarlılık ve en düşük YNO elde edilmiş, model için oluşturulan karmaşıklık matrisine bakıldığında demans tahmininde en başarılı yöntem olduğu görülmüştür. KA ise demans tahmininde diğer algoritmalar kadar başarılı olmasa da sağlıklı bireyleri en yüksek oranla doğru olarak sınıflandırarak yüksek özgüllük değerine ulaşmıştır. Modellerin başarısını arttırmak amacıyla veri seti, bölünme sırasında gruplar arasındaki denge ve dağılım göz önünde bulundurularak, yaş ve eğitim öznitelikleri için belirlenen eşik değerlere göre dört gruba bölünmüştür. Yaş özniteliği için eşik değer Bölüm 1.1.2.1’de verilen oranlar dikkate alınarak 65, eğitim özniteliği için ise bireylerin lisans mezunu olma durumları dikkate alınarak 16 olarak belirlenmiştir.


Yaş ve eğitime göre dört gruba bölünen veri seti üzerindeki sınıflandırma performansları ölçülmüş (Çizelge 3.11- Çizelge 3.42), modellerin dört grup üzerindeki ortalama başarıları hesaplanmıştır. Modellerin başarı ölçümlerindeki değişim (Şekil 4.1 - Şekil 4.4)’te birbirleriyle kıyaslanmıştır.

Sınıflandırma sonrası özniteliklerin sınıflandırma üzerindeki önemleri incelenmiş, en önemli öznitelikler saptanmıştır.

RO algoritması ile hesaplanan öznitelik önem skorları incelendiğinde (Çizelge 3.43) MMSE testi , yaş ve vücut kitle indeksi sınıflandırmada en önemli üç öznitelik olarak belirlenmiştir. Eğitim özniteliğinin de sınıflandırma üzerinde etkili olduğu görülürken; cinsiyet, kullanılan el ve etnik köken en düşük skorlarla sınıflandırmada en az öneme sahip öznitelikler olmuştur. So ve arkadaşlarının çalışmasına [25] baktığımızda ise Ki-Kare ve Bilgi Kazanımı yöntemleriyle belirlenen öznitelik önem sıralamasında MMSE testinde yer alan sorular da öznitelik olarak değerlendirilip incelenmiş, ilk sınıflandırmada kullandıkları veri seti için test sorularının en yüksek skorlara ulaştığı, cinsiyet ve yaşın en az öneme sahip iki öznitelik olarak belirlendiği; ikinci veri seti için elde ettikleri sonuçların ise bu çalışma kapsamında elde edilen sonuçlarla benzer olduğu, yaşın öneminin oldukça artarak test sorularının bazılarında daha yüksek skor aldığı ancak cinsiyetin sınıflandırma üzerinde en az etkili öznitelik olarak belirlendiği görülmektedir.


Sınıflandırmadaki en önemli öznitelik olarak belirlenen MMSE nöropsikolojik tarama testi için yapılan performans ölçümleri sonrası elde edilen karmaşıklık matrisinde görüldüğü üzere (Çizelge 3.44), testin sağlıklı bireyleri tahmin etmede başarılı olduğu ancak 1685 demans hastasının 1252’sini sağlıklı tahmin ederek hasta bireyler üzerinde yeterli başarıya sahip olmadığı söylenebilir. Çizelge 3.45’e baktığımızda ise testin özgüllüğünün yüksek olduğu ancak hasta bireyler üzerinde yeterli başarıya ulaşamadığı için duyarlılık ve YNO ölçümlerinde aynı performansı sergilemediği görülmektedir.

Aşağıdaki grafiklerde modellerin veri seti üzerindeki ilk sınıflandırma sonuçları, yaş ve eğitime göre gruplara ayrılan veri seti üzerindeki ortalama başarıları ve MMSE testinin başarısı karşılaştırılmıştır (Şekil 4.1 - Şekil 4.4).




Şekil 4.1 : Doğruluk karşılaştırması.

Şekil 4.1’de görüldüğü gibi, yöntemlerin tamamı MMSE testi ile elde edilen %79.48 doğruluktan daha yüksek doğruluğa ulaşmıştır. Özellikle yaş ve eğitime göre ayrılan veri setinde elde edilen doğruluk önceki modellere oranla daha da artarak KNN, DVM ve RO yöntemlerinde yaklaşık %89’a, KA yönteminde ise yaklaşık %88’e ulaşmıştır.




Şekil 4.2 : Duyarlılık karşılaştırması.



Şekil 4.3 : YNO karşılaştırması.

Şekil 4.2 ve Şekil 4.3'te verilen duyarlılık ve YNO grafikleri incelendiğinde sınıflandırma modellerinin MMSE testinden başarılı oldukları ve tüm yöntemlerde yaş ve eğitime göre ayrılan veri setindeki performans ölçümleri sonucunda hedeflendiği gibi duyarlılıkta artış, YNO oranında azalma olduğu gözlemlenmiştir.

Şekil 4.4'teki özgüllük sonuçlarına bakıldığında ise modellerin yüksek başarı gösterdiği, veri seti bölünmesiyle özgüllük değerlerinin yükseldiği ancak MMSE testinin özgüllük skoruna ulaşamadıkları görülmektedir.



Şekil 4.4 : Özgüllük karşılaştırması.

Literatürdeki benzer çalışmalarla elde edilen sınıflandırma sonuçlarına baktığımızda ise; Shankle ve ark. [21] 609 kişinin FAQ ve BOMC testi sonuçlarıyla gerçekleştirdikleri çalışmada yaklaşık %86 doğruluğa ulaşmışlardır. Shankle ve ark. [22] bir diğer çalışmalarında ise 442 kişinin FAQ, MMSEPLUS ve ICP test sonuçlarını kullanarak makine öğrenmesi yöntemleri uygulamışlardır. FAQ testi ile en iyi

performansa ulařarak %89 doęruluk, %94 duyarlılık ve %80 özğüllük elde etmişlerdir. MMSEPLUS testi için C4.5 algoritması ile %79 doęruluk, %77 duyarlılık ve %80 özğüllük; ICP testi için ise %66 doęruluk, %68 duyarlılık ve %55 özğüllük elde edilmiştir. So ve ark. [25] çalışmasında ise demansa sahip ve saęlıklı bireyleri tahmin etmek için yapılan ilk sınıflandırmada DVM algoritmasıyla %91.8 doęruluk, %90 duyarlılık, RO algoritmasıyla %97.2 doęruluk, %95 duyarlılık ve en başarılı yöntem olan MLP algoritmasıyla %97.2 doęruluk, %97 duyarlılık elde etmişlerdir. Demans ve bilişsel bozulma görülen hastaları tahmin etmek için yapılan ikinci sınıflandırmada ise DVM %74.03 doęrulukla en başarılı yöntem olmuş, RO ile ise %72.98 doęruluęa ulaşmışlardır. Çalışmada kullandıkları ilk veri setine ait istatistiksel bilgiler dahilinde demans hastalarına ait 0-25 aralıęındaki MMSE test skorları ortalamasının 18, eęitimin ortalama 7 yıl, yař ortalamasının ise 74 olduęu; saęlıklı bireylerde ise 14-30 aralıęında olan MMSE test skorlarının ortalamasının 25, eęitim ortalamasının 5 yıl, yař ortalamasının ise 72 olduęu kaydedilmiştir.

Bu çalışma kapsamında literatürdeki benzer çalışmalar olan Shankle ve arkadaşlarının her iki çalışmasına [21,22] kıyasla oldukça fazla örnek ile çalışılmış, 6179 kişinin MMSE test skorları kullanılmıştır. Veri setine uygulanan makine öğrenmesi yöntemlerinden KNN, DVM ve RO ile ilk sınıflandırmada yaklaşık %85, veri seti bölünmesi sonrası gerçekleştirilen ikinci sınıflandırmada yaklaşık %89, KA ile ise ilk sınıflandırmada yaklaşık %84, ikinci sınıflandırmada yaklaşık %88 doęruluęa ulaşılmıştır. İlk sınıflandırmada KNN algoritması için %60 üzeri duyarlılık, yaklaşık %40 YNO ve %94 üzeri özğüllük, DVM algoritması için %58 üzeri duyarlılık, %41 üzeri YNO ve %95 üzeri özğüllük ve RO algoritması için yaklaşık %58 duyarlılık, %42 üzeri YNO ve yaklaşık %95 özğüllük deęerleri ölçülmüştür. İkinci sınıflandırmada ise ortalama bazında KNN algoritması %60 üzeri duyarlılık, yaklaşık %40 YNO ve %96 üzeri özğüllük, DVM algoritması %59 üzeri duyarlılık, %40 üzeri YNO ve %96 üzeri özğüllük ve RO algoritması %58 üzeri duyarlılık, yaklaşık %42 YNO ve %96 üzeri özğüllük deęerine ulaşmıştır.

Elde edilen doęruluk ve özğüllük ölçümlerinin bahsedilen çalışmalara [21,22] göre başarılı olduęu fakat duyarlılıęın daha düşük olduęu görölmektedir. Ancak MMSE testiyle elde edilen yaklaşık %26 duyarlılık deęerinin makine öğrenmesi yöntemleriyle oldukça arttırıldıęı da göz ardı edilmemelidir.

So ve ark. [25] gerekleřtirdiđi alıřmaya baktıđımızda ise ilk sınıflandırma sonucunda elde ettikleri performans ölümlerinin oldukça yüksek olduđu görölmektedir. Bu durum alıřmadaki en önemli öznelik olan MMSE test skorlarının hasta ve sađlıklı sınıf arasındaki dađılımının başarıml ölümlerinde en belirleyici faktör olmasıyla açıklanabilir. Bu alıřmadaki hasta ve sađlıklı sınıflara ait MMSE skorları ortalamaları arasındaki farkın benzer alıřmaya [25] göre daha düşük olması ve veri setinin beklenenden yüksek test skorlarına sahip demans hastalarını iermesi sebebiyle demans sınıfının skor aralıđının daha geniř olduđu, bu durumların da başarı ölümlerinde farklılıklara yol atıđı söylenebilir.



5. SONUÇ

Günümüzde yaşlı nüfusun artmasıyla birlikte demans prevalansında artış görülmekte, buna ek olarak demansa yakalanma yaşı da gitgide düşmektedir. Son zamanlarda sağlık alanında yapay zeka destekli sistemler oldukça yaygınlaşmış olup, birçok hastalığın teşhis ve tedavi aşamalarında etkin rol oynamaktadır.

Bu çalışma kapsamında makine öğrenmesi yöntemleriyle nöropsikolojik tarama testi başarısını arttırarak demansa dair tahmin amaçlanmıştır. Bunun için veri setine ön işleme yöntemleri uygulanmış olup, kullanılacak öznelilikler belirlenmiş ve modeller için en uygun parametreler tespit edilerek sınıflandırma gerçekleştirilmiştir. Performansta artış elde etmek amacıyla veri setinde bölünme yapılarak sınıflandırma yöntemleri uygulanmıştır. Sınıflandırma sonrası elde edilen ölçümler ile nöropsikolojik testin başarısı karşılaştırılmıştır.

Bu çalışma ile MMSE testinin yanlış negatif oranı düşürülerek, hasta bireyleri doğru olarak tahmin etme başarısı oldukça arttırılmış; doğruluk, duyarlılık ve yanlış negatif oranı dikkate alındığında uygulanan tüm yöntemlerin nöropsikolojik testin demans taramasındaki performansını arttırdığı, çalışmanın başarılı sonuçlara ulaştığı görülmüştür. Veri setine uygulanan iki sınıflandırmada da makine öğrenmesi yöntemlerinden KNN, DVM ve RO birbirine yakın performans ölçümlerine ulaşarak çalışma için tercih edilebilir yöntemler olmuştur.

Gelecek çalışmalarda demansın varlığına dair yapılan öngörünün yanında, hastaların teşhis edilmiş diğer hastalıkları ve demans türleri de sınıflandırmaya dahil edilerek hastaların hangi demans türüne sahip olduğu tahmini yapılabilir ve bu türlerin diğer hastalıklarla olan ilişkisi yorumlanabilir.



KAYNAKLAR

- [1] **What is dementia? - Dementia UK.** (2019). Alındığı Tarih: 07.07.2019, adres: <https://www.dementiauk.org/understanding-dementia/what-is-dementia>.
- [2] **Dementia.** (2019). *World Health Organization*. Alındığı Tarih: 07.07.2019, adres: <https://www.who.int/en/news-room/fact-sheets/detail/dementia>.
- [3] **Korczyn, A. D., Vakhapova, V. ve Grinberg, L. T.** (2012). Vascular dementia, *J Neurol Sci.*, s. 322(1-2): 2–10.
- [4] **Petersen, R. C., Caracciolo, B., Brayne, C., Gauthier, S., Jelic, V., Fratiglioni, L.** (2014). Mild cognitive impairment: a concept in evolution, *J Intern Med*, 275(3):214-28.
- [5] **Risk factors for dementia: Factsheet 450LP,** (2016). Alzheimer's Society United Against Dementia.
- [6] **Livingston, G., Sommerlad, A., Orgeta, V., Costafreda, S. G., Huntley, J., Ames, D., et al.** (2017). Dementia prevention, intervention, and care, *Lancet*, 390 (10113): 2673–2734.
- [7] **Karaali, K.** (2016). Demansta Radyolojik Bulgular, *Nükleer Tıp Seminerleri*, 3:139-143.
- [8] **Gürvit, İ. H.** (2011). Demans Sendromu, Alzheimer Hastalığı Ve Alzheimer Dışı Demanslar, *İstanbul Tıp Fakültesi Nöroloji Kitabı*.
- [9] **Folstein, M.F., Folstein, S.E., Mchugh, P.R.** (1975). "Mini-Mental State": A Practical Method For Grading The Cognitive State Of Patients For The Clinician, *J. Gsychiaf. Res.*, Vol. 12, Pp. 189-190.
- [10] **Gürvit, H.İ., Baran, B.** (2007). Demanslar ve Kognitif Bozukluklarda Ölçekler, *Nöropsikiyatri Arşivi*, 44: 58-65.
- [11] **Alpaydın, E.** (2010). Introduction to Machine Learning, Second Edition, The MIT Press, Cambridge.
- [12] **Portugal, I., Alencar, P., Cowan, D.** (2015). The Use of Machine Learning Algorithms in Recommender Systems: A Systematic Review, arXiv, vol. 4, 1–16.
- [13] **Deo, R. C.** (2015). Machine Learning in Medicine, *Circulation*, 132:1920-1930.
- [14] **Öztemel, E.** (2006). Yapay Sinir Ağları, 2. Basım, Papatya Yayıncılık Eğitim, İstanbul.
- [15] **Cuingnet, R., Gerardin, E., Tessieras, J., Auzias, G., Lehéricy, S., Habert, M. O., Chupin, M., Benali, H., Colliot, O.** (2011). Automatic classification of patients with Alzheimer's disease from structural MRI: a comparison of ten methods using the ADNI database, *NeuroImage*, 56 (2):(2011), pp. 766-781.

- [16] **Bansal, D., Chhikara, R., Khanna, K., and Gupta, P.** (2018). Comparative analysis of various machine learning algorithms for detecting dementia, *Procedia Computer Science*, 132:1497–1502.
- [17] **Demirhan, A.** (2016). Classification of structural MRI for detecting Alzheimer's disease, *International Journal of Intelligent Systems and Applications in Engineering*, 195-198.
- [18] **Aruna, S. K., & Chitra, S.** (2016). Machine Learning Approach for Identifying Dementia from MRI Images, *World Academy of Science, Engineering and Technology, International Journal of Computer, Electrical, Automation, Control and Information Engineering*, 9(3),881-888.
- [19] **Miller, V., Erlien, S., Piersol, J.** (2012). Identifying Dementia in MRI Scans using Machine Learning, Stanford, CA: Stanford University.
- [20] **Chen, R., & Herskovits, E. H.** (2010). Machine-learning techniques for building a diagnostic model for very mild dementia, *Neuroimage*, 52(1): 234-244.
- [21] **Shankle, W. R., Datta, P., Dillencourt, M., & Pazzani, M.** (1996). Improving dementia screening tests with machine learning methods, *Alzheimer's Research*, 2(3).
- [22] **Shankle, W. R., Mani, S., Pazzani, M. J., & Smyth, P.** (1997). Detecting very early stages of dementia from normal aging with machine learning methods, In *Conference on Artificial Intelligence in Medicine in Europe* Springer, Berlin, Heidelberg: 71-85.
- [23] **Wang, T., Qiu, R., G., Yu, M.** (2018). Predictive modeling of the progression of Alzheimer's disease with recurrent neural networks, *Sci Rep*, 8: 9161.
- [24] **Maroco, J., Silva, D., Rodrigues, A., Guerreiro, M., Santana, I., & de Mendonça, A.** (2011) "Data mining methods in the prediction of Dementia: A real-data comparison of the accuracy, sensitivity and specificity of linear discriminant analysis, logistic regression, neural networks, support vector machines, classification trees and random forests. *BMC Res. Notes* 4, 299.
- [25] **So, A., Hooshyar, D., Park, K., Lim, H.** (2017). Early Diagnosis of dementia from clinical data by machine learning techniques. *Appl Sci.*;7(7):651.
- [26] **Danubianu, M., Popa, V., Tobolcea, I.** (2012). Unsupervised Information Based Feature Selection for Speech Therapy Optimization by Data Mining Techniques, *Proceedings of The Seventh International Multi-Conference on Computing in the Global Info.*
- [27] **Han, J., Kamber, M.** (2001). *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers, USA, 550p.
- [28] **Müller, A. C., Guido, S.** (2017). *Introduction to Machine Learning with Python*, O'Reilly Media, USA.
- [29] **Hu, L.-Y., Huang, M.-W., Ke, S.-W., Tsai, C.-F.** (2016). The distance function effect on k-nearest neighbor classification for medical datasets, *Springerplus*, 5(1): 1304.

- [30] **Schölkopf, B., Smola A. J.** (2002). Learning with Kernels, The MIT Press, Cambridge, Massachusetts, London, England.
- [31] **Zhang, S., Zong, M., Sun, K., Liu, Y., Cheng D.** (2014). Efficient kNN Algorithm Based on Graph Sparse Reconstruction, ADMA, 356-369.
- [32] **VanderPlas, J.** (2017). Python Data Science Handbook, O'Reilly Media, USA.
- [33] **Vapnik, V. N.** (1999). An Overview of Statistical Learning Theory, IEEE Transactions On Neural Networks, Vol.10, No.5.
- [34] **Gunn, S.** (1998). Support Vector Machines for Classification and Regression, ISIS Technical Report, Image Speech and Intelligent Systems Research Group, University of Southampton.
- [35] **Burges, C. J. C.** (1998). A Tutorial On Support Vector Machines For Pattern Recognition, Data Mining And Knowledge Discovery 2(2):121–167.
- [36] **SVM.** (t.y.). *İlyas Çiçekli*. Alındığı Tarih: 10.08.2019, adres: <https://web.cs.hacettepe.edu.tr/~ilyas/Courses/BIL712/lec06-SVM.pdf>.
- [37] **Rokach, L., Maimon, O.** (2015). Data Mining With Decision Trees Theory And Applications, 2.Baskı, World Scientific Publishing, Singapore.
- [38] **Breiman, L., Friedman, J., Olshen, R., Stone, C.** (1984). Classification and Regression Trees, Wadsworth Int. Group.
- [39] **Denil, M., Matheson, D., De Freitas, N.** (2014). Narrowing the gap: Random forests in theory and in practice, Proceedings of The 31st International Conference on Machine Learning.
- [40] **Nisbet, R., Elder, J., Miner, G.** (2009). Handbook Of Statistical Analysis And Data Mining Applications, Elsevier, Canada.
- [41] **Shalev-Shwartz, S., Ben-David, S.** (2014). Understanding Machine Learning: From Theory to Algorithms, Cambridge University Press, New York, USA, ISBN 1107057132, 9781107057135.
- [42] **Breiman, L.** (2001). Random Forests, Machine Learning, 45, 5–32.
- [43] **Ho, T. K.** (1998). The random subspace method for constructing decision forests, IEEE transactions on pattern analysis and machine intelligence, 20(8), 832-844.
- [44] **Breiman, L.** (1996). Bagging Predictors. Machine Learning, 24, 123-140.
- [45] **Kohavi, R., Provost, F.** (1998). Glossary of terms. Machine Learning—Special Issue on Applications of Machine Learning and the Knowledge Discovery Process. Machine Learning, 30, 271-274.



ÖZGEÇMİŞ

Ad-Soyad : Tuğba TUNA
Doğum Tarihi ve Yeri : 10.12.1993 / İstanbul
E-posta : ttubatuna@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2015, Yıldız Teknik Üniversitesi, Kimya Metalurji Fakültesi, Matematik Mühendisliği
- **Yüksek Lisans** : İstanbul Teknik Üniversitesi, Hesaplamalı Bilim ve Mühendislik Anabilim Dalı, Hesaplamalı Bilim ve Mühendislik Programı