

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SPONTANE KONUŞMADAN ALZHEİMER
HASTALIĞI TESPİTİ VE VERİ SETİ
OLUŞTURMA

Ediz AKARSU

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Prof. Dr. Banu DİRİ

Temmuz, 2024

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SPONTANE KONUŞMADAN ALZHEİMER HASTALIĞI
TESPİTİ VE VERİ SETİ OLUŞTURMA

Ediz AKARSU tarafından hazırlanan tez çalışması 03.07.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Banu DİRİ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Banu DİRİ, Danışman
Yıldız Teknik Üniversitesi

DR.ÖĞR.ÜYE. Hafıza İrem Türkmen ÇİLİNGİR, Üye
Yıldız Teknik Üniversitesi

DOÇ.DR. Aysun GÜRAN, Üye
Doğuş Üniversitesi

Danışmanım Prof. Dr. Banu DİRİ sorumluluğunda tarafımda hazırlanan SPONTANE KONUŞMADAN ALZHEİMER HASTALIĞI TESPİTİ VE VERİ SETİ OLUŞTURMA başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Ediz AKARSU

İmza

*Anneannem Remziye YETİMOĞLU
ve aileme ithafen*



TEŞEKKÜR

Tez süreci boyunca emeđi geen tez danıřmanım Prof. Dr. Banu DİRİ'ye, konum hakkında tıbbi her türlü yönlendirmeyi yapmaktan kaçınmayan Prof. Dr. Başar BİLGİÇ hocama, veri toplama sürecinde bana yardımcı olan Dr. Zahra Huseynli'ye ok teřekkür ederim. Tezin bařlangıcından bitiş noktasına kadar, iyi ve kötü günümde yanımda olarak beni bu süreçte yalnız bırakmayan niřanlım Berna SOMUNCU'ya ne kadar teřekkür etsem azdır. Beni tüm eğitim hayatı boyunca destekleyen annem, Sevim AKARSU ve babam, Recep AKARSU'ya ok teřekkür ederim.

Ediz AKARSU

İÇİNDEKİLER

KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xv
1 GİRİŞ	1
1.1 Alzheimer Hastalığı	1
1.2 Belirti ve Semptomlar	2
1.2.1 Hafıza	3
1.2.2 Düşünme	3
1.2.3 Karar Verme	3
1.2.4 Kişilik ve Davranışlarda Bozulmalar	4
1.2.5 Korunan Beceriler	4
1.2.6 Kalıtsal Faktörler ve Çevresel Faktörler	4
1.2.7 Alzheimer Hastalığının Nedenleri	4
1.2.8 Risk Faktörleri	5
1.3 Teşhis Yöntemleri	7
1.3.1 Fiziksel ve Nörolojik Testler	7
1.3.2 Nöropsikolojik Testler	7
1.3.3 Beyin Taraması ve Görüntülemesi	7
1.4 Literatür Özeti	8
1.5 Tezin Amacı	11
1.6 Hipotez	12
2 MATERYAL ve YÖNTEMLER	13
2.1 Veri Seti	13
2.1.1 Veri Toplama	13
2.1.2 Veri Dönüştürme ve İşleme	13

2.1.3	Veri Etiketleme	14
2.1.4	Veri Setinin Oluşturulması	14
2.1.5	Metin Temizleme ve Hazırlık	14
2.2	Veri Setinden Öz Nitelik Seçimi	15
2.2.1	Duygu Analizi ile Özellik Çıkartılması	15
2.3	Makine Öğrenmesi Tabanlı Sınıflandırma Algoritmaları	16
2.3.1	Karar Ağaçları	17
2.3.2	Rastgele Orman	17
2.3.3	Naive Bayes	17
2.3.4	Destek Vektör Makinesi	17
2.3.5	K-En Yakın Komşu	18
2.3.6	Parametere Seçimi	18
2.4	Derin Öğrenme Temelli Teknikler	18
2.4.1	Tekrarlayan Sinir Ağları	20
2.4.2	İki Yönlü Kodlayıcı Temsilleri (BERT)	21
2.5	Model Seçimi	21
3	DENEYSEL SONUÇLAR	22
3.1	Ses Dosyasından Yazıya Veri Dönüştürme	23
3.2	Makine Öğrenmesi Algoritmalarıyla Sınıflandırma	23
3.2.1	Performans Metrikleri	24
3.3	Makine Öğrenmesi Deney Sonuçları	25
3.3.1	Kullanılan Öz Nitelikler ve Modelleme Yaklaşımları	25
3.3.2	Karar Ağaçları Sonuçları	27
3.3.3	Rastgele Orman Sonuçları	29
3.3.4	Naive Bayes Sonuçları	31
3.3.5	Destek Vektör Makineleri Sonuçları	33
3.3.6	K=5 En Yakın Komşu Sonuçları	35
3.3.7	K=7 En Yakın Komşu Sonuçları	37
3.3.8	En Başarılı Model	37
3.4	Derin Öğrenme ile Deney Sonuçları	40
3.4.1	LSTM Modelinin Eğitimi ve Sonuçları	40
3.4.2	BERT Modeli	42
3.4.3	BERTürk Modeli	47
3.4.4	SMOTE ile BERT Modeli	54
3.4.5	XLN-RoBERTa Modeli	58
4	SONUÇ	62
	KAYNAKÇA	65



KISALTMA LİSTESİ

ABD	Amerika Birleşik Devletleri
ADDReSS	Alzheimer's Dementia Recognition through Spontaneous Speech
AH	Alzheimer Hastalığı
AVT	Adlandırılmış Varlık Tanıma
BERT	Bidirectional Encoder Representations from Transformers
C	Cinsiyet
CRF	Conditional Random Fields
CT	Computed Tomography
DAS	Duygu Analiz Skoru
DDİ	Doğal Dil İşleme
DKF	Durak Kelime Frekansı
DS	Duraksama Sayısı
DVM	Destek Vektör Makineleri
ED	Eğitim Durumu
GBDT	Gradient Boosting Decision Tree
HBB	Hafif Bilişsel Bozukluk
İsimKS	İsim Kullanım Sıklığı
KA	Karar Ağaçları
KF	Kelime Farklılığı
KYK	K-En Yakın Komşu
MCI	Mild Cognitive Impairment
MRI	Magnetic Resonance Imaging
NB	Naive-Bayes

NEDD	Normalize Edilmiş Duraksama Deęeri
NLP	Natural Language Processing
NN	Neural Network
PET	Pozitron Emisyon Tomografi
RF	Random Forest
RNN	Recurrent Neural Network
RO	Rastgele Orman
SA	Sinir Ağları
SVM	Support Vector Machine
TSA	Tekrarlayan Sinir Ağları
TF-IDF	Term Frequency-Inverse Document Frequency
Y	Yaş
ZamirKS	Zamir Kullanım Sıklığı
ZarfKS	Zarf Kullanım Sıklığı

ŞEKİL LİSTESİ

Şekil 1.1	Ölen Beyin [2]	2
Şekil 1.2	TAU ve Amiloid Proteinleri (M. Scholl. In: Brain connectivity, 2021) [3]	5
Şekil 1.3	Özellikler ve Önem Katsayıları [9]	8
Şekil 1.4	Boston Diyagnostik Afazi Sınavı'ndan Kurabiye Hırsızlığı Resmi	10
Şekil 2.1	Derin Öğrenme Katmanları	19
Şekil 3.1	Veri Seti Korelasyonu	39
Şekil 3.2	Özellik Önem Dereceleri	40
Şekil 3.3	Model Eğitimindeki Kayıp ve Doğruluk Değerlerinin Değişimi . .	46
Şekil 3.4	Eğitim kaybı ve doğruluk değerleri	49
Şekil 3.5	Eğitim Kaybı ve Doğruluk Değerleri (6 Epoch)	52
Şekil 3.6	Eğitim kaybı ve doğruluk oranının epochlara göre değişimi (14 epoch)	53
Şekil 3.7	Eğitim Kaybı ve Doğrulamanın Göre Değişimi (25 Epoch)	55
Şekil 3.8	Eğitim Kaybı ve Doğrulamanın Göre Değişimi	56
Şekil 3.9	XLM-RoBERTa Modeli ile Eğitim ve Doğrulama Kaybı	60

TABLO LİSTESİ

Tablo 1.1	3 modelin performans karşılaştırması	9
Tablo 1.2	Model performans karşılaştırması	11
Tablo 3.1	Test makinesi özellikleri	22
Tablo 3.2	Ddi modelleri ve başarıları	23
Tablo 3.3	Hata/karışıklık matrisi	24
Tablo 3.4	Karar ağaçları doğruluk oranına göre performans	27
Tablo 3.5	Karar ağaçları f1-skoruna göre performans	28
Tablo 3.6	Rastgele orman modeli doğruluk performans sonuçları	29
Tablo 3.7	Rastgele orman modeli f1-skor performans sonuçları	30
Tablo 3.8	Naive bayes modeli doğruluk performans sonuçları	31
Tablo 3.9	Naive bayes modeli f1-skor performans sonuçları	32
Tablo 3.10	Destek vektör makineleri doğruluk performans sonuçları	33
Tablo 3.11	Destek vektör makineleri f1-skor performans sonuçları	34
Tablo 3.12	Kyk-5 modeli doğruluk performans sonuçları	35
Tablo 3.13	Kyk-5 modeli f1-skor performans sonuçları	36
Tablo 3.14	Kyk-7 modeli doğruluk performans sonuçları	37
Tablo 3.15	Kyk-7 modeli f1-skor performans sonuçları	38
Tablo 3.16	Rastgele orman modeli en başarılı f1-skor öz nitelikleri	38
Tablo 3.17	Lstm modeli test sonuçları	42
Tablo 3.18	Bert modeli eğitim ve doğruluk değerleri	45
Tablo 3.19	Bert modeli sınıflandırma raporu	46
Tablo 3.20	Ortalama f1-skoru	46
Tablo 3.21	Türkçe bert modeli eğitim ve doğruluk değerleri	49
Tablo 3.22	Türkçe bert modeli sınıflandırma raporu	49
Tablo 3.23	Ortalama f1-skoru	50
Tablo 3.24	6 epoch eğitim ve validasyon sonuçları	51
Tablo 3.25	6 epoch türkçe bert modeli sınıflandırma raporu	51
Tablo 3.26	Ortalama f1-skoru (6 epoch)	51
Tablo 3.27	14 epoch eğitim ve doğrulama sonuçları	52
Tablo 3.28	14 epoch türkçe bert modeli sınıflandırma raporu	52
Tablo 3.29	Ortalama f1-skoru (14 epoch)	53
Tablo 3.30	Smote olmadan 14 epoch sonuçları	54

Tablo 3.31	Smote ile 14 epoch sonuçları	55
Tablo 3.32	Smote ile 25 epoch sonuçları	55
Tablo 3.33	Eğitim ve doğrulama kaybı ve doğruluğu	60
Tablo 3.34	Xlm-roberta modeli ile sınıflandırma sonuçları	60



SPONTANE KONUŞMADAN ALZHEİMER HASTALIĞI TESPİTİ VE VERİ SETİ OLUŞTURMA

Ediz AKARSU

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Prof. Dr. Banu DİRİ

Bu çalışma, Alzheimer hastalığının tanısı ve evrelerinin tahminlenmesi için özgün bir yaklaşım sunmakta ve gelecek çalışmalara temel olması amaçlanmaktadır. Ana odak, Alzheimer hastalığı tanısı ve evre tahmini için Türkçe veri seti oluşturmak için Alzheimer hastalarının spontane konuşmalarından faydalanılmıştır. Bu veri seti, hastalığın tanı ve evrelerinde kritik öneme sahip olan hastanın dil ve konuşma bozukluklarının analiz edilmesi için kullanılmıştır. Çalışma, klinik test sonuçları veya görüntüleme verileri yerine, doğrudan hastanın konuşma verilerine dayanmaktadır. Alzheimer hastalığıyla ilgili dil özelliklerinin makine öğrenmesi ve derin öğrenme teknikleri kullanılarak nasıl tespit edilebileceğini inceleyen bu çalışma, her iki yöntemin sonuçlarını karşılaştırmalı olarak değerlendirmektedir. Yapılan çalışmanın sonuçlarına göre en yüksek makine öğrenme modeli başarısı Rastgele Orman ve DVM ile %67, en yüksek derin öğrenme modeli başarısı BERTurk ile de %83 elde edilmiştir. Elde edilen bulgular, Alzheimer hastalığının erken tanısında ve evrelerinin belirlenmesinde bu yöntemlerin potansiyel etkinliğini göstermektedir. Ayrıca, bu çalışmanın Türkçe konuşma verileri üzerinden Alzheimer hastalığının incelenmesi için değerli bir kaynak oluşturarak, dil tabanlı tanı yöntemlerinin geliştirilmesine katkı sağlaması düşünülmektedir.

Anahtar Kelimeler: Alzheimer hastalığı, makine öğrenmesi, derin öğrenme, konuşma analizi, Alzheimer hastası konuşma veri seti.

YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ABSTRACT

DETECTING ALZHEIMER’S DISEASE FROM SPONTANEOUS SPEECH AND GENERATING A DATA SET

Ediz AKARSU

Department of Computer Engineering
Master of Science Thesis

Supervisor: Prof. Dr. Banu DİRİ

The paper presents a novel approach for the diagnosis and stage prediction of Alzheimer’s disease and is intended to serve as a basis for future studies. The main focus is on creating a Turkish dataset for Alzheimer’s disease diagnosis and stage prediction. Spontaneous speech of Alzheimer’s patients is used to create this dataset. This dataset was used to analyze the patient’s speech and language disorders, which are critical in the diagnosis and stages of the disease. The study is based directly on the patient’s speech data, rather than clinical test results or imaging data. This study examines how language features related to Alzheimer’s disease can be detected using machine learning and deep learning techniques and comparatively evaluates the results of both methods. According to the results of the study, the highest machine learning model success was 67% with Random Forest and SVM, and the highest deep learning model success was 83% with BERTurk. The findings show the potential effectiveness of these methods in the early diagnosis and detection of Alzheimer’s disease stages. Furthermore, this study is expected to contribute to the development of language-based diagnostic methods by providing a valuable resource for the study of Alzheimer’s disease on Turkish speech data.

Keywords: Alzheimer’s disease, machine learning, deep learning, speech analysis, Alzheimer’s disease patient speech dataset

YILDIZ TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF SCIENCE AND ENGINEERING



Alzheimer hastalığı, günümüz ve yakın gelecekte dikkat edilmesi gereken en önemli hastalıklardan biridir. Hem hasta hem de hasta yakınları açısından yaşamı önemli ölçüde zorlaştıran bu hastalığın henüz bilinen bir tedavisi yoktur. Bununla birlikte, Alzheimer hastalığının takibi büyük önem taşımaktadır. Alzheimer hastalığı, sinisi ve hızlı ilerleyen bir nörodejeneratif hastalık olduğundan, tanı yöntemleri ve evre takibi hastalığın seyri açısından kritik öneme sahiptir. Günümüzde yapılan PET taramaları ve bilgisayarlı görüntüleme raporları ile çok başarılı sonuçlar elde edilse de, bu yöntemler maliyetli olup tekrarlanma sıklığı açısından zaman gerektiren teknolojilerdir. Bu nedenle, dil tabanlı bir hastalık tespiti ve evre takibi büyük bir ihtiyaçtır ve bu alanda yapılacak çalışmalar oldukça değerli olacaktır.

1.1 Alzheimer Hastalığı


Alzheimer Hastalığı (AH), sinir sistemi hücrelerinin ölümüyle birlikte bilişsel yeteneklerin kaybolmasına yol açan nörodejeneratif bir hastalıktır. AH, beyin hücrelerinin dejenerasyonu ve ölümü ile karakterize edilen ilerleyici bir rahatsızlıktır. Aynı zamanda, AH, bireyin bağımsız işlev görme yeteneğini engelleyerek düşünmesini olumsuz etkileyen ve günlük sosyal yeteneklerinde sürekli düşüşe yol açan demansın en yaygın nedenidir.

Davranış bozukluklarına yol açan sendromlara demans denir ve demans vakalarının %60-%80 payını Alzheimer hastaları oluşturur [1].

AH genellikle 65 yaş ve üstü bireylerde görülür. AH olan kişiler, başlangıçta yakın geçmişini unutmaya başlarlar; ilerleyen aşamalarda beyindeki hasar nedeniyle hafıza kaybı, düşünme ve muhakeme yeteneklerinde azalma, yargılama ve karar verme mekanizmalarında zayıflama ortaya çıkar. Bununla birlikte, kitap okuma, dans etme ve şarkı söyleme gibi beceriler genellikle korunur.

AH'nin nedeni tam olarak bilinmemektedir, ancak beyin hücrelerinin düzgün

alışmasını engelleyen bir dizi toksik olayın rol oynadığı düşünölmektedir. Çevresel faktörler (travma, yaş, sigara vb.) ve genetik faktörler (ailede demans öyküsü, ilişkili protein seviyelerinin artması, APOE-e4 gen alelinin varlığı vb.) hastalığın riskini artıran unsurlar arasında yer alır. AH'nin genetik temeli, sinir hücreleri arasındaki iletişim ve haberleşmenin bozulmasına dayanır. Bu bozulmalar, nörofibril yumaklarının (TAU proteinleri) birikmesi ve anormal nöritik plakların (beta-amiloid peptit) oluşmasından kaynaklanır. AH olan hastaların beyin görüntölemelerinde, sağlıklı bireylerin beyin hacimlerine göre hacimsel küçölme gözlemlenir (Şekil 1.1).



Şekil 1.1 Ölen Beyin [2]

AH'nin tespit ve teşhis yöntemleri için birden fazla yöntem kullanılmaktadır. AH'nin erken belirtileri, yakın zamanda yaşanan olayları veya konuşmaları hatırlamamak şeklinde ortaya çıkabilir. AH ilerledikçe, AH'den muzdarip kişi hatırlaması gereken ve beklenen davranışları dahi unutacaktır. Bu durumda AH sahip bireyin günlük yaşantısını olumsuz etkileyecektir.

1.2 Belirti ve Semptomlar

AH'nin en belirgin belirtisi hafıza kaybıdır. Hastalığın erken dönemlerinde bireyler genellikle yakın geçmişte yaşananları hatırlamakta zorlanırlar. Hastalığın ilerleyen dönemlerinde ise hafıza sorunları artar ve AH'nin diğer belirtileri ortaya çıkar.

Başlangıçta, AH'li bireyler hatırlama ve düşüncelerini organize etme konusunda zorluk yaşayabilir. Çoğu zaman bireyin kendisi bu değişikliklerin farkında olmayabilir ve genellikle bir aile üyesi veya arkadaş bu semptomların kötüleştiğini

ilk fark eden kiři olur.

1.2.1 Hafıza

Herkes zaman zaman bir řeyleri unutabilir; örneęin telefonunu nereye koyduęunu unutmak veya bir tanıdığın adını hatırlayamamak normaldir. Ancak, Alzheimer hastalığı ile ilişkili hafıza kaybı kalıcıdır ve zamanla kişinin iş veya evdeki görevlerini yerine getirme yeteneğini ciddi řekilde olumsuz etkiler. Alzheimer hastalarında karşılaşılan bazı hafıza kayıpları:

- Yakın zamandaki konuşmaları, sözleri ve buluşmaları unutabilir.
- Konuşmaları tekrar tekrar anlatabilir.
- Eşyalarını sıklıkla yanlış yerlere koyabilir ve bunları mantıksız yerlerde bulabilir.
- Bildiğı yerlerde yolunu kaybedebilir.
- Zamanla akraba, arkadaş ve kullandığı eşyaların isimlerini unutmaya başlayabilir.
- Doğru kelimeleri bulmakta, düşüncelerini ifade etmekte veya konuşmalara katılmakta zorlanabilir.

1.2.2 Düşünme

AH, özellikle matematik gibi soyut kavramlar üzerinde yoğunlaşmayı ve düşünmeyi zorlaştırabilir. Hastalar için birden fazla görevi aynı anda yapmak oldukça zor olabilir ve özellikle finansal işlemleri yönetmek, çek defterini dengelemek ve faturaları zamanında ödemek gibi konularda güçlükler yaşayabilirler. Karşılaşılan bu tür zorluklar ile yaşantılarını sürdürmede farklı sorunlara yol açabilir.

1.2.3 Karar Verme

Alzheimer hastaları günlük yaşamlarında uygun kararlar alma ve doğruyu seçme yeteneklerinde azalma yaşayabilir. Örneęin, sosyal hayatlarında yanlış ya da uygun olmayan seçimler yapabilir, yağmurlu bir havada şemsiye almayabilir, mutfakta yemek yaparken unutkanlık veya araba kullanırken karşılaşılan beklenmedik durumlara uygun řekilde tepki verememe gibi günlük problemlerle baş etmekte zorlanabilirler.

1.2.4 Kişilik ve Davranışlarda Bozulmalar

AH'nin beyinde yarattığı değişiklikler ve bozulmalar kişinin psikolojisini ve hareketlerini etkileyebilir. Bu tür durumlarda hastalarda; ilgisizlik, depresiflik, sosyalleşmeden kaçınma, sinir, ani davranış değişimleri, saldırganlık, güven kaybı, sanrılar görme gibi davranış bozuklukları gözlemlenebilir.

1.2.5 Korunan Beceriler

Bazı beceriler, semptomlar kötüleşse bile, uzun süre korunabilir. Bunlar:

- Şarkı söylemek
- El işi, nakış yapmak
- Kitap okumak
- Hikaye anlatmak
- Müzik dinlemek
- Dans etmek
- Resim çizmek

Bu yeteneklerin AH bireylerde korunması, bu beceri ve yeteneklerin beyinin farklı bölgeleri tarafından kontrol edilmesinden kaynaklıdır.

1.2.6 Kalıtsal Faktörler ve Çevresel Faktörler


Doktorlar ve araştırmacılar, AH'nin zamanla beyin hücrelerinin deformasyonuna sebep olan kalıtsal özellikler, yaşam standartları ve diğer dış etkenlerden kaynaklandığı düşünülmektedir. Ancak, hastalığın neden olduğu genetik değişikliklerin %1'den daha az bir oranda görüldüğü ve bu değişikliklerin kişinin hastalığı geliştirmesini neredeyse garanti ettiği bilinmektedir. Bu etkenler de hastalığın erken yaşlarda ortaya çıkmasına sebep olabilir.

1.2.7 Alzheimer Hastalığının Nedenleri

AH beyin ve sinir hücrelerinin işleyişinin bozulmasına sebep olan, beyin proteinleri ile ilgili problemlerden kaynaklanır. Sinir hücrelerinin zarar görmesi, birbirleriyle olan iletimlerini kaybetmesi ve beslenemeyerek ölmesi olabilir. Bu hasarlar, hafızayı kontrol eden beyin bölgelerinde başlar ve ilk belirtiler ortaya çıkmadan

yıllar önce sürecin başladığı anlaşılr. Hastalık ilerledikçe sinir hücrelerinin kaybı beyin tüm bölgelerine yayılır ve ileri evrelerde beyin hacimsel olarak küçülür.

Araştırmacılar, hastalık üzerinde etkili olduğu düşünölen iki ana protein üzerine yoğunlaşmışlardır: beta-amiloid ve tau proteinleri (Şekil 1.2). Beta-amiloid, daha büyük proteinlerin parçalanması sonucu oluşur ve bunların toplanarak sinir hücreleri üzerinde toksik etki yaratan kümeler oluşturur. Bu kümeler, amiloid plaklar olarak adlandırılan büyük öbeklenmelere dönüşür. Tau proteinleri ise sinir hücrelerinin iç taşıma ve iletim sistemlerinde rol oynar. AH'de, tau proteinleri anormal şekilde katlanır ve nörofibriller yumaklar olarak adlandırılan yapılar oluşur, bu yapılarda sinir hücrelerinde iletim sistemini bozar ve hücreler zamanla işlevini kaybederek öölürler.



Şekil 1.2 TAU ve Amiloid Proteinleri (M. Scholl. In: Brain connectivity, 2021) [3]

1.2.8 Risk Faktörleri

1.2.8.1 Cinsiyet

Alzheimer hastalığının risk faktörlerini değerlendirirken, cinsiyetin önemli bir belirleyici olduğu gözlemlenmektedir. Kadınlar, yaşamları boyunca Alzheimer hastalığına yakalanma riski açısından daha yüksek bir profilde bulunmaktadır. Kadınların, Alzheimer hastalığına yakalanma riski erkeklere oranla daha yüksektir [4].

1.2.8.2 Yaş

AH'nin bilinen en büyük risk faktörü yaştır. Artan yaş ile AH yakalanma riski de artmaktadır. Her ne kadar AH normal yaşlanmanın bir parçası olmasa da, yaş ilerledikçe hastalığa yakalanma olasılığı artar. Örneğin, Amerika Birleşik Devletleri'nde 2011 yılı itibarıyla yapılan çalışmada 65 yaş ve üzeri bireyler

arasında 4,5 milyon Alzheimer vakası tespit edilmiştir. Bu vakaların yaş gruplarına göre dağılımı ise şu şekildedir: 65-74 yaş aralığında 700 bin, 75-84 yaş aralığında 2,3 milyon ve 85 yaş üstünde 1,5 milyon [5]. 2050 yılına ilişkin projeksiyonlar, ABD’de Alzheimer hasta sayısının 13,8 milyona yükselmesini öngörmektedir. Global ölçekte ise bu rakamın 100 milyonu aşması beklenmektedir. AH’nin 65 yaş üzeri bireylerdeki global prevalans oranı %4,7 olarak belirlenmiştir. Bölgesel farklılıklar göz önünde bulundurulduğunda, Afrika’da %2,6, Asya’da %4, Avrupa’da %6,2 ve Amerika Birleşik Devletleri’nde %6,9 olarak tespit edilmiştir [6]. Hastalığın insidansı yaş ile doğru orantılı olarak artmakta olup, 60 yaş üstü bireylerde her on yıl sonunda insidans oranı iki katına çıkmaktadır.

İstanbul, Kadıköy’de gerçekleştirilen ve Türkiye’den ilk geniş kapsamlı çalışma olarak kabul edilen "Turkish Alzheimer’s Prevalence Study (TAPS)" adlı çalışmada, 70 yaş ve üzeri bireylerde demans yaygınlığı %20, AH yaygınlığının ise %16 olduğu belirlenmiştir. Bu sonuçlar, Türkiye’nin demografik yapısına uyarlandığında, ülkede yaklaşık 300.000 ile 350.000 arasında Alzheimer hastası olduğu tahmin edilmektedir. Bu çalışma, AH’nin Türkiye’deki yaygınlığını anlamak adına önemli bir veri sağlamaktadır ve bu tür çalışmalar, sağlık politikalarının şekillendirilmesi ve kaynakların doğru alanlara yönlendirilmesi açısından kritik öneme sahiptir [7].

Yaş faktörlerinin yanında ailede AH öyküsü bulunan bireylerde hastalığa yakalanma olasılığı daha yüksektir.

1.2.8.3 Hafif Bilişsel Bozukluk

Hafif Bilişsel Bozukluk (HBB) normal yaşlanma ve demans arasındaki klinik bir durumu temsil eder. HBB hafızada veya diğer zihinsel becerilerinde yaşa göre beklenenden daha büyük düşüşler yaşanmasını ifade eder ve bu durum kişinin sosyal veya işlevsel yaşamını doğrudan etkilemez. Ancak, HBB olan kişilerde demans geliştirme riski artar. Özellikle, HBB’nin öncelikli belirtisi hafıza kaybı ise, Alzheimer’a bağlı hastalığa ilerleme ihtimali daha yüksektir. HBB teşhisi alan bireyler, yaşam tarzı değişiklikleri yaparak ve düzenli sağlık kontrolleriyle hastalığın ilerlemesini takip edebilirler.

1.2.8.4 Yaşam Standardı ve Kalp Hastalıkları

Yaşam standartları ve kalp sağlığı AH’yi doğrudan etkileyen risk faktörleri olmasa da, benzer risklerin AH’ye yakalanma ihtimalini artırdığı gözlemlenmiştir. Bu risklere sebep olacak faktörler:

- Hareket eksikliği
- Obezite
- Tütün ve tütün grubu ürünleri kullanmak, kullanılan ortamlarda bulunmak
- Diyabet
- Tansiyon
- Sağlıksız beslenme

Yaşam standartlarını iyileştirmek, düzenli spor yapmak, sağlıklı beslenmek, diğer kalp hastalıklarına yakalanma riskini düşürdüğü gibi AH riskini de düşürür.

1.3 Teşhis Yöntemleri

AH'nin teşhisi genellikle bireyin ve yakın çevresinin gözlemleri ile başlar. Bu aşamadan sonra, doktora başvurulmalıdır. AH'ye sahip bireyin aile fertleri ve yakın çevresince bu gözlem devam eder. Bu sürecin devamında doktorlar tarafından yapılan hafıza ve düşünme becerilerinin değerlendirilmesini içeren testlerle desteklenir.

1.3.1 Fiziksel ve Nörolojik Testler

AH tespitinde, hastanın sinir sistemini test eden bir dizi testler uygulanır. Refleks, kas gücü, koordinasyon, duyu kaybı ve denge gibi faktörler takip edilir.

1.3.2 Nöropsikolojik Testler

AH bireyin zihinsel durumunu test eden, düşünme becerilerini ve hafızayı değerlendirmek için kapsamlı testler doktorlar tarafından yapılmaktadır. Sonuçlar benzer yaş grupları ile karşılaştırılmaktadır. Ayrıca hastalığın takibinde bu testlerin sonuçları bir başlangıç noktası olarak kabul edilir.

1.3.3 Beyin Taraması ve Görüntülemesi

Beyin taraması ve görüntülemesinde Manyetik Rezonans Görüntülemesi (MRI) ile beynin ayrıntılı görüntüleri elde edilerek, beynin hacmen küçülüp küçülmediği izlenir. Bu yöntem tanı koymak için sadece ilk adımdır. X ışınları ile beynin kesit görüntülerini alan Pozitron Emisyon Tomografisi (PET taraması) ile de kana düşük seviyeli radyoaktif madde verilerek Amiloid PET ölçümü ile olağan dışı miktar

ölçümlenir. Hastada birikim miktarı fazla ise demans teşhisi konularak hastalığın hangi evrede olunduğunun teşhisi yapılır.


Bu hastalığın doğal seyrinde yedi farklı aşama tanımlanmıştır: Dışarıdan normal (klinik öncesi), çok hafif bozukluk, hafif bozukluk, orta dereceli bozukluk, orta ciddi bozukluk, ciddi bozukluk, çok ciddi bozukluk.

"Dışarıdan normal (klinik öncesi)", hastalığın hasta ve hekim tarafından bilinmesinden çok öncesine aittir. "Çok hafif bozukluk" ve "hafif bozukluk" birleştirilerek hafif bilişsel bozukluk olarak da tanımlanabilir [8]. Bu çerçevede çalışmamızda bilişsel bozukluk olan hastaları Evre 1 olarak etiketlendirdik. "Orta dereceli bozukluk" Evre 2, "Orta ciddi bozukluk" Evre 3, "Ciddi bozukluk" ile "Çok Ciddi bozukluk" birlikte Evre 4 olarak etiketlenmiştir.

1.4 Literatür Özeti

Bu konuda henüz Türkçe dilinde yapılmış bir çalışma ve veri seti yoktur. Bu kapsamda İngilizce dilinde ADReSS veri seti ile yapılan çalışmalar mevcuttur.

Aradhana Soni'nin "Alzheimer Hastalığını Tespit Etmek İçin Fiil Akıcılığı, Doğal Dil İşleme ve Makine Öğrenimini Kullanma" çalışmasında hassas nöropsikolojik test sonuçlarından faydalanılmış, Rastgele Orman (RO), Sinir Ağları (SA), Tekrarlayan Sinir Ağları (TSA) ve Doğal Dil İşleme (DDİ) metotlarını kullanmıştır. DDİ ve TSA ile %67, Rastgele Orman ile de %76 başarı elde etmiştir [9]. Çalışmada seçilen özellikler ve özelliklerin katsayıları Tablo 1.3 de gösterilmiştir.



Şekil 1.3 Özellikler ve Önem Katsayıları [9]

RO kullanılarak yapılan çalışma öncesinde detaylı bir veri ön işlemesi yapılmıştır.

Çalışmanın ilerleyen aşamasında makine öğrenmesi ve derin öğrenme model değerlendirilmesinde; dilin anlam ve yapı özellikleri üzerinden çıkarılan özellikler kullanılarak sonuçlar elde edilmişlerdir [9]. Farklı modeller üzerinde çalışılmış olup, RO, TSA ve SA kullanılmıştır. Bu çalışmanın sonuçları Tablo 1.1 de gösterilmiştir.

Tablo 1.1 3 modelin performans karşılaştırması

	RO	SA	TSA
Doğruluk	%76,00	%68,89	%66,67
F1 Skoru	%71,40	%66,10	%71,88
AUC	%75,00	%69,00	%60,00

Adam Ševčík ve arkadaşları bir başka çalışmalarında [10] AH'nın sebepleri ve tanısı üzerine olan çalışmalara yoğunlaşmışlar ve bu kapsamdaki bir çok çalışma ile veri setlerinin incelemesi yapılmıştır. Bunun sonucunda var olan veri setlerinden "ADReSS", "PITT", "CCC" [11] veri setlerinin en başarılı sonuçlarda kullanılan veri setleri olduğu çıkarımına ulaşılmıştır. Bunların yanında yaş dağılımı, cinsiyet gibi demografik etkenler ve AH tanısı için en uygun algoritmaların seçilimi konusuna da yer verilmiştir.


"Konuşmaya Dayalı Alzheimer Hastalığının Tahmini için Önceden Eğitilmiş ve Özellik Tabanlı Modellerin Karşılaştırılması" başlıklı çalışmada [12] ön eğitilmiş DDİ modellerinden "BERT" modeli kullanılmış ve makine öğrenmesi yöntemlerinden özellik seçimi ile farklı algoritmaların sonuçları karşılaştırılarak değerlendirilmiştir. Bu çalışmada DVM %81, ön eğitilmiş BERT modelinde ise %83 başarı oranları yakalanmıştır. Bu çalışmanın sonuçları Tablo 1.2 te gösterilmiştir.

Spontane konuşma kayıtlarının doğal dil işleme teknikleri kullanılarak ön eğitilmiş modeller ile de çalışmalar yapılmıştır [13]. Önceki çalışmalara ek olarak erken tanı üzerine yoğunlaşmıştır. "ADReSS" veri setinin yanında "Kurabiye Hırsızı" [14] görselinin yorumlanması ile elde edilen transkriptler işlenmiştir. Görsel Şekil 1.4 da gösterilmiştir.

TF-IDF (Term Frequency-Inverse Document Frequency) vektörleri DVM modeliyle işlenmiş ve elde ettikleri sonuçları ön eğitilmiş DDİ modelleri ile kıyaslayarak sonuçları incelemişlerdir. Çalışmalarda elde ettikleri en başarılı iki model listelenmiştir: En başarılı iki model:

Model 1

- **Model:** Hasta+Hekim / DistilRoBERTa



Şekil 1.4 Boston Diyagnostik Afazi Sınavı’ndan Kurabiye Hırsızlığı Resmi

- **Doğruluk :** %87
- **Kesinlik :** %89
- **Geri Çağırma:** %82
- **F1 Skoru :** %85

Model 2

- **Model:** Hasta+Hekim / DistilBERT
- **Sınıf AH Olmayan:**
 - **Kesinlik:** %83
 - **Geri Çağırma:** %79
 - **F1 Skoru:** %81
 - **Doğruluk:** %81
- **Sınıf AH Olan:**
 - **Kesinlik:** %80
 - **Geri Çağırma:** %83
 - **F1 Skoru:** %82
 - **Doğruluk:** %81

Tablo 1.2 Model performans karşılaştırması

Model	Özellik Sayısı	Doğruluk	Kesinlik	Geri Çağırma
Önceki Çalışma	–	%75,00	–	–
DVM	10	%81,25	%80,00	%83,33
SA	10	%77,08	%76,71	%77,78
RO	50	%75,69	%80,33	%68,06
NB	80	%72,92	%78,95	%62,50
BERT	–	%83,32	%83,89	%83,33

"Alzheimer Hastalığında Sözel Akıcılık Becerilerinin İncelenmesi" çalışması Türkçe dili kullanılarak yapılmış ilk çalışmadır [15]. AH olan bireyler ile olmayan bireylere sözel akıcılık testleri uygulanarak niteliksel ve niceliksel sonuçlar kıyaslanarak sonuçlar elde edilmiştir [16]. Niceliksel sonuçlar: toplam kelime sayısı; Niteliksel sonuçlar: öbekleme ve kelimeler arası geçişler olarak incelenmiştir. Bu çalışma kapsamında sözel akıcılık testleri, fononik akıcılık testi, semantik akıcılık testi kontrol grubu ve Alzheimer hastaları arasında ayırt edici sonuçlar ortaya çıkartmıştır.

1.5 Tezin Amacı

AH, küresel olarak milyonlarca insanı etkileyen, ilerleyici ve geri dönüşümsüz bir nörodejeneratif hastalıktır. Bu hastalığın en belirgin özelliği, hafıza kaybı ve bilişsel işlevlerin azalmasıdır. AH'nın henüz kesin bir tedavisi bulunmamakta ve mevcut tedavi yöntemleri yalnızca semptomları hafifletmeye odaklanmaktadır. Bu nedenle, erken tanı, hastalığın ilerlemesini yavaşlatmak ve yaşam kalitesini iyileştirmek için kritik önem taşımaktadır.

2020 yılı itibari ile dünya genelinde 55 milyondan fazla hasta mevcut ve 2030'da 79 milyonu, 2050 yılında ise 139 milyonu geçmesi tahmin edilmektedir [3].

Hastalık tanısı konulmuş kişilerin, hastalık seviyesinin takibi önemlidir. Bu süreçte sürekli MRI veya PET taraması ile beyin görüntüleme yöntemlerine başvurulması hastanın radyasyona ve radyoaktif maddeye maruz kalması anlamına gelmektedir.

Bu çalışmanın temel amacı, AH'nin erken tanı, tanı sonrası hastalığın takibi ve evrelerin takibi konusunda dil ve konuşma analizinin potansiyelini araştırmaktır. Alzheimer hastalarında dil kullanımındaki değişiklikler, hastalığın erken belirtileri ve evrelerin tespiti arasında yer alabilir. Bu çalışma, Türkçe konuşan Alzheimer hastalarının spontane konuşma verilerini analiz ederek, makine öğrenmesi ve derin öğrenme yöntemleriyle bu erken belirtilerin tespit edilmesine ve hastalığın

evrelerinin belirlenmesine odaklanmaktadır. Bu yaklaşım, erken tanı koymada ve hastalığın evresinin belirlenmesinde yeni bir yol açabilir, hastalığın takibi sürecinde ve AH'nin yönetimi için yeni stratejilerin geliştirilmesine katkı sağlayabileceği düşünülmektedir.

1.6 Hipotez

- Türkçe konuşan Alzheimer hastalarının spontane konuşma verilerinin makine öğrenmesi ve derin öğrenme teknikleri kullanılarak analizi, hastalığın erken tespitinde ve hastalık süreçlerinin izlenmesinde geleneksel görüntüleme yöntemlerine (MRI ve PET) kıyasla daha etkili bir yöntem sunabilir.
- Bu analiz, hastalığın erken evrelerinde dil kullanımındaki değişiklikleri belirleyebilir ve bu belirtiler hastalığın ilerleyişini göstermede kullanılabilir.
- Bu yaklaşım, AH'nin erken tanısı için yeni bir ölçümlenebilir değişken olabilir.
- Alzheimer hastalarının sık sık maruz kaldığı radyasyon ve radyoaktif madde etkileşimini azaltabilir.
- Oluşturulan veri seti ileri ki çalışmalarda Türkçe dili için referans noktası olarak kullanılabilir.

2 MATERYAL ve YÖNTEMLER

Yapılan çalışmada, dil tabanlı bir sistem modeli üzerinde çalışmamızın yürütülmesi planlanmış olup, kullanılan veri seti ve materyaller bu bölümde detaylı bir şekilde açıklanmıştır.

2.1 Veri Seti

2.1.1 Veri Toplama

Bu çalışma, Etik Kurul onayı ile İstanbul Üniversitesi Tıp Fakültesi Nöroloji Anabilim Dalı çalışma ekibi tarafından bilgilendirilmiş onam formu alınan toplam 61 hasta verisi üzerinde gerçekleştirilmiştir. Çalışma için etik kurul onayı, İstanbul Üniversitesi İstanbul Tıp Fakültesi Klinik Araştırmalar Etik Kurulu tarafından 02 Kasım 2023 tarihli ve 2227481 sayılı kararla verilmiştir. Hastalara, Şekil 1.4 daki "Kurabiye Hırsız" adlı görselin incelenmesi ve bu görselde gördüklerini detaylı bir şekilde anlatmaları istenmiştir. Elde edilen konuşma kayıtları, çalışmanın veri setinin temellerini oluşturmuştur.

2.1.2 Veri Dönüştürme ve İşleme

Alzheimer hastalarının konuşmalarını içeren ".mov" formatındaki video dosyalarından ses verilerini çıkarmak için FFmpeg[17] yazılımı kullanılmıştır. Bu süreçte ses dosyası ".wav" formatına dönüştürülmüştür. Bu yöntemle, çalışma için gerekli ses verileri verimli ve kaliteli bir şekilde elde edilmiştir. Ardından, bu ses dosyaları DDİ metodları ve Hugging Face platformundaki ön eğitilmiş modeller kullanılarak metin formatına çevrilmiştir. Türkçe dili için hazırlanmış olan ön eğitilmiş birden fazla model test edilmiş ve çıktıları karşılaştırılmıştır. Sesten yazıya dönüşüm sonucunda elde edilen metin dosyalarının kontrollerde yetersiz ve başarısız olması sebebiyle, tüm kayıtlar tekrardan detaylı bir şekilde yeniden dinlenilmiş ve insan müdahalesi ile doğrulama ve gerekli düzeltmeler metin dosyaları üzerinde yapılmıştır. Bu çalışmanın asıl amacı doğru ve temiz veri

elde etmek olduğundan sesten yazıya dönüştürme işleminde kullanılan yöntemlerin iyileştirilmesi için ayrıca bir efor sarf edilmemiştir.

2.1.3 Veri Etiketleme

Hastaların AH'nın hangi evresinde olduğu, alanında uzman doktorlar tarafından değerlendirilmiş ve bu bilgiler araştırma ekibiyle paylaşılmıştır. Bu evre bilgileri, veri setinin etiketlenmesinde temel kriter olarak kullanılmıştır.

2.1.4 Veri Setinin Oluşturulması

Veri setini oluşturan her hasta için ayrı ayrı dosyalar oluşturulmuş ve hastaların metin dosyaları "text" (.txt) formatında, etiketlenmiş olduğu evre dizinin altında dosya olarak saklanmıştır. Gizlilik ve etik kuralları gereği, tüm kişisel bilgileri gizlenmiş ve her bir hastaya eşsiz bir tanımlayıcı numara atanmıştır. Bu numara ile hastaların eğitim durumu, cinsiyet ve yaşı gibi hastanın demografik verileri ayrı bir dosyada saklanmıştır. Hastalardan 36 tanesi kadın, 25 tanesi erkektir, eğitim durumunda ise yoğunluk ilköğretim mezunu sayıdadır. 15 hasta 65 yaşından küçük, 46 hasta ise 65 yaşından büyüktür.

Çalışma, hastalığın farklı evrelerindeki hastaları içermektedir; bunlar arasında 1., 2., ve 3. evre hastalar bulunmaktadır. Ancak, ileri evre olarak kabul edilen 4. evredeki hastaların hastaneye getirilme sıklığı oldukça düşük olduğundan, elimizde yeterli sayıda 4. evre hasta verisi bulunmamaktadır. Bu durum, veri setimizin dengesizliğine yol açmakta ve modelimizin doğruluğunu olumsuz etkilemektedir. Bu nedenle, çalışmada 4. evre hasta verilerini dahil etmeme kararı alınmıştır. Dolayısıyla, analizlerimiz ve sonuçlarımız, 1., 2., ve 3. evre hastalar üzerine odaklanmaktadır.

Metin verisinden ise; duraksama sayısı, duraksama sayısının metin uzunluğuna göre oranı, durak kelime frekansı, kelime çeşitliliği, zarf, zamir, isim kullanma sıklığı ve metnin duygusal analiz değerleri olmak üzere 8 özellik seçilmiştir.

2.1.5 Metin Temizleme ve Hazırlık

Metinlerin analiz sürecini kolaylaştırmak için tüm içerik küçük harfe dönüştürülmüş ve duraksama anlamına gelen "..." ifadesi, "threedot" şeklinde özel bir kelime ile değiştirilmiştir. Ayrıca, metinlerden tüm noktalama işaretleri temizlenmiştir. Sonrasında, bu temizlenmiş metinler, demografik veriler ile eşleştirilerek son veri seti oluşturulmuştur. Eksik demografik veriler, veri setindeki

ortalama deęerler veya en sık kullanılan parametrelerle tamamlanmıřtır.

2.2 Veri Setinden Öz Nitelik Seçimi

Bu aşamada, Alzheimer hastalarının konuşma analizi için ilk olarak, hastaların konuşma metinlerindeki kelime çeşitlilięi incelenmiřtir. Bu, dilin zenginlięi ve biliřsel işlevlerdeki potansiyel deęişiklikleri yansıtan önemli bir göstergedir. Ardından, 'threedot' olarak işaretlenmiř duraksamayı ifade eden kelime sayıları ve bunların normalize edilmiř deęerleri hesaplanmıřtır. Bu durum, konuşma akıřındaki deęişiklikleri ve düşünce süreçlerindeki potansiyel bozulmaları belirlemek için kullanılmıřtır.

Daha sonraki adımda, metinlerdeki durak kelimelerin frekansı ve bunların normalizasyon sonuçları analiz edilmiřtir. Bu analiz, konuşma içerięinin derinlięini ve yapısal karmařıklıęını deęerlendirmek için önemlidir.

Ayrıca, Türkçe kelimelerin köklerini çıkartmak için hem Natural Language Toolkit (NLTK) hem de Zemberek kütüphaneleri kullanılmıřtır. Bu kütüphaneler, dilbilimsel yapıların ve sözcüklerin daha detaylı incelenmesine olanak tanımıřtır. Bu iki kütüphane ile yapılan işlemlerden sonra çıkan sonuçların %99 oranında benzerlik göstermesi sebebiyle model eęitiminde yalnızca NLTK sonuçları kullanılmıřtır.

2.2.1 Duygu Analizi ile Özellik Çıkartılması

Önemli bir dięer adım ise, ön eęitimli dil modelleri kullanarak yapılan duygu analizidir. Bu analiz, hastaların konuşmalarındaki duygusal tonlamaları tespit etmek ve bunları -1 ile +1 arasında normalize ederek deęerlendirmek için geręekleştirilmiřtir. Bu analiz yapılırken Hugging Face açık kaynaklı modellerden yararlanılmıřtır. Kullanılan model, "savasy/bert-base-turkish-sentiment-cased" modelidir [18]. Bu model, Türkçe metinlerde duygu analizi yapmak üzere önceden eęitilmiřtir.

Model ve tokenizer, Hugging Face kütüphanesi kullanılarak yüklenmiřtir. Hastaların konuşma metinleri, tokenizer aracılıęıyla işlenmiř ve modelden geęirilen metinlerin duygu skorları hesaplanmıřtır. Duygu skorları, negatif ve pozitif olmak üzere iki etiket üzerinden deęerlendirilmiřtir. Skorlar softmax fonksiyonu kullanılarak normalize edilmiř ve -1 ile +1 arasında bir deęer alacak řekilde ayarlanmıřtır. Negatif etiketli skorlar -1 ile çarpılarak negatif deęerler elde edilmiřtir.

Bu analiz, Alzheimer hastalarının duygusal ifade biçimlerindeki potansiyel değişiklikleri ortaya çıkarmak için kritik bir ölçümdür. Duygu analizi sonuçları, hastaların konuşmalarındaki duygusal tonlamaların değerlendirilmesi için kullanılmıştır.

Son olarak, elde edilen bu özellikler, demografik bilgilerle birleştirilerek, model eğitimi için kullanılacak olan son veri çerçevesi (dataFrame) oluşturulmuştur. Bu entegrasyon, hastaların demografik özelliklerinin, konuşma ve dil kullanımındaki varyasyonlarla nasıl ilişkilendirildiğinin anlaşılmasına katkıda bulunmuştur.

2.3 Makine Öğrenmesi Tabanlı Sınıflandırma Algoritmaları

Makine öğrenmesi algoritmaları, eğitim verilerini kullanarak öğrenme sürecini gerçekleştirir ve yeni verileri doğru bir şekilde sınıflandırmak ya da tahmin etmek için tasarlanmıştır. Bu algoritmalar, yapısal veya yapısal olmayan verilerle eğitilebilir ve temel amacı, öğrendikten sonra karşılaştıkları yeni verileri doğru kategorilere yerleştirebilmektir. Sınıflandırma algoritmaları genellikle iki temel kategoriye ayrılır: "İkili Sınıflandırma", iki olası sonuç arasında ayrım yaparken; "Çoklu Sınıflandırma" birden fazla olası sonucu değerlendirir. Eğitici sınıflandırma algoritmaları dört ana grupta incelenebilir: "Mantıksal Öğrenme Algoritmaları", "Destek Vektör Makineleri", "İstatistik Tabanlı Algoritmalar" ve "Tembel Öğrenme Algoritmaları". P. C. Sen ve arkadaşlarının yürüttüğü bir araştırmada, karar ağaçları gibi mantıksal öğrenme algoritmalarının sınıflandırma hızı ve doğruluk konusunda diğer yöntemlere göre daha üstün olduğu bulgusu elde edilmiştir [19]. Bu tezde, sınıflandırma problemleri için özellikle Karar Ağaçları ve Rastgele Orman gibi algoritmalar başarıyla kullanılmıştır. Bunun yanı sıra, Naive Bayes, Destek Vektör Makinesi, K-En Yakın Komşu gibi çeşitli makine öğrenmesi teknikleri de kullanılmıştır ve bunların sınıflandırma performansları karşılaştırmalı olarak analiz edilmiştir. Ayrıca, bu tezde derin öğrenme yöntemlerinden Tekrarlayan Sinir Ağları ve ön eğitilmiş modeller arasında yer alan İki Yönlü Kodlayıcı Temsilleri (BERT) modeli de kullanılmıştır. Bu modern ve gelişmiş teknikler, geleneksel makine öğrenmesi algoritmalarıyla karşılaştırıldığında farklı veri yapıları ve karmaşık problemler üzerinde nasıl bir performans sergiledikleri detaylıca ele alınmıştır. Böylece, tez kapsamında geniş bir algoritma yelpazesinin etkinlik ve verimlilik açısından değerlendirilmesi sağlanmıştır.

2.3.1 Karar Ağaçları

Karar ağacı sınıflandırıcıları, veri sınıflandırması konusunda en yaygın kullanılan yöntemlerden biri olarak kabul edilir. Bu yöntemler, çeşitli disiplinlerden araştırmacılar tarafından geniş bir uygulama yelpazesinde kullanılmaktadır. Özellikle, makine öğrenmesi, desen tanıma ve istatistik alanlarında kullanılmaktadır. Karar ağaçları, tıbbi hastalık analizleri, metin sınıflandırma, görüntü işleme gibi farklı uygulama alanlarına kadar geniş bir kullanım alanına sahiptir[20].

2.3.2 Rastgele Orman

2001 yılında L. Breiman tarafından önerilen Rastgele Orman algoritması, genel amaçlı bir sınıflandırma ve regresyon yöntemi olarak büyük bir başarı elde etmiştir. Çeşitli rastgeleleştirilmiş karar ağaçlarını bir araya getirerek onların tahminlerini ortalamalarını alarak birleştiren bu yaklaşım, gözlem sayısının değişken sayısından çok daha fazla olduğu durumlarda mükemmel performans göstermiştir. Ayrıca, büyük ölçekli problemlere uygulanabilecek kadar esnek olan bu yöntem, çeşitli özel öğrenme görevlerine kolayca uyarlanabilir ve değişken önemlilik ölçüleri sağlar[21].

2.3.3 Naive Bayes

Naive Bayes, sınıflandırma için en iyi bilinen veri madenciliği algoritmalarından biridir. Sınıf göz önüne alındığında tüm niteliklerin birbirinden bağımsız olduğu varsayımına dayanarak yeni bir örneğin bir sınıfa ait olma olasılığını çıkarır. Bu varsayım, eğitim verilerinden çok değişkenli olasılıkları tahmin etme ihtiyacından kaynaklanmaktadır. Pratikte, öznelilik değerlerinin çoğu kombinasyonu ya eğitim verilerinde mevcut değildir ya da yeterli sayıda mevcut değildir. Sonuç olarak, her bir ilgili çok değişkenli olasılığın doğrudan tahmini güvenilir olmayacaktır. Naive Bayes, koşullu bağımsızlık varsayımıyla bu çıkmazı aşar. Bu katı bağımsızlık varsayımına rağmen, Naive Bayes birçok gerçek dünya uygulamasında gerçekten yetkin bir sınıflandırıcıdır [22].

2.3.4 Destek Vektör Makinesi

Son yıllarda, Destek Vektör Makineleri (DVM) ve bunların çeşitli bilim alanlarındaki uygulamaları üzerine muazzam miktarda araştırma yapılmıştır. DVM'ler, birçok uygulama alanında en güçlü ve sağlam sınıflandırma ve regresyon algoritmalarından biridir. DVM, araştırmacılar arasında son derece popüler ve aktif bir araştırma alanı olan örüntü tanımadaki önemli bir rol oynamaktadır. DVM'lerin

iyi performans göstermediği bazı alanlardaki araştırmalar, büyük veri setleri için DVM, çoklu sınıflandırma için DVM ve dengesiz veri setleri için DVM gibi diğer uygulamaların geliştirilmesini teşvik etmiştir. Ayrıca DVM, sınıflandırma yeteneğini geliştirmek ve parametreleri optimize etmek için evrim algoritmaları gibi diğer gelişmiş yöntemlerle entegre edilmiştir. DVM algoritmaları, çeşitli bilimsel ve mühendislik alanlarındaki araştırma ve uygulamalarda tanınırlık kazanmıştır[23].

2.3.5 K-En Yakın Komşu


K-En Yakın Komşu (KYK) algoritması, veri madenciliğinde etkili bir denetimli sınıflandırma tekniği olarak sıkça kullanılmaktadır. Ancak, büyük veri setleri ile çalışırken mevcut KYK bulma yöntemleri yeterince verimli değildir. Çevrimiçi ve çevrimdışı sunucularda günlük olarak üretilen ve sürekli genişleyen büyük veri kümeleri ile başa çıkabilmek için daha etkili KYK bulma teknikleri geliştirilmelidir. Büyük veri kümeleri, gürültülü ve hatalı veri örnekleri içerebileceğinden, bu tür verilerle çalışacak sağlam bir KYK bulma yöntemine olan ihtiyaç artmaktadır[24]. Temel olarak seçilen örnekler k sayıdaki en yakın komşuluklarının uzaklıklarına göre sınıflara ayırır.

2.3.6 Parametere Seçimi

Çalışmada kullandığımız tüm makine öğrenmesi yöntemlerinde, varsayılan parametreler kullanılmıştır.

2.4 Derin Öğrenme Temelli Teknikler

Derin öğrenme, yeterli veri miktarının sağlanması ve gelişmiş hesaplama kaynaklarının kullanılabilirliği ile son yıllarda öne çıkan bir teknoloji haline gelmiştir. 1980’lerde basit problemleri çözmek için kullanılan algoritmalar, bugün derin mimarilerle karmaşık görevlere uygulanmaktadır. Günümüzde, toplumun dijitalleşmesi ve bilgisayar kullanımının artmasıyla birlikte elde edilen büyük veri kümeleri, Derin Öğrenme modellerinin eğitiminde kullanılmaktadır. Bu veriler, daha karmaşık model yapıları ve büyük bellek ihtiyaçları doğurmuştur. Derin öğrenme modelleri, özellikle görüntü sınıflandırma ve nesne tanıma gibi alanlarda başarılı olmuş, Yapay Sinir Ağları üzerine kurulu Tekrarlayan Sinir Ağları gibi gelişmiş yapılar kullanılmıştır. Bu modeller, gelişmiş grafik işlem birimleri (GPU) ile desteklenerek, veri üzerinde katman katman öğrenme yapabilen, hiyerarşik yapılarda özellik keşfi gerçekleştirebilen ve ezberlemeyi önleyici tekniklerle donatılmıştır. Sonuç olarak, derin öğrenme, büyük veri ve gelişmiş işlem



Şekil 2.1 Derin Öğrenme Katmanları

kapasitesi sayesinde, pek çok modern bilgisayarlı görü problemine etkili çözümler sunmaktadır[25]. Derin öğrenmenin çalışmasını bir örnek üzerinden anlatacak olursak, Şekil 2.1 görselindeki, kedi ve köpek görüntülerini sınıflandırmak için kullanılan bir yapay sinir ağı modelinin temsili bir yapısı gösterilmektedir. Görselde, en sol tarafta çeşitli kedi ve köpek görüntülerinin bulunduğu giriş katmanı yer almaktadır. Bu katman, modelin alacağı ham verileri temsil eder ve bu veriler sinir ağına beslenir.

Görüntüler, sinir ağının giriş katmanından başlayarak, çeşitli işlemlerden geçerek, çok sayıda gizli katmandan (hidden layers) oluşan yapısına girer. Her bir gizli katman, giriş verisini daha yüksek düzeyde özelliklere indirger. Bu katmanlar arasındaki bağlantılar (nöronlar arası bağlar), modelin öğrenme yeteneğini ve karmaşıklığını artırır. Gizli katmanlardaki her nöron, gelen veri üzerinde belirli hesaplamalar yapar ve bu işlemler sonucunda elde edilen bilgiler sonraki katmana aktarılır.

Modelin son katmanı olan çıkış katmanı (output layer), öğrenilen özelliklere dayanarak bir tahminde bulunur. Bu örnekte çıkış katmanı, görüntülerin kedi veya köpek kategorilerine ayrılmasını sağlar. Her bir çıkış nöronu, bir sınıfa ait olasılığı temsil eder ve en yüksek olasılığa sahip sınıf, modelin tahmini olarak sunulur.

Bu yapısal görsel, derin öğrenme modellerinin nasıl karmaşık veri yapılarını analiz edebileceğini ve görsel tanıma görevlerinde nasıl kullanılabileceğini özetlemektedir. Model, giriş verilerinden başlayarak, sıralı katmanlar aracılığıyla bilgiyi işler ve sonunda belirli bir görev için kullanılabilecek anlamlı sonuçlar üretir. Bu süreç, modern yapay zeka uygulamalarının temelini oluşturan öğrenme

ve tahmin mekanizmalarını yansıtır.

2.4.1 Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları (TSA), konuşma tanıma ve çevrimiçi el yazısı tanıma gibi tek boyutlu dizi öğrenme görevlerinde etkinliklerini kanıtlamıştır. TSA'ların bu tür görevlerde başarılı olmasını sağlayan özellikler arasında, girdi çarpıtmalara karşı gösterdiği dayanıklılık ve bağlamsal bilgilere erişim yeteneği bulunmaktadır. Bu özellikler, çok boyutlu alanlarda da arzu edilen niteliklerdir. Ancak, şu ana kadar TSA'ların birden fazla uzay-zamansal boyuta sahip verilere doğrudan uygulanabilirliği konusunda bir yöntem geliştirilmemiştir. TSA'ların çok boyutlu verilere uygulanabilirliğini araştırarak, video işleme, tıbbi görüntüleme ve diğer pek çok alanda potansiyel kullanımlarını genişlettiği görülmüştür[26]. TSA'ların en önemli özelliği, bilgiyi zaman içinde "geri döndürebilme" yeteneğidir. Bu yapı sayesinde, bir önceki adımda elde edilen bilgiler, ağın bir sonraki adımında karar verme sürecine dahil edilir. Bu, TSA'ları zamanla değişen veriler için ideal kılar. Bir sonraki verinin tahmin edilmesini için kullanışlıdır.

2.4.1.1 Uzun Kısa Dönemli Bellek (LSTM) Ağları

Uzun Kısa Dönemli Bellek (LSTM) ağları, TSA'ların bir çeşidi olarak, özellikle uzun vadeli bağımlılıkları öğrenme konusunda TSA'ların karşılaştığı sorunları çözmek üzere geliştirilmiştir [27]. LSTM'ler, standart TSA'ların aksine, uzun süreli bellek hücreleri ve çeşitli kapılar (giriş, çıkış ve unutma kapıları) kullanarak daha uzun süreli bağlamsal bilgileri tutma ve bu bilgileri karar verme sürecine entegre etme yeteneğine sahiptir. Bu kapılar, hangi bilginin tutulacağı, hangi bilginin unutulacağı ve hangi bilginin çıktıya katkıda bulunacağına karar vererek, ağın zaman içerisindeki bilgi akışını etkili bir şekilde yönetir [28].

LSTM ağları, özellikle zaman serisi analizi, doğal dil işleme ve konuşma tanıma gibi görevlerde yüksek performans sergiler [29]. Alzheimer hastalığının tespiti ve aşamalarının tahmini gibi karmaşık ve çok boyutlu veri gerektiren uygulamalarda da LSTM ağlarının potansiyel faydaları büyük olabilir. LSTM'ler, Alzheimer hastalarının konuşma verilerindeki uzun vadeli dilsel ve bilişsel değişiklikleri yakalayarak, hastalığın erken tespiti ve aşamalarının doğru bir şekilde tahmini için kullanılabilir [30].

Yukarıda belirtilen özellikler, LSTM ağlarını Alzheimer hastalığının belirlenmesi ve aşamalarının tahmini gibi zorlu görevlerde umut verici bir araç haline getirmektedir. LSTM'ler, bu tür görevlerde kullanılan veri setlerinin karmaşıklığı

ve zaman içindeki değişkenliği göz önüne alındığında, yüksek doğrulukta sonuçlar elde etmek için idealdir [30].

2.4.2 İki Yönlü Kodlayıcı Temsilleri (BERT)

Dil modelleri, kelime dizilerindeki kelimelerin olasılıksal dağılımını hesaplamak için kullanılır. Geleneksel dil modelleri, bir kelime dizisindeki önceki kelimeleri temel alarak sonraki kelimenin olasılığını tahmin eder. Ancak, BERT (Bidirectional Encoder Representations from Transformers - İki Yönlü Kodlayıcı Temsilleri) adı verilen gelişmiş bir dil modeli, tahminlerini yaparken hem önceki hem de sonraki kelimeleri dikkate alır. BERT, bu işlemi "masked language model" (maskeleme) yöntemi ile gerçekleştirir. Bu yöntemde, kelime dizisindeki elemanların yaklaşık %15'i rastgele maskelenir ve model, maskelenen kelimeyi bağlamı kullanarak tahmin etmeye çalışır. Bu çift yönlü yaklaşım, BERT'in dil anlayışını ve metin üzerindeki çıkarımlarını önemli ölçüde geliştirir[31].

2.5 Model Seçimi

Çalışmada, AH'nın tanı ve evrelerinde kullanılmak üzere çeşitli makine öğrenmesi ve derin öğrenme modelleri değerlendirilmiştir. İlk olarak, beş farklı makine öğrenmesi yöntemi seçilmiştir: DVM, KYK, Rastgele Orman, Karar Ağaçları ve Naive Bayes. Bu algoritmalar, konuşma metinlerinden çıkarılan özellikler ve demografik veriler üzerinde test edilerek, AH'nın farklı evrelerinin doğru bir şekilde sınıflandırılmasında etkinlikleri ölçülmüş ve sonuçları 4. Bölümde sunulmuştur.

Ardından, çalışmanın kapsamı genişletilerek, TSA derin öğrenme modelinin bir çeşidi olan LSTM çıktısı incelenmiştir. LSTM modelinden sonra, İki Yönlü Kodlayıcı Temsilleri (BERT) ön eğitilmiş model ve türevleri ile bu modellerin sonuçları incelenmiştir. Modelimizin kullanıldığı BERT sürümü, 'dbmdz/bert-base-turkish-cased' olarak bilinir ve Türkçe diline özgü verilerle eğitilmiştir. Model, 12 katmanlı, 768 gizli birim ve toplamda yaklaşık 110 milyon parametre içerir[32].

Bu çeşitlilikteki model seçimi AH'nın tanı ve evrelemede farklı yaklaşımların etkinliğini karşılaştırmak, en uygun metodolojinin belirlenmesine ve en uygun öz nitelik seçimine yardımcı olmak amacıyla yapılmıştır.

3

DENEYSEL SONUÇLAR

Eğitilmiş Makine Öğrenimi sistemleri, sınıflandırma konularında başarılı çözümler üretmektedir. Bu çalışma kapsamında, Alzheimer Hastalarının spontane konuşmalarından yararlanılarak veri seti oluşturulmuştur. Alzheimer hastalarından toplanan veriler ile AH'nin tespiti ve evre tahminlemesi için Türkçe dilinde ilk veri seti elde edilmiştir. Bu veri seti oluşturulurken hastaların video kayıtlarından öncelikle ses verisi çıkartılarak, elde edilen ses dosyalarından da Hugging Face platformundaki önceden eğitilmiş modeller kullanılarak metin formatına dönüştürülmüştür. Bu aşamada kullanılan modeller Bölüm 3.1 de detaylandırılmıştır. Bölüm 3.2 de, farklı Makine Öğrenmesi algoritmalarına yeni oluşturulan veri seti ile sınıflandırma işlemleri yapılmış ve bu modellerin sonuçları Karışıklık Matrisleri ile görselleştirilmiştir. Bu matristeki sonuçlar doğrultusunda makine öğrenmesi modellerinin başarıları ölçülmüştür. Burada başarı ölçütü olarak birden fazla yöntem kullanılmış ve karşılaştırmalı olarak algoritmalar değerlendirilmiştir. Bölüm 3.3'te ise derin öğrenme metotları ile Alzheimer hastalığı tespiti için testler yapılmış, alınan sonuçlar ile başarıları hesaplanarak raporlaması yapılmıştır. Son olarak Bölüm 3.4'te Derin Öğrenme metotları ve Makine Öğrenmesi algoritmaları ile yapılan çalışmaların sonuçları karşılaştırılmıştır. Deneysel sonuçlar Tablo 3.1'deki donanımlar kullanılarak gerçekleştirilmiştir.

Tablo 3.1 Test makinesi özellikleri

Özellik	Değer
Bilgisayar	MacBook Pro
İşletim Sistemi	MacOS
İşlemci Yongası	Apple M2
Toplam Çekirdek Sayısı	8
Bellek	8GB
Ek Test Ortamı	Google Colab
Geliştirme Ortamı	Jupyter
Geliştirme Dili	Python

3.1 Ses Dosyasından Yazıya Veri Dönüştürme

Çalışmanın bu aşamasında, sestten metne dönüşüm için çeşitli ön eğitimli modeller kullanılmıştır. Bu modeller, Hugging Face platformunun açık kaynaklı Doğal Dil İşleme (DDİ) modelleri arasından seçilmiştir. Kullanılan DDİ modelleri ve bunların başarıları, Tablo 3.2’de detaylı bir şekilde sunulmuştur.

Tablo 3.2 Ddi modelleri ve başarıları

Model	Başarı Oranı
patrickvonplaten/wav2vec2-large-xlsr-turkish-demo [33]	0,70
gorkemgoknar/wav2vec2-large-xlsr-53-turkish [34]	0,15
anltrkkn/wav2vec2-large-xlsr-53-turkish [35]	0,70
ceyda/wav2vec2-large-xlsr-53-turkish [36]	0,50
dundar/wav2vec2-large-xlsr-53-turkish [37]	0,20
ozcangundes/wav2vec2-large-xlsr-53-turkish [38]	0,30
cahya/wav2vec2-base-turkish-artificial [39]	0,25
mpoyraz/wav2vec2-xls-r-300m-cv7-turkish [40]	0,82
mpoyraz/wav2vec2-xls-r-300m-cv8-turkish [41]	0,83

Bu çalışmada incelenen metin verilerinin doğruluğu, araştırmanın başarısı için hayati öneme sahiptir. İlk elde edilen sonuçlar, beklenen standartlara ulaşmadığı için yetersiz bulunmuştur. Araştırmanın esas amacı, doğru ve güvenilir veri setleri üretebilmek olduğundan, sestten metne dönüşüm süreçlerinde daha kapsamlı iyileştirmeler yapılmasına karar verilmiştir. İlk aşamada elde edilen metin verileri detaylı bir şekilde yeniden gözden geçirilmiş ve dinleme yoluyla incelenerek gerekli düzeltmeler dikkatlice yapılmıştır. Bu süreç, metinlerin son halinin elde edilmesini sağlamıştır. Sonuç olarak, ses verisinden metin verisine dönüşüm sürecinde elde edilen veri setinin kalitesi artırılmış ve çalışmanın hedeflerine doğru önemli bir ilerleme sağlanmıştır.

3.2 Makine Öğrenmesi Algoritmalarıyla Sınıflandırma

Bu bölümde, makine öğrenmesi algoritmaları kullanılarak yapılan sınıflandırma işlemlerinin performansını değerlendirmek için karışıklık matrisi (hata matrisi) ve bu matristen türetilen metrikler anlatılmıştır. Karışıklık matrisi, sınıflandırma modelinin tahmin sonuçlarını gerçek değerlerle kıyaslayarak, modelin performansını anlamamıza yardımcı olan bir araçtır.

Karışıklık matrisi, bir sınıflandırma modelinin tahminlerinin doğruluğunu dört temel değer üzerinden gösterir: Gerçek Pozitif (GP), Yanlış Pozitif (YP), Gerçek Negatif (GN) ve Yanlış Negatif (YN).

Tablo 3.3 Hata/karışıklık matrisi

Tahmin/Gerçek	Gerçek	Yanlış
Pozitif	Gerçek-Pozitif	Yanlış-Pozitif
Negatif	Gerçek-Negatif	Yanlış-Negatif

Bu karışıklık/hata matrisinin gösterimi Tablo 3.3'te verilmiştir. Karışıklık matrisinin metrikleri aşağıda açıklanmıştır:

- **Gerçek Pozitif (GP):** Modelin pozitif olarak tahmin ettiği ve gerçekten de pozitif olan durumların sayısı.
- **Yanlış Pozitif (YP):** Modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan durumlar.
- **Gerçek Negatif (GN):** Modelin negatif olarak tahmin ettiği ve gerçekten de negatif olan durumların sayısı.
- **Yanlış Negatif (YN):** Modelin negatif olarak tahmin ettiği ancak gerçekte pozitif olan durumlar.

3.2.1 Performans Metrikleri

Karışıklık matrisinden türetilen metrikler, modelin sınıflandırma performansını değerlendirmek için kullanılır. Alzheimer hastalığı evrelerinin tahmin edilebilmesi için kullandığımız metrikler "Doğruluk", "Kesinlik", "Duyarlılık/Hassasiyet" ve "F1-Skor" değerleridir.

Doğruluk (Accuracy)

Tüm tahminler arasında doğru tahmin edilenlerin oranı:

$$\text{Doğruluk} = \frac{GP + GN}{GP + GN + YP + YN} \quad (3.1)$$

Kesinlik (Precision)

Pozitif olarak tahmin edilen durumlar arasında gerçekten pozitif olanların oranı:

$$\text{Kesinlik} = \frac{GP}{GP + YP} \quad (3.2)$$

Duyarlılık (Recall/Sensitivity)

Gerçekte pozitif olan durumlar arasında model tarafından doğru olarak tahmin edilenlerin oranı:

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \quad (3.3)$$

F1-Skoru

Kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır ve dengeli bir performans ölçüsü sağlar:

$$\text{F1-Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.4)$$

Bu metrikler, modelin sınıflandırma başarısını çeşitli açılardan değerlendirmemize olanak tanır.

Bu çalışmada, Alzheimer hastalığının doğru evrelerinin tahmin edilmesi büyük önem taşımaktadır; yanlış tahminlerin de etkileri göz ardı edilemez. Bu sebeple, başarı metriği olarak dengeli bir ölçüm sağlayan F1-Skor önceliklendirilmiştir. Alzheimer hastalığı dört farklı evrede sınıflandırılrsa da, "Evre 4" hastalarının az sayıda olması nedeniyle veri setinde dengesiz bir dağılım mevcuttur. Bu dengesizliği gidermek amacıyla, tez çalışması kapsamında "Evre 4" hastaları analiz dışı bırakılmış ve sadece ilk üç evre üzerinden sınıflandırma yapılmıştır. Bu yaklaşım, modelin daha stabil ve güvenilir sonuçlar vermesini sağlamakta ve hastalığın evrelerini daha etkin bir şekilde tahmin etmeye odaklanmaktadır.

3.3 Makine Öğrenmesi Deney Sonuçları

Bu bölümde, İngilizce dil analizi için literatürde tanımlanmış özelliklerden yararlanarak Türkçe dil verileri üzerinde gerçekleştirilen makine öğrenmesi deneylerinin sonuçları sunulmaktadır. Seçilen özellikler, dil işleme alanındaki önceki çalışmalardan elde edilen bilgilerle desteklenmiş ve bu özelliklerin Türkçe metinler üzerindeki etkileri değerlendirilmiştir.

3.3.1 Kullanılan Öz Nitelikler ve Modelleme Yaklaşımları

Çalışmada aşağıda listelenen demografik özellikler, dil özellikleri ve duygu analiz skorları kullanılmıştır.

- Yaş (Y)

- Cinsiyet (C)
- Eğitim Durumu (ED)
- Duraksama Sayısı (DS)
- Normalize Edilmiş Duraksama Değeri (NEDD)
- Durak Kelime Frekansı (DKF)
- Kelime Farklılığı (KF)
- Zarf Kullanım Sıklığı (ZarfKS)
- Zamir Kullanım Sıklığı (ZamirKS)
- İsim Kullanım Sıklığı (İsimKS)
- Duygu Analiz Skoru (DAS)

Bu çalışmada, Türkçe dil verileri üzerinde çeşitli makine öğrenmesi modellerinin performansları uygulanarak test edilmiş ve elde edilen sonuçlar karşılaştırmalı olarak analiz edilmiştir. Araştırmada, Karar Ağaçları, Rastgele Orman, Naive Bayes, Destek Vektör Makineleri ve K-En Yakın Komşu gibi farklı makine öğrenmesi algoritmaları kullanılmıştır. Her bir model, tüm özellik kombinasyonları üzerinde çalıştırılmış ve elde edilen çıktılar, verilerin detaylı bir şekilde incelenmesi ve değerlendirilmesi amacıyla kaydedilmiştir.

Analiz sonuçları, her bir model için Alzheimer hastalığının farklı evrelerine ait en başarılı tahminlemelere yönelik hata matrislerini ve en iyi performans gösteren özneliliklerle elde edilen ilk 15 sonuç değerini içermekte; ayrıca, modellerin doğruluk ve F1 skoru gibi başarı metrikleri üzerinden bir karşılaştırma yapılarak, hangi modelin Alzheimer hastalığının evre tahminlemesi için daha uygun olduğu belirlenmiştir. Çalışmanın sonuçları, Alzheimer hastalığının erken teşhisi ve doğru evreleme için kullanılabilecek en etkili makine öğrenmesi modellerine dair değerli bilgiler sunmaktadır. Bu bulgular, hastalığın yönetimi ve ilerlemesinin takibi açısından önemli katkılar sağlamakta ve bu alandaki araştırmalar için yeni yollar açmaktadır.

3.3.2 Karar Ağaçları Sonuçları

Karar ağaçları modelinin en yüksek doğruluk oranını %63,3 ile "Yaş, Cinsiyet, Kelime Farklılığı ve Zamir Kullanım Sıklığı" özellikleri ile edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %61,1 ile "Yaş, Cinsiyet, Eğitim Durumu, Duraksama Sayısı, Zarf Kullanım Sıklığı ve Duygu Analiz Skoru" özellikleri ile elde edilmiştir. Tablo 3.4 ve Tablo 3.5 de en başarılı 15 özellik kombinasyonları listelenmiştir.

KA modelinde şu parametreler kullanılmıştır:

- Karar Ağacı Derinliği (*max_depth*): 5
- Minimum Yaprak Düğüm Sayısı (*min_samples_leaf*): 2
- Minimum Bölünme Sayısı (*min_samples_split*): 10
- Maksimum Özellik Sayısı (*max_features*): 'auto'

Bu parametreler modelin *overfitting* yapmasını engelleyerek daha dengeli bir performans sergilemesini sağlamıştır. Modelin doğruluk ve F1-skorları ile ilgili elde edilen en başarılı sonuçlar, modelin Alzheimer hastalığının teşhis ve evreleme süreçlerinde kullanılabilirliğini göstermektedir.

Tablo 3.4 Karar ağaçları doğruluk oranına göre performans

Özellikler	Doğruluk
Y, C, KF, ZamirKS	%63,3
Y, NEDD, KF, ZarfKS, ZamirKS	%61,1
Y, C, ED, DS, ZarfKS, DAS	%61,1
Y, C, DS, NEDD, KF, ZarfKS	%61,1
Y, C, ED, DS, NEDD, DKF, KF, ZarfKS, ZamirKS, İsimKS	%61,1
Y, ED, ZamirKS	%61,1
Y, C, KF, ZarfKS	%61,1
Y, DS, KF, ZarfKS	%59,3
Y, DS, KF, ZamirKS	%59,3
Y, C, ED, DS, DAS	%59,3
ED, NEDD, DKF, KF	%59,3
Y, C, ED, NEDD, KF, DAS	%59,3
Y, C, ED, DS, DKF, DAS	%59,3
Y, ED, DKF, ZamirKS, DAS	%59,3

Tablo 3.5 Karar ağaçları f1-skoruna göre performans

Özellikler	F1-Skor
Y, C, ED, DS, ZarfKS, DAS	%61,1
Y, C, ED, DS, NEDD, DKF, KF, ZarfKS, ZamirKS, İsimKS	%60,4
Y, C, KF, ZamirKS	%59,3
Y, C, ED, DS, KF, ZarfKS, DAS	%58,6
Y, C, ED, DS, DAS	%58,6
Y, NEDD, KF, ZarfKS, ZamirKS	%58,3
Y, C, ED, DS, KF, ZamirKS, DAS	%58,3
Y, C, ED, NEDD, DKF, KF, ZarfKS, DAS	%58,0
Y, C, KF, ZarfKS, ZamirKS	%57,8
C, ED, DKF, KF, ZamirKS, İsimKS	%57,8
Y, C, ED, NEDD, DAS	%57,6
Y, C, ED, DS, DKF, DAS	%57,2
Y, ED, DS, NEDD, KF, DAS	%57,1
C, ED, DS, DKF, ZamirKS, İsimKS	%56,8
Y, C, ED, DS, NEDD, DKF, KF	%56,5

3.3.3 Rastgele Orman Sonuçları

Rastgele Orman modelinin en yüksek doğruluk oranını %70,4 ile "Yaş, Cinsiyet, Eğitim Durumu, Kelime Farklılığı ve Zamir Kullanım Sıklığı" özellikleri ile elde edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %67,2 ile "Yaş, Cinsiyet, Eğitim Durumu, Kelime Farklılığı, Zamir Kullanım Sıklığı ve Duygu Analiz Skoru" özellikleri ile elde edilmiştir. Tablo 3.6 ve Tablo 3.7 de en başarılı 15 özellik kombinasyonları listelenmiştir.

RO modelinde şu parametreler kullanılmıştır:

- Ağaç Sayısı (*n_estimators*): 100
- Maksimum Derinlik (*max_depth*): None
- Minimum Yaprak Düğüm Sayısı (*min_samples_leaf*): 1
- Minimum Bölünme Sayısı (*min_samples_split*): 2
- Maksimum Özellik Sayısı (*max_features*): 'auto'

Tablo 3.6 Rastgele orman modeli doğruluk performans sonuçları

Özellikler	Doğruluk
Y, C, ED, KF, ZamirKS	%70,4
Y, C, ED, KF, ZamirKS, DAS	%68,5
Y, C, ED, NEDD, KF, ZamirKS, DAS	%66,6
Y, C, ED, NEDD, KF, DAS	%64,8
Y, C, ED, KF	%64,8
Y, C, ED, DKF, KF, DAS	%62,9
Y, C, ED, DS, KF, ZamirKS, DAS	%62,9
Y, C, ED, NEDD, ZamirKS, DAS	%62,9
Y, C, ED, ZamirKS, DAS	%61,1
Y, ED, NEDD, KF, ZamirKS, İsimKS	%61,1
Y, C, ED, DKF, KF, ZamirKS, İsimKS, DAS	%61,1
Y, C, ED, KF, ZamirKS, İsimKS	%59,2
Y, C, ED, DKF, KF, ZamirKS, DAS	%57,4
Y, C, ED, DAS	%57,4
Y, ED, ZamirKS, DAS	%57,4

Tablo 3.7 Rastgele orman modeli f1-skor performans sonuçları

Özellikler	F1-Skor
Y, C, ED, KF, ZamirKS, DAS	%67,2
Y, C, ED, KF, ZamirKS	%66,8
Y, C, ED, NEDD, KF, ZamirKS, DAS	%64,4
Y, C, ED, NEDD, KF, DAS	%64,1
Y, C, ED, KF	%63,2
Y, C, ED, DKF, KF, DAS	%61,7
Y, C, ED, DS, KF, ZamirKS, DAS	%60,1
Y, C, ED, NEDD, ZamirKS, DAS	%60,0
Y, C, ED, ZamirKS, DAS	%58,8
Y, ED, NEDD, KF, ZamirKS, İsimKS	%58,6
Y, C, ED, DKF, KF, ZamirKS, İsimKS, DAS	%58,1
Y, C, ED, DKF, KF, ZamirKS, DAS	%56,8
Y, C, ED, KF, ZamirKS, İsimKS	%56,1
Y, C, ED, DAS	%55,8
Y, ED, ZamirKS, DAS	%55,5

3.3.4 Naive Bayes Sonuçları

Naive Bayes modelinin en yüksek doğruluk oranını %66,7 ile "Eğitim Durumu ve İsim Kullanım Sıklığı" özellikleri ile elde edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %65 ile "Eğitim Durumu ve İsim Kullanım Sıklığı" özellikleri ile elde edilmiştir. Tablo 3.8 ve Tablo 3.9 de en başarılı 15 özellik kombinasyonları listelenmiştir.

NB modelinde şu parametreler kullanılmıştır:

- Gaussian NB modeli kullanılmıştır.
- Varyanslar aynı kabul edilmiştir (varsayılan ayarlar kullanılmıştır).

Tablo 3.8 Naive bayes modeli doğruluk performans sonuçları

Özellikler	Doğruluk
ED, İsimKS	%66,7
ED, DS, DKF, KF, İsimKS	%66,7
ED, DKF, KF, İsimKS	%64,8
Y, C, ED, DS, NEDD, DKF, KF, İsimKS	%64,8
C, ED, DKF, KF, İsimKS	%64,8
Y, C, ED, DS, DKF, KF, İsimKS	%64,8
Y, C, ED, DS, İsimKS	%64,8
ED, NEDD, DKF, İsimKS	%62,9
C, ED, NEDD, DKF, İsimKS	%62,9
Y, ED, DKF, KF, İsimKS	%62,9
Y, ED, DS, DKF, KF, İsimKS	%62,9
C, ED, DS, NEDD, DKF, İsimKS	%62,9
C, ED, İsimKS	%62,9
Y, ED, NEDD, DKF, KF, İsimKS	%62,9
Y, ED, DS, NEDD, KF, İsimKS	%62,9

Tablo 3.9 Naive bayes modeli f1-skor performans sonuçları

Özellikler	F1-Skor
ED, İsimKS	%65
ED, DS, DKF, KF, İsimKS	%64,9
ED, DKF, KF, İsimKS	%64,0
Y, C, ED, DS, NEDD, DKF, KF, İsimKS	%63,5
C, ED, DKF, KF, İsimKS	%63,2
Y, C, ED, DS, DKF, KF, İsimKS	%63,2
ED, NEDD, DKF, İsimKS	%62,5
C, ED, NEDD, DKF, İsimKS	%62,1
Y, ED, DKF, KF, İsimKS	%62,0
Y, C, ED, DS, İsimKS	%62,0
Y, ED, DS, DKF, KF, İsimKS	%62,0
C, ED, DS, NEDD, DKF, İsimKS	%61,8
C, ED, İsimKS	%61,0
Y, ED, NEDD, DKF, KF, İsimKS	%61,0
Y, ED, DS, NEDD, KF, İsimKS	%61,0

3.3.5 Destek Vektör Makineleri Sonuçları

Destek Vektör Makineleri modelinin en yüksek doğruluk oranını %68,5 ile "Yaş, Eğitim Durumu, Duraksama Sayısı, Normalize Edilmiş Duraksama Değeri, Kelime Farklılığı ve Zamir Kullanım Sıklığı" özellikleri ile elde edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %67,2 ile "Yaş, Eğitim Durumu, Duraksama Sayısı, Normalize Edilmiş Duraksama Değeri, Kelime Farklılığı ve Zamir Kullanım Sıklığı" özellikleri ile elde edilmiştir. Tablo 3.10 ve Tablo 3.11 de en başarılı 15 özellik kombinasyonları listelenmiştir.

DVM modelinde şu parametreler kullanılmıştır:

- Kernel Türü (*kernel*): Linear
- Düzenleme Parametresi (*C*): 1
- Sınıf Ağırlıkları (*class_weight*): None

Tablo 3.10 Destek vektör makineleri doğruluk performans sonuçları

Özellikler	Doğruluk
Y, ED, DS, NEDD, KF, ZamirKS	%68,5
Y, C, ED, NEDD, DKF, KF, DAS	%66,7
ED, DS, NEDD, KF, ZamirKS	%66,7
Y, ED, DS, NEDD, KF, ZamirKS, DAS	%64,8
ED, DS, NEDD, KF, ZamirKS, DAS	%64,8
Y, C, ED, DS, NEDD, KF, DAS	%64,8
Y, C, ED, DS, NEDD, DKF, KF, DAS	%64,8
Y, ED, DS, NEDD, KF, ZarfKS, ZamirKS, DAS	%64,8
Y, ED, NEDD, KF, ZarfKS, ZamirKS, DAS	%64,8
Y, C, ED, DS, NEDD, KF, ZamirKS	%64,8
Y, ED, DS, KF, ZamirKS	%64,8
Y, ED, DS, NEDD, KF, DAS	%64,8
Y, C, ED, DS, NEDD, KF	%64,8
Y, C, ED, DS, NEDD, DKF, KF	%64,8
Y, ED, NEDD, KF, ZarfKS, ZamirKS	%62,9

Tablo 3.11 Destek vektör makineleri f1-skor performans sonuçları

Özellikler	F1-Skor
Y, ED, DS, NEDD, KF, ZamirKS	%67,2
Y, ED, DS, NEDD, KF, ZamirKS, DAS	%64,8
Y, C, ED, NEDD, DKF, KF, DAS	%63,9
ED, DS, NEDD, KF, ZamirKS, DAS	%63,5
Y, C, ED, DS, NEDD, KF, DAS	%63,5
Y, C, ED, DS, NEDD, DKF, KF, DAS	%63,1
ED, DS, NEDD, KF, ZamirKS	%63,0
Y, ED, DS, NEDD, KF, ZarfKS, ZamirKS, DAS	%63,0
Y, ED, NEDD, KF, ZarfKS, ZamirKS, DAS	%62,9
Y, C, ED, DS, NEDD, KF, ZamirKS	%62,9
Y, ED, DS, KF, ZamirKS	%62,6
Y, ED, DS, NEDD, KF, DAS	%62,6
Y, C, ED, DS, NEDD, KF	%62,5
Y, C, ED, DS, NEDD, DKF, KF	%62,3
Y, ED, NEDD, KF, ZarfKS, ZamirKS	%61,8

3.3.6 K=5 En Yakın Komşu Sonuçları

K=5 En Yakın Komşu (KYK-5) modelinin en yüksek doğruluk oranını %64,8 ile "Eğitim Durumu, Durak Kelime Frekansı, Kelime Farklılığı ve Duygu Analiz Skoru" özellikleri ile elde edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %63,8 ile "Yaş, Cinsiyet, Eğitim Durumu, Durak Kelime Frekansı ve Duygu Analiz Skoru" özellikleri ile elde edilmiştir. Tablo 3.12 ve Tablo 3.13 de en başarılı 15 özellik kombinasyonları listelenmiştir.

KYK-5 modelinde şu parametreler kullanılmıştır:

- Komşu Sayısı ($n_neighbors$): 5
- Mesafe Metriği ($metric$): Minkowski
- Ağırlık Türü ($weights$): Uniform

Tablo 3.12 Kyk-5 modeli doğruluk performans sonuçları

Özellikler	Doğruluk
ED, DKF, KF, DAS	%64,8
Y, ED, NEDD, ZamirKS, DAS	%64,8
Y, C, ED, DKF, DAS	%63,0
Y, C, ED, NEDD, DAS	%63,0
ED, NEDD, DKF, KF, DAS	%63,0
Y, C, ED, DKF, ZamirKS, DAS	%61,1
Y, ED, DS, NEDD, KF, DAS	%61,1
Y, C, ED, NEDD, KF, ZamirKS, DAS	%61,1
Y, C, ED, DS, NEDD, KF, ZamirKS, DAS	%61,1
Y, C, ED, DS, DKF, KF, ZamirKS, DAS	%61,1
Y, C, ED, DAS	%61,1
Y, C, ED, ZamirKS, DAS	%59,3
ED, DKF, KF, ZamirKS, DAS	%59,3
Y, C, ED, DS, DKF, DAS	%59,3
Y, C, ED, NEDD, KF, DAS	%59,3

Tablo 3.13 Kyk-5 modeli f1-skor performans sonuçları

Özellikler	F1-Skor
Y, C, ED, DKF, DAS	%63,8
Y, C, ED, DKF, ZamirKS, DAS	%61,7
ED, DKF, KF, DAS	%61,7
Y, ED, DS, NEDD, KF, DAS	%60,6
Y, C, ED, NEDD, KF, ZamirKS, DAS	%60,6
Y, C, ED, DS, NEDD, KF, ZamirKS, DAS	%59,9
Y, C, ED, DS, DKF, KF, ZamirKS, DAS	%59,4
C, ED, NEDD, DKF, KF, DAS	%59,3
C, ED, DKF, KF, DAS	%59,3
Y, C, ED, DS, DKF, DAS	%59,3
Y, C, ED, DS, KF, ZamirKS, DAS	%59,2
Y, C, ED, DKF, KF, DAS	%58,9
C, ED, DS, DKF, ZamirKS, DAS	%58,9
Y, C, ED, DS, NEDD, KF	%58,7
Y, C, ED, DS, NEDD, DKF, KF	%58,3

3.3.7 K=7 En Yakın Komşu Sonuçları

K=7 En Yakın Komşu (KYK-7) modelinin en yüksek doğruluk oranını %64,8 ile "Eğitim Durumu ve İsim Kullanım Sıklığı" özellikleri ile elde edilmiştir. Benzer şekilde, F1-skoru açısından en iyi performans, %64,4 ile "Eğitim Durumu ve İsim Kullanım Sıklığı" özellikleri ile elde edilmiştir. Tablo 3.14 ve Tablo 3.15 de en başarılı 15 özellik kombinasyonları listelenmiştir.

KYK-7 modelinde şu parametreler kullanılmıştır:

- Komşu Sayısı (*n_neighbors*): 7
- Mesafe Metriği (*metric*): Minkowski
- Ağırlık Türü (*weights*): Uniform

Tablo 3.14 Kyk-7 modeli doğruluk performans sonuçları

Özellikler	Doğruluk
ED, İsimKS	%64,8
ED, DS, DKF, KF, İsimKS	%64,8
C, ED, İsimKS	%64,8
ED, DKF, KF, ZamirKS	%63,0
ED, DKF, KF, İsimKS	%63,0
C, ED, DKF, KF, İsimKS	%63,0
ED, DS, DKF, KF, ZamirKS	%63,0
ED, NEDD, DKF, KF, ZamirKS	%63,0
C, ED, NEDD, DKF, KF, ZamirKS	%63,0
Y, C, ED, DS, DKF, KF, İsimKS	%63,0
Y, ED, NEDD, DKF, KF, ZamirKS	%61,1
Y, C, ED, NEDD, DKF, KF, ZamirKS	%61,1
ED, DS, DKF, ZamirKS	%61,1
ED, NEDD, DKF, KF	%61,1

3.3.8 En Başarılı Model

Bu çalışma, çeşitli makine öğrenmesi modelleri kullanarak Alzheimer hastalığının evrelerini tahmin etmek amacıyla yapılmıştır. Yapılan analizlerde, Rastgele Orman modeli, en yüksek F1-skorunu elde ederek en başarılı model olarak öne çıkmıştır. Bu modelin en iyi performansı gösterdiği öz nitelik gruplamaları Tablo 3.16'da belirtilmiştir. 3.3.8.1 bölümünde de Rastgele Orman modeli için veri korelasyon matrisi ve modeldeki öz niteliklerin önem katsayıları hesaplanarak gösterilmiştir.

- Yaş (Y)

Tablo 3.15 Kyk-7 modeli f1-skor performans sonuçları

Özellikler	F1-Skor
ED, İsimKS	%64,4
ED, DS, DKF, KF, İsimKS	%63,5
ED, DKF, KF, ZamirKS	%62,6
ED, DKF, KF, İsimKS	%62,6
C, ED, DKF, KF, İsimKS	%62,6
ED, DS, DKF, KF, ZamirKS	%61,8
ED, NEDD, DKF, KF, ZamirKS	%61,5
Y, ED, NEDD, DKF, KF, ZamirKS	%60,9
C, ED, NEDD, DKF, KF, ZamirKS	%60,8
Y, C, ED, DS, DKF, KF, İsimKS	%60,8
Y, C, ED, NEDD, DKF, KF, ZamirKS	%60,7
C, ED, İsimKS	%60,7
ED, DS, DKF, ZamirKS	%60,6
ED, NEDD, DKF, KF	%60,5


Tablo 3.16 Rastgele orman modeli en başarılı f1-skor öz nitelikleri

Model	Öz Nitelikler	F1-Skor
Rastgele Orman	Y, C, ED, KF, ZamirKS, DAS	0,672
DVM	Y, ED, DS, NEDD, KF, ZamirKS	0,672

- Cinsiyet (C)
- Eğitim Durumu (ED)
- Kelime Farklılığı (KF)
- Zamir Kullanım Sıklığı (ZamirKS)
- Duygu Analiz Skoru (DAS)

3.3.8.1 Veri Seti Korelasyonu


Bu çalışma, veri setinde bulunan özelliklerin anlam düzeylerini değerlendirerek hastalık evresi tespiti için makine öğrenimi modelinin etkinliğini artırmayı amaçlamaktadır. Rastgele Orman modelimiz, özellikle çeşitli özellik kombinasyonlarının performansını değerlendirdiğimiz analizlerimizde en başarılı model olarak öne çıkmıştır. Modelimizin analizinde, hangi öz niteliklere öncelik verilmesi gerektiğinin değerlendirilmesi kritik bir adımdır. Analiz bulgularımız, model tahminleri üzerinde en büyük etkiye sahip değişkenlerin yaş, cinsiyet, eğitim düzeyi, kelime farklılığı, zamir kullanım sıklığı ve duygusal analiz skoru olduğunu göstermiştir.



Şekil 3.1 Veri Seti Korelasyonu

Hastalığın evresini tanımlarken, eğitim durumu önemli bir faktör olarak öne çıkmaktadır. Bu, bireyin hastalığını yönetme becerisi ve sağlık bilincinin, eğitim düzeyi ile doğrudan ilişkili olduğunu göstermektedir. Ayrıca, modelimiz kelime çeşitliliğinin ve duygu analizi skorunun, hastanın genel sağlık ve psikolojik durumunun güçlü göstergeleri olduğunu ortaya koymuştur. Bu iki metrik, bireyin dil kullanımının ve bilişsel performansının sağlık durumunu nasıl etkilediğini açıklamaktadır.

Bu değerlendirmeler, tez çalışmamızda kullanılan metodolojinin avantajlarını vurgulamakta ve Alzheimer hastalığı konuşma verilerinden makine öğrenimi modellemesinin kullanılabilirliğini göstermektedir. Rastgele Orman modelinin korelasyon matrisi Şekil 3.1'de tablo şeklinde gösterilmiştir. Modelde kullandığımız öz niteliklerin önem dereceleri ise Şekil 3.2'de gösterilmiştir. Genel model performansını da artıran öz nitelik seçimi ve model optimizasyon prosedürlerimiz aracılığıyla daha hassas evre tahminleri üretme kapasitemizi göstermektedir.



Şekil 3.2 Özellik Önem Dereceleri

3.4 Derin Öğrenme ile Deney Sonuçları

Çalışmamızda, Alzheimer hastalığının evrelerini tahmin etmek amacıyla çeşitli makine öğrenmesi yöntemlerinin yanında, derin öğrenme yöntemleri de kullanılmıştır. Metin verilerinin analizinde, özelleştirilmiş bir Tekrarlayan Sinir Ağları (TSA) olan LSTM (Uzun Kısa Süreli Bellek) modeli tercih edilmiştir. LSTM modeli, dil verilerinin sıralı doğasını yakalamada oldukça başarılıdır ve bu nedenle metin verilerini işlerken tercih edilmiştir.

3.4.1 LSTM Modelinin Eğitimi ve Sonuçları

Öncelikle, metin verileri üzerinde ön işleme adımları uygulanmıştır. Bu adımlar:

- Metin verileri Türkçe dilinde tokenize edilmiştir.
- Her bir metin için kelime çeşitliliği hesaplanmıştır.
- Hedef değişken (evre) kategorik hale getirilerek numerik kodlara dönüştürülmüştür.
- Metinler tokenleştirilmiş ve diziye dönüştürülmüştür.
- Dizilerin boyutları eşitlenerek sabit uzunlukta diziler oluşturulmuştur.

Modelin yapılandırılması ve eğitimi aşağıdaki adımlarla gerçekleştirilmiştir:

- **Embedding Katmanı:** Giriş verilerini (tokenize edilmiş ve pad edilmiş diziler) alır ve her bir kelime için öğrenilebilir bir vektör temsili oluşturur. Bu katman, kelimelerin anlamını öğrenmeye yardımcı olur.
 - *input_dim=5000*: En fazla 5000 farklı kelime dikkate alınır.
 - *output_dim=128*: Her kelime 128 boyutlu bir vektör ile temsil edilir.
 - *input_length=max_sequence_length*: Giriş dizilerinin uzunluğu sabitlenir.
- **LSTM Katmanı:** Dil verilerinin sıralı yapısını öğrenir ve uzun süreli bağımlılıkları yakalar.
 - *units=64*: 64 adet gizli birim (hücre) kullanılır.
- **Dense Katmanı:** Çıkış katmanı olup, her sınıf (evre) için bir olasılık değeri üretir. Bu katman softmax aktivasyon fonksiyonu kullanarak sınıflandırma yapar.
 - *units=df_metin['evre_kod'].nunique()*: Çıkış birimleri, sınıf sayısına (evre sayısına) eşittir.
 - *activation='softmax'*: Sınıflandırma için softmax aktivasyon fonksiyonu kullanılır.
- **Modelin Derlenmesi:**
 - *Eğitim Kaybı Fonksiyonu*: *sparse_categorical_crossentropy*, çok sınıflı sınıflandırma problemleri için kullanılır.
 - *Optimizasyon Algoritması*: *adam*, adaptif öğrenme hızına sahip bir optimizasyon algoritmasıdır.
 - *Değerlendirme Metrikleri*: *accuracy*, modelin doğruluk oranını hesaplamak için kullanılır.
- **Modelin Eğitimi:**
 - *Epoch Sayısı*: 10 epoch boyunca model eğitilmiştir. Her epoch, tüm eğitim verisinin modelden geçirilmesi anlamına gelir.
 - *Batch Size*: Her bir adımda kullanılan örnek sayısı 128 olarak belirlenmiştir.

Bu sonuçlar, modelin doğruluk ve kesinlik açısından makul bir performans gösterdiğini, ancak duyarlılık ve F1 skoru açısından iyileştirilmesi gerektiğini

Tablo 3.17 Lstm modeli test sonuçları

Metrik	Değer
Kesinlik (Precision)	%80
Duyarlılık (Recall)	%33
F1 Skoru	%19
Doğruluk (Accuracy)	%41

göstermektedir. Bu nedenle, modelin performansını artırmak için daha ileri düzey yöntemler kullanılmıştır.

Bu çalışmanın bir sonraki adımı olarak, BERT (Bidirectional Encoder Representations from Transformers) modelini kullanarak metin verilerini daha derinlemesine analiz ettik. BERT modeli, özellikle dil anlama görevlerinde üstün performans göstermekte olup, LSTM modeline kıyasla daha yüksek başarı elde etme potansiyeline sahiptir.

3.4.2 BERT Modeli

BERT (Bidirectional Encoder Representations from Transformers), Google tarafından geliştirilen ve doğal dil işleme (DDİ) alanında devrim yaratan bir dil modelidir. BERT, metinlerin bağlamını iki yönlü (bidirectional) olarak anlamak üzere tasarlanmıştır ve pek çok DDİ görevinde üstün performans sergiler.

3.4.2.1 BERT Nedir?

BERT, Transformer mimarisine dayanan bir dil modelidir. Transformer mimarisi, dikkat (attention) mekanizması kullanarak metinlerdeki kelime öbeklerinin (tokens) birbirleriyle olan ilişkilerini anlamaya çalışır. BERT, iki yönlü (bidirectional) dikkat mekanizması kullanarak metinlerin bağlamını hem sol hem de sağ taraftan öğrenir.

3.4.2.2 BERT Modelinin Özellikleri

Transformer Katmanları:

- BERT, 12 veya 24 transformer katmanı (katman sayısı, modelin base veya large versiyonuna bağlı olarak değişir) içerir. Her katman, çok başlı dikkat (multi-head attention) ve besleme ileri ağı (feed-forward network) içerir.

İki Yönlü Dikkat (Bidirectional Attention):

- BERT, iki yönlü dikkat mekanizması kullanarak metinlerin bağlamını hem sol hem de sağ taraftan anlamaya çalışır. Bu, modelin metinlerin anlamını daha iyi kavramasını sağlar.

Girdi ve Girdi Temsilleri:

- Model, kelime öbeklerini (tokens) ve konum bilgisi gömmelerini (positional embeddings) kullanarak giriş dizisini işler. Kelime öbekleri, modelin öğrenilmiş kelime öbeği gömmeleri (embeddings) aracılığıyla temsil edilir.

Maskeli Dil Modeli (Masked Language Model - MLM):

- Eğitim sırasında, girdi metnindeki bazı kelime öbekleri maskelenir ve modelden bu maskelenmiş kelime öbeklerini tahmin etmesi istenir. Bu yöntem, modelin bağlamı anlamasını ve eksik kelimeleri tahmin etmesini sağlar.

İki Görevli Eğitim (Dual-Task Training):

- BERT, maskeli dil modeli (MLM) ve sonraki cümle tahmini (Next Sentence Prediction - NSP) olmak üzere iki farklı görevle eğitilir. Bu, modelin hem kelime seviyesinde hem de cümle seviyesinde bağlamı anlamasına yardımcı olur.

3.4.2.3 BERT'in Eğitimi

BERT, büyük bir metin veri seti (örneğin, Wikipedia ve BooksCorpus) üzerinde eğitilmiştir. Bu veri setleri, modelin geniş bir bağlamda dil bilgisi ve kelime ilişkilerini öğrenmesini sağlar. Eğitim sürecinde, model maskeli dil modeli (MLM) ve sonraki cümle tahmini (NSP) görevleri kullanılarak optimize edilmiştir.

3.4.2.4 BERT'in Kullanım Alanları

BERT, pek çok DDİ görevinde yüksek performans gösterir:

- **Metin Sınıflandırma:** Metinlerin kategorilere ayrılması.
- **Duygu Analizi:** Metinlerdeki duygusal tonların belirlenmesi.

- **Adlandırılmış Varlık Tanıma (AVT):** Metinlerdeki özel isimlerin (kişiler, yerler, organizasyonlar) tespit edilmesi.
- **Soru Cevaplama:** Doğal dildeki sorulara doğru ve anlamlı cevaplar verilmesi.
- **Çeviri ve Dil Modelleme:** Farklı diller arasındaki çeviri işlemleri ve dil modelleme.

BERT, dil modelleme alanında büyük bir ilerleme sağlayarak, pek çok DDİ görevinde state-of-the-art performans elde etmiştir. Bu model, dilin bağlamını anlamada güçlü yetenekler sunar ve geniş bir uygulama yelpazesinde etkili çözümler sağlar.

- **Sınıflandırma Katmanı:** BERT modelinin çıktısına eklenen bir dense (yoğun) katman, sınıflandırma görevini gerçekleştirir. Bu katman, BERT'in ürettiği özellik vektörlerini alır ve bunları belirli sınıflara (bu örnekte hasta evreleri) ayırır.

Modelin Çalışmamızda Detaylı İşleyişi

- **Girdi (Input):**
 - Hastaların metin verileri (metin kolonu).
 - Bu metin verileri, BERT tokenizer tarafından işlenir ve tokenlere dönüştürülür.
- **BERT ile Özellik Çıkarımı:**
 - Tokenize edilen metin verileri, BERT modeline beslenir.
 - BERT, bu metin verilerini işleyerek her bir kelimenin bağlamsal anlamını içeren özellik vektörleri üretir.
- **Sınıflandırma Katmanı:**
 - BERT modelinin sonundaki CLS tokeninin çıktısı, sınıflandırma katmanına gönderilir.
 - Sınıflandırma katmanı, bu özelliği kullanarak her bir örneğin hangi Alzheimer evresi ait olduğunu tahmin eder.
- **Kayıp Hesaplama ve Optimizasyon:**

- Modelin tahminleri, gerçek sınıflarla karşılaştırılarak kayıp hesaplanır.
- Bu kayıp değeri, modelin ağırlıklarını güncellemek için kullanılır.

Özet

- **Temel Model:** BERT (Transformer tabanlı dil modeli)
- **Ek Katman:** BERT'in çıktısını kullanarak sınıflandırma yapan dense (yoğun) katman
- **Diğer Derin Öğrenme Modelleri:** Bu uygulamada başka bir derin öğrenme modeli kullanılmadı. Yalnızca BERT ve onun üzerine eklenen sınıflandırma katmanı kullanıldı.

Eğitim Süreci ve Sonuçları:

İlk olarak kullandığımız BERT modeli "bert-base-uncased" modelidir. Bu model çoklu dil desteği ile bilinen daha çok İngilizce dili iyi sonuçlar veren bir modeldir.

Tablo 3.18 Bert modeli eğitim ve doğruluk değerleri


Epoch	Eğitim Kaybı	Doğruluk
1	1,0035	%63,64
2	0,9721	%72,73
3	0,9239	%72,73
4	0,9089	%72,73
5	0,8304	%72,73
6	0,7112	%72,73

Tablo 3.18'de gösterildiği gibi, epoch sayısı arttıkça kayıp değerleri azalmaktadır, bu da modelin eğitim verisine daha iyi uyum sağladığını gösterir. Doğruluk, ilk epoch'ta %63,6 iken, sonraki epoch'larda %72,7'ye yükselmiş ve orada stabil kalmıştır.

Şekil 3.3'de de görülebileceği gibi, modelin eğitim sürecindeki kayıp ve doğruluk değerlerinin değişimi aşağıda gösterilmektedir.

Sınıflandırma Performansı:

- Evre 1: Tek örnek olduğu için model bu sınıfı doğru tahmin etmiş.
- Evre 2: Model bu sınıfı tanımakta zorluk çekiyor.



Şekil 3.3 Model Eğitimindeki Kayıp ve Doğruluk Değerlerinin Değişimi

Tablo 3.19 Bert modeli sınıflandırma raporu

Sınıf	Kesinlik	Duyarlılık	F1-Skor	Örnek Sayısı
Evre 1	0,50	1,00	0,67	1
Evre 2	0,00	0,00	0,00	2
Evre 3	0,78	0,88	0,82	8

- Evre 3: Model bu sınıfı oldukça iyi tahmin etmiş.

Genel Performans:

- Doğruluk: %73 doğruluk, modelin toplamda doğru tahmin oranını göstermektedir.
- Ağırlıklı Ortalama Sonuçlar: Sınıfların veri setinde ne kadar temsil edildiğini dikkate alarak değerlendirir - Duyarlılık: 0,61, Geri Çağırma: 0,73, F1-Skor: 0,66.

Alzheimer hastalığı evreleme çalışmamızın başarı kriteri F1-Skoru olduğunda, bu modelin sonucu Tablo 3.20’de gösterilmiştir.

Tablo 3.20 Ortalama f1-skoru

Metot	F1-Skor
Ortalama F1-Skor	0,66

Bu model, İngilizce BERT modeli (bert-base-uncased) kullanılarak eğitildi ve sınıflandırma için kullanıldı. Modelin performansını artırmak için Türkçe model ile testler yapıldı. Bu testler Bölüm 3.4.3’te anlatılmaktadır.

3.4.3 BERTürk Modeli

BERTürk, BERT modelinin Türkçe diline özel olarak eğitilmiş bir versiyonudur. Bu model, Türkçe metinlerde yüksek performans göstermeyi amaçlar ve BERT mimarisinin tüm avantajlarını Türkçe dilinde sunar.

BERTürk, Google tarafından geliştirilen BERT (Bidirectional Encoder Representations from Transformers) modelinin, Türkçe diline uyarlanmış halidir. BERT modeli, iki yönlü (bidirectional) dikkat (attention) mekanizması kullanarak metinlerin bağlamını anlar ve doğal dil işleme görevlerinde üstün performans gösterir.

3.4.3.1 BERTürk Modelinin Özellikleri

Transformer Katmanları:

- BERTürk, 12 transformer katmanı içerir. Her katman, çok başlı dikkat (multi-head attention) ve besleme ileri ağı (feed-forward network) içerir.

Girdi ve Girdi Temsilleri:

- Model, kelime öbeklerini (tokens) ve konum bilgisi gömmelerini (positional embeddings) kullanarak giriş dizisini işler.

Dikkat (Attention) Mekanizması:

- BERTürk, her kelime öbeğinin diğer kelime öbekleriyle olan ilişkisini değerlendirir ve bağlam bilgisi ile daha anlamlı temsiller oluşturur.

Maskeli Dil Modeli (Masked Language Model - MLM):

- Eğitim sırasında, girdi metnindeki bazı kelime öbekleri maskelenir ve modelden bu maskelenmiş kelime öbeklerini tahmin etmesi istenir. Bu yöntem, modelin bağlamı anlamasını sağlar.

3.4.3.2 BERTürk'un Eğitimi

BERTürk, büyük bir Türkçe veri seti üzerinde eğitilmiştir. Bu veri seti, Wikipedia, haber siteleri ve diğer büyük Türkçe metin kaynaklarından elde edilmiştir. Eğitim sürecinde, model Türkçe dil yapısını ve kelime ilişkilerini öğrenmiştir.

3.4.3.3 BERTürk'un Kullanım Alanları

BERTürk, çeşitli Türkçe doğal dil işleme görevlerinde yüksek performans gösterir:

- **Metin Sınıflandırma:** Türkçe metinlerin kategorilere ayrılması.
- **Duygu Analizi:** Türkçe metinlerdeki duygusal tonların belirlenmesi.
- **Adlandırılmış Varlık Tanıma (AVT):** Türkçe metinlerdeki özel isimlerin (kişiler, yerler, organizasyonlar) tespit edilmesi.
- **Soru Cevaplama:** Türkçe doğal dildeki sorulara doğru ve anlamlı cevaplar verilmesi.

BERTürk, Türkçe dilinde güçlü dil modeli yetenekleri sunarak, Türkçe DDİ görevlerinde etkili ve yüksek performanslı bir çözüm sağlar. Bu model, Türkçe dil yapısını ve bağlamını anlama konusunda optimize edilmiştir ve geniş bir kullanım alanına sahiptir.

Daha iyi sonuçlar elde etmek ve modelin Türkçe dilindeki performansını artırmak amacıyla, modeli Türkçe BERT ile çalıştırdık. Türkçe BERT modeli, özellikle Türkçe metinler üzerinde eğitim aldığı için dilin bağlamını ve inceliklerini daha iyi anlamaktadır.

3.4.3.4 BERTürk Modeli Eğitimi ve Sonuçları - 10 Epoch

- BERTürk, özellikle Türkçe metinler için optimize edilmiş olan `dbmdz/bert-base-turkish-cased` modeli kullanıldı.

Eğitim Süreci:

- **Optimizasyon:** AdamW optimizasyon algoritması kullanıldı.
- **Epoch:** Model 10 epoch boyunca eğitildi.
- **Veri Bölme:** Veriler %80 eğitim ve %20 test olacak şekilde bölündü.


Eğitim Sonuçları

- İlk epoch'tan itibaren eğitim kaybı düzenli olarak azaldı.
- Doğruluk, epochlar boyunca dalgalandı, ancak genellikle %72,73 civarında sabit kaldı ve son epoch'ta %81,82'ye ulaştı.

Tablo 3.21 Türkçe bert modeli eğitim ve doğruluk değerleri

Epoch	Eğitim Kaybı	Doğruluk
1	0,6822	%72,73
2	0,5681	%63,64
3	0,4980	%72,73
4	0,4652	%72,73
5	0,3256	%81,82
6	0,2945	%72,73
7	0,2475	%72,73
8	0,2769	%72,73
9	0,1619	%72,73
10	0,1113	%81,82

- Modelin doğruluk oranı, eğitim kaybının azalmasına paralel olarak önce iyileşti, sonra sabit kaldı. Bu sonuçlar Şekil 3.4’de gösterilmiştir.
- Modelin sonuçları Tablo 3.21 de sunulmuştur.



Şekil 3.4 Eğitim kaybı ve doğruluk değerleri

Sonuçların Değerlendirilmesi

Tablo 3.22 Türkçe bert modeli sınıflandırma raporu

Sınıf	Kesinlik	Duyarlılık	F1-Skoru
Evre 1	0,50	1,00	0,67
Evre 2	0,50	0,50	0,50
Evre 3	1,00	0,88	0,93

Alzheimer hastalığı evreleme çalışmamızın başarı kriteri F1-Skoru olduğunda, bu modelin sonuçları Tablo 3.22’de gösterildiği gibidir.

- **Doğruluk** : 0,82 (11 örnek üzerinde)
- **Kesinlik, Duyarlılık, F1-Skoru:** Evre 1 ve evre 2 için düşük, evre 3 için yüksek performans gösterdi.
 - **Evre 1:** 1 örnekle ilgili, modelin doğruluğu %50, duyarlılık %100 (tüm evre 0 örneklerini doğru tanımladı), F1-skor %67.
 - **Evre 2:** 2 örnekle ilgili, modelin doğruluğu %50, duyarlılık %50, F1-skor %50,
 - **Evre 3:** 8 örnekle ilgili, modelin doğruluğu %100, duyarlılık %88, F1-skor %93.

Analiz:

- Model Evre 3'yi oldukça iyi tanıyabildi, ancak Evre 1 ve Evre 2'de zorlandı. Evre 1 ve Evre 2 için örneklem sayısı az olduğundan bu oranlarla karşılaşmak olağan olarak değerlendirildi.
- Eğitim sürecinde eğitim kaybının düzenli olarak azalması, modelin eğitim setine iyi adapte olduğunu gösteriyor.
- Doğruluğun sabit kalması, modelin validasyon seti üzerindeki performansının belirli bir seviyede sabitlendiğini gösteriyor. Ancak epoch 5 ve epoch 10'da daha yüksek doğruluk oranına ulaşıldı.

Şekil 3.4'de de görüldüğü gibi, modelin eğitim sürecindeki kayıp ve doğruluk değerlerinin yanı sıra sınıflandırma sonuçları da görselleştirilmiştir.

Ortalama F1-Skoru:

Alzheimer hastalığı evreleme çalışmamızın başarı kriteri F1-Skoru olduğunda, bu modelin sonucu Tablo 3.23'de gösterilmiştir.

Tablo 3.23 Ortalama f1-skoru

Metot	F1-Skoru
Ağırlıklı Ortalama	%83

3.4.3.5 BERTürk Modeli Eğitimi ve Sonuçları - 6 Epoch

Sınıflandırma Raporu:

Gözlemler:

Tablo 3.24 6 epoch eğitim ve validasyon sonuçları

Epoch	Eğitim Kaybı	Doğruluk
1	1,1796	%18,18
2	1,1098	%45,45
3	1,0315	%72,73
4	1,0245	%72,73
5	0,9619	%72,73
6	0,8931	%72,73

Tablo 3.25 6 epoch türkçe bert modeli sınıflandırma raporu

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Örnek Sayısı
Evre 1	0,25	1,00	0,40	1
Evre 2	0,00	0,00	0,00	2
Evre 3	1,00	0,88	0,93	8

- Eğitim kaybı sürekli olarak azaldı, bu da modelin eğitim verisine iyi uyum sağladığını gösteriyor.
- Doğruluğun ilk epoch'ta %18,18, ikinci epoch'ta %45,45, ardından %72,73'e çıkarak sabit kaldı. Bu durum, modelin belirli bir doğruluk seviyesine ulaştığını ve daha fazla iyileşme göstermediğini gösterebilir.

Ortalama F1-Skoru:

Alzheimer hastalığı evreleme çalışmamızın başarı kriteri F1-Skoru olduğunda, bu modelin sonucu Tablo 3.26'de gösterilmiştir.

Tablo 3.26 Ortalama f1-skoru (6 epoch)

Metot	F1-Skoru
Ağırlıklı Ortalama	%72


Sonuçların Görselleştirilmesi:

Şekil 3.5'de de görüldüğü gibi, modelin eğitim sürecindeki kayıp ve doğruluk değerleri görselleştirilmiştir.

3.4.3.6 BERTürk Modeli Eğitimi ve Sonuçları - 14 Epoch

Sınıflandırma Raporu:

Gözlemler:



Şekil 3.5 Eğitim Kaybı ve Doğruluk Değerleri (6 Epoch)

Tablo 3.27 14 epoch eğitim ve doğrulama sonuçları

Epoch	Eğitim Kaybı	Doğruluk
1	1,2354	%9,09
2	1,0716	%72,73
3	1,0260	%72,73
4	0,9631	%72,73
5	0,9305	%63,64
6	0,8625	%63,64
7	0,8198	%72,73
8	0,8059	%63,64
9	0,6566	%63,64
10	0,5974	%72,73
11	0,4914	%81,82
12	0,4036	%81,82
13	0,3072	%72,73
14	0,2123	%72,73

Tablo 3.28 14 epoch türkçe bert modeli sınıflandırma raporu

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Örnek Sayısı
Evre 1	0,33	1,00	0,50	1
Evre 2	0,50	0,50	0,50	2
Evre 3	1,00	0,75	0,86	8

- Eğitim kaybı sürekli olarak azalıyor, bu da modelin eğitim verisine iyi uyum sağladığını gösteriyor.
- Doğruluk oranı ilk epoch'ta %9,09 ile çok düşük başladı, ancak ikinci epoch'tan itibaren %72,73 civarında sabitlendi. Epoch 11 ve 12'de

%81,82'ye ulaştı, ancak tekrar %72,73'e döndü.

- Evre 1 ve Evre 2 için düşük performans, veri setinin dengesizliğine işaret ediyor olabilir.


Ortalama F1-Skoru:

Alzheimer hastalığı evreleme çalışmamızın başarı kriteri F1-Skoru olduğunda, bu modelin sonucu Tablo 3.29'de gösterilmiştir.

Tablo 3.29 Ortalama f1-skoru (14 epoch)

Metot	F1-Skoru
Ağırlıklı Ortalama	%76

Sonuçların Görselleştirilmesi:



Şekil 3.6 Eğitim kaybı ve doğruluk oranının epochlara göre değişimi (14 epoch)

Şekil 3.6'de de görüldüğü gibi, modelin eğitim sürecindeki kayıp ve doğruluk oranı sonuçları da görselleştirilmiştir.

Eğitim ve Doğrulama Eğrileri

- **Eğitim Kaybı:** Hem 6 epoch hem de 14 epoch boyunca eğitim kaybının düzenli olarak azaldığını gözlemliyoruz.
- **Doğrulama:** Doğrulama bazı epoch'larda dalgalanma gösteriyor. Bu, modelin bazı epoch'larda aşırı uyum veya düşük uyum yaşadığını göstermektedir.

- **Veri Seti Dengesi:** Dengesizlik sorununu çözmek için bir sonraki bölümde veri dengeleme metotlarından biri olan SMOTE ile BERTürk modeli çalıştırılarak sonuçlar incelenmiştir.

3.4.4 SMOTE ile BERT Modeli

SMOTE, yani "Sentetik Azınlık Aşırı Örneklemme Tekniği", dengesiz veri setlerindeki azınlık sınıfların temsil oranını artırmak için kullanılan bir veri artırma tekniğidir. Dengesiz veri setlerinde, bazı sınıflar diğer sınıflara göre çok daha az sayıda örnek içerebilir. Bu durum, makine öğrenimi algoritmalarının azınlık sınıfları öğrenme ve doğru şekilde sınıflandırma yeteneğini olumsuz etkileyebilir. Biz de çalışmamızda bu dengesizliği gidermek için SMOTE kullandık.

3.4.4.1 SMOTE Nasıl Çalışır?

SMOTE, azınlık sınıftaki örneklerin sayısını artırmak için sentetik örnekler oluşturur. Bunu şu şekilde yapar:

- **K En Yakın Komşu Kullanımı:** Azınlık sınıftaki her örnek için, k-en yakın komşu algoritmasını kullanarak k tane en yakın komşuyu belirler.
- **Sentetik Örnekler Oluşturma:** Belirlenen komşular arasında rastgele bir komşu seçilir. Orijinal örnek ile seçilen komşu arasındaki vektör boyunca rastgele bir noktada yeni bir sentetik örnek oluşturulur.

3.4.4.2 SMOTE Olmadan 14 Epoch Sonuçları

Tablo 3.30 Smote olmadan 14 epoch sonuçları

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Destek
0	0,33	1,00	0,50	1
1	0,50	0,50	0,50	2
2	1,00	0,75	0,86	8

Doğruluk: %73 (11 örnek üzerinde)

SMOTE yöntemi kullanılmadan elde edilen sonuçlar 3.30 da sunulmuştur.

SMOTE Olmadan Ortalama F1-Skoru: %76

3.4.4.3 SMOTE ile 14 Epoch Sonuçları


SMOTE yöntemi kullanılarak elde edilen sonuçlar 3.31 de sunulmuştur.

Tablo 3.31 Smote ile 14 epoch sonuçları

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Destek
Evre 1	1,00	0,25	0,40	4
Evre 2	0,57	0,57	0,57	7
Evre 3	0,67	1,00	0,80	4

Ortalama F1-Skoru:

- Ortalama F1-Skoru: %59



Şekil 3.7 Eğitim Kaybı ve Doğrulamanın Göre Değişimi (25 Epoch)

Şekil 3.7’de de görüldüğü gibi, modelin eğitim sürecindeki kayıp ve doğruluk oranı sonuçları da görselleştirilmiştir.

3.4.4.4 SMOTE ile 25 Epoch Sonuçları


Tablo 3.32 Smote ile 25 epoch sonuçları

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Destek
Evre 1	0,44	1,00	0,62	4
Evre 2	0,00	0,00	0,00	7
Evre 3	0,67	1,00	0,80	4

SMOTE yöntemi kullanılarak ve 25 epoch eğitim ile elde edilen sonuçlar 3.32 de sunulmuştur.

Ortalama F1-Skoru:

- Ortalama F1-Skoru: %38



Şekil 3.8 Eğitim Kaybı ve Doğrulamanın Göre Değişimi

Şekil 3.8’de de görüldüğü gibi, modelin eğitim sürecindeki kayıp ve doğruluk oranı sonuçları da görselleştirilmiştir.

3.4.4.5 Karşılaştırmalı Analiz ve Yorumlar

Performans Karşılaştırması Doğruluk:

- SMOTE olmadan 14 epoch: %73
- SMOTE ile 14 epoch: %60
- SMOTE ile 25 epoch: %53

Ağırlıklı Ortalama F1-Skoru:

- SMOTE olmadan 14 epoch: %76
- SMOTE ile 14 epoch: %59
- SMOTE ile 25 epoch: %38

Evre 1 Performansı:

- SMOTE olmadan 14 epoch sürecinde Kesinlik %33, Duyarlılık %100,

- SMOTE ile 14 epoch sürecinde Kesinlik %100, Duyarlılık %25.
- SMOTE ile 25 epoch sürecinde Kesinlik %44, Duyarlılık %100,

SMOTE, Evre 1'in Duyarlılık oranını düşürmüş, ancak Kesinlik oranını artırmış görünüyor.

Evre 2 Performansı:

- SMOTE olmadan 14 epoch sürecinde Kesinlik %50, Duyarlılık %50,
- SMOTE ile 14 epoch sürecinde Kesinlik %57, Duyarlılık %57.
- SMOTE ile 25 epoch sürecinde Kesinlik %0, Duyarlılık %0,

SMOTE, Evre 2'nin performansını 14 epoch'ta artırmış ancak 25 epoch'ta tamamen performans kaybına neden olmuştur.

Evre 3 Performansı:

- SMOTE olmadan 14 epoch sürecinde Kesinlik %100, Duyarlılık %75.
- SMOTE ile 14 epoch sürecinde Kesinlik %67, Duyarlılık %100,
- SMOTE ile 25 epoch sürecinde Kesinlik %67, Duyarlılık %100,

SMOTE, Evre 3 için Duyarlılık oranını artırmış, ancak Kesinlik oranını düşürmüştür.

SMOTE ile 25 epoch sürecinde modelin aşırı öğrenme yaptığı ve performansın düştüğü gözlenmiştir.

SMOTE, Evre 2 için performansı artırmada yeterli olmamış ve hatta 25 epoch sürecinde performansı tamamen kaybettirmiştir.

SMOTE, Evre 1 ve Evre 3 için bazı iyileştirmeler sağlamış olsa da, Evre 1 için performansı önemli ölçüde düşürmüştür. Bu durum, SMOTE'un Evre 2 için yeterli sentetik örnek oluşturamadığını veya oluşturulan örneklerin yeterince temsil edici olmadığını göstermektedir.

Sonraki bölümde, XLM-RoBERTa modelini kullanarak model sonuçları incelenmiştir.

3.4.5 XLM-RoBERTa Modeli

XLM-RoBERTa, çok dilli doğal dil işleme görevleri için geliştirilen bir dil modelidir. Bu model, 100 farklı dilde büyük bir veri seti üzerinde eğitilmiş olan RoBERTa modelinin çok dilli versiyonudur. XLM-RoBERTa, dil modellerinin sınırlarını genişleterek farklı dillerde yüksek performans göstermeyi amaçlar [42].

XLM-RoBERTa, Facebook AI tarafından geliştirilen RoBERTa modelinin çok dilli bir varyantıdır. RoBERTa modeli, BERT modelinin optimizasyonları ve hiperparametre ayarları ile iyileştirilmiş versiyonudur. XLM-RoBERTa ise, RoBERTa modelinin eğitildiği geniş veri seti ve çok dilli destek sayesinde, birden fazla dilde başarılı performans sergileyebilir [43].

3.4.5.1 XLM-RoBERTa'nın Özellikleri ve Katmanları

Dönüştürücü Katmanları:

- XLM-RoBERTa, 12 dönüştürücü katmanı içerir. Her katman, çok başlı dikkat mekanizması ve ileri beslemeli ağ içerir.
- Her bir dönüştürücü katmanı, giriş olarak bir dizi kelime öbeğini alır ve bu kelime öbeklerini daha yüksek seviyeli temsillere dönüştürür [44].

Girdi ve Girdi Temsilleri:

- XLM-RoBERTa, sabit boyutta bir kelime öbeği dizisi kullanır. Girdi metni, sözcük işleyici tarafından kelime öbeklerine dönüştürülür ve bu kelime öbekleri, modelin girdi katmanlarına beslenir.
- Kelime öbekleri, modelin öğrenilmiş kelime öbeği gömmeleri aracılığıyla temsil edilir [31].

Dikkat Mekanizması:

- Modelde, çok başlı dikkat mekanizması kullanılır. Bu mekanizma, her kelime öbeğinin diğer kelime öbekleriyle olan ilişkisini değerlendirir ve bağlam bilgisini dikkate alarak daha anlamlı temsiller oluşturur [44].

Konum Bilgisi Gömmeleri:

- XLM-RoBERTa, kelime öbeklerinin sırasını belirlemek için konum bilgisi gömmelerini kullanır. Bu gömmeler, kelime öbeklerinin giriş dizisindeki pozisyonlarını belirlemeye yardımcı olur [31].

Maskeli Dil Modeli:

- XLM-RoBERTa, maskeli dil modeli yaklaşımını kullanarak eğitilir. Eğitim sırasında, girdi metnindeki bazı kelime öbekleri maskelenir ve modelden bu maskelenmiş kelime öbeklerini tahmin etmesi istenir. Bu yöntem, modelin bağlamı anlamasını ve eksik kelimeleri tahmin etmesini sağlar [31].

3.4.5.2 XLM-RoBERTa'nın Eğitimi

XLM-RoBERTa, 2,5 TB büyüklüğünde çok dilli bir veri seti kullanılarak eğitilmiştir. Bu veri seti, Wikipedia, Common Crawl ve diğer büyük metin veri kaynaklarından elde edilmiştir. Modelin eğitimi sırasında, 100 farklı dilde metinler kullanılarak, dil bilgisi ve kelime ilişkileri öğrenilmiştir [42].

3.4.5.3 XLM-RoBERTa'nın Kullanım Alanları

XLM-RoBERTa, çok dilli doğal dil işleme görevlerinde yüksek performans göstermektedir. Aşağıda, XLM-RoBERTa'nın kullanım alanlarından bazıları bulunmaktadır:

- **Metin Sınıflandırma:** Farklı dillerde metinlerin kategorilere ayrılması.
- **Duygu Analizi:** Metinlerdeki duygusal tonların belirlenmesi.
- **Adlandırılmış Varlık Tanıma:** Metinlerdeki özel isimlerin (kişiler, yerler, organizasyonlar) tespit edilmesi.
- **Çeviri ve Dil Çifti Modelleme:** Farklı diller arasındaki çeviri işlemleri ve dil çiftlerinin modellemesi.
- **Soru Cevaplama:** Doğal dildeki sorulara doğru ve anlamlı cevaplar verilmesi.


XLM-RoBERTa, geniş dil desteği ve güçlü dil modeli yetenekleri sayesinde, çok dilli doğal dil işleme görevlerinde etkili ve esnek bir çözüm sunmaktadır. Bu model, özellikle çok dilli veri setleri üzerinde çalışırken büyük avantajlar sağlar ve farklı dillerde yüksek performans elde edilmesini mümkün kılar.

3.4.5.4 XLM-RoBERTa Modeli ile 10 Epoch Sonuçları

Çalışmamızda kullanılan modelin sonuçları Tablo 3.33’de ve eğitim ve doğrulama kaybının grafiği ise Şekil 3.9 de gösterilmiştir.

Tablo 3.33 Eğitim ve doğrulama kaybı ve doğruluğu

Epoch	Eğitim Kaybı	Doğruluk
1	1,1518	%9,09
2	1,2163	%9,09
3	1,1241	%72,73
4	1,1108	%72,73
5	1,1195	%72,73
6	1,1139	%72,73
7	1,0692	%72,73
8	1,0786	%18,18
9	1,0657	%27,27
10	1,0786	%72,73



Şekil 3.9 XLM-RoBERTa Modeli ile Eğitim ve Doğrulama Kaybı

Sınıflandırma Raporu

Çalışmamızda kullanılan modelin sınıflandırma sonuçları ise Tablo 3.34 olduğu gibidir.

Tablo 3.34 Xlm-roberta modeli ile sınıflandırma sonuçları

Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Örnek Sayısı
Evre 1	0,00	0,00	0,00	1
Evre 2	0,00	0,00	0,00	2
Evre 3	0,73	1,00	0,84	8

3.4.5.5 Analiz ve Yorumlar

Eğitim ve Doğrulama Oranı:

- Eğitim kaybı epoch sayısı arttıkça genel olarak azalmıştır.
- Doğrulama oranı bazı epoch'larda %72,73'e kadar çıkmış ancak dalgalanma göstermiştir. Bu dalgalanma, modelin bazı epoch'larda daha iyi performans gösterdiğini, ancak genel olarak stabil olmadığını gösterir.

Sınıf Performansı:

- Evre 1: Bu, modelin Evre 1'i hiç doğru tespit edemediğini gösterir.
- Evre 2: Bu, modelin Evre 2'yi de hiç doğru tespit edemediğini gösterir.
- Evre 3: Model, Evre 3'ü tespit etmekte oldukça başarılıdır.

Gözlemler

Yüksek Sınıf Dengesizliği: Evre 1 ve Evre 2 için düşük performans, veri setindeki sınıf dengesizliğinden kaynaklanıyor olabilir. Özellikle Evre 1 ve Evre 2 için daha fazla veri toplanması veya veri dengeleme teknikleri uygulanması gerekmektedir.

Aşırı öğrenme: Eğitim kaybı düşerken doğruluk oranının dalgalanması, modelin aşırı öğrenme yaptığını göstermektedir.

XLM-RoBERTa Performansı: XLM-RoBERTa modeli, Evre 3'ü tespit etmekte başarılıdır, ancak diğer sınıflar için performansı yeterli değildir.

4 SONUÇ

Alzheimer hastalığı, nörodejeneratif bir hastalık türüdür. Sinir hücrelerinin ölümü veya iletim ağındaki bozulmalar sonucunda duygusal ve davranışsal değişiklikler, günlük aktivite bozuklukları, unutkanlık ve fonksiyonel gerilemeler gibi semptomlar ortaya çıkar. Bu hastalık, gün geçtikçe yaygınlaşmaktadır ve henüz tedavisi bulunmamaktadır. Bu durum, hastaların yaşam kalitesini önemli ölçüde etkilemektedir.

Alzheimer hastalığının tedavisinin bulunamamış olması, hastalığın seyrini endişe verici kılmaktadır. Bu nedenle, Alzheimer hastalığı için erken teşhis, tanı ve hastalığın takibi son derece önemlidir. Günümüzde, doktorlar hastalığın tespiti için beyin görüntüleme yöntemlerine ve PET tarama sonuçlarına başvurumaktadırlar. Ancak bu yöntemler hem maliyetli hem de yan etkileri olabilecek kontrol yöntemleridir. Bu nedenle, daha az maliyetli ve tekrarlanma sıklığı konusunda endişe yaratmayan alternatif yöntemlere ihtiyaç vardır.

Bu bağlamda, Alzheimer hastalığının konuşmaları analiz edilerek hastalık tespiti ve evre tahminlemesi yapılması gibi bir yaklaşım geliştirilmiştir. Tezimizdeki bu yaklaşım, daha az maliyetli ve tekrarlanma sıklığı açısından endişe yaratmayan bir yöntem olarak öne çıkmaktadır.

Bu yaklaşımın uygulanabilmesi için, öncelikle literatürdeki dil tabanlı çalışmalar incelendi ve Alzheimer hastalığı ile ilişkilendirilecek özellikler belirlendi. Bu amaçla, dil tabanlı çalışmaların incelenmesi sonucunda Türkçe dilinde Alzheimer hastalığı tespitinde kullanılabilecek özellikler çıkarıldı.

Daha sonra, Türkçe dilinde veri seti olmadığı için İstanbul Üniversitesi Tıp Fakültesi Nöroloji Anabilim Dalı ile birlikte 61 hasta kaydından oluşan bir veri seti oluşturuldu. Bu veri setinde, 3 tanesi demografik özellikler olmak üzere 11 özellik yer almaktadır. Bu özellikler, Türkçe dil özellikleri ve dil tabanlı özelliklerden yararlanılarak seçilmiştir.

Oluşturulan özellikler, Python programlama dili ve makine öğrenmesi için kullanılan kütüphaneler ile işlenerek sayısal değerlere dönüştürülmüştür. Dönüşüm ile makine öğrenmesi ve derin öğrenme modelleri tarafından bu verilerin kullanılabilir hale getirilmesi sağlanmıştır.

Bu çalışma kapsamında, Alzheimer hastalarının spontane olarak "Kurabiye Hırsızı" görselini yorumladıkları konuşmalardan elde edilen veriler kullanarak çeşitli makine öğrenimi ve derin öğrenme modelleri ile Alzheimer hastalığının evrelerinin tahmini yapılmıştır. Türkçe dilinde Alzheimer hastalığı için doğal dil işleme teknikleri kullanılarak yapılacak çalışmalar için veri seti oluşturulmuş ve bu veri seti ile sınıflandırma işlemleri gerçekleştirilmiştir. Çalışmanın başarı kriteri olarak F1-skoru kullanılmıştır. F1-skor parametresinin başarı kriteri olarak seçilme sebebi, doğru tahminlerin dışında yanlış tahminlerde de başarılı olmanın hastalık ve hastalığın takibinde önem taşımasıdır.

Hazırlanan veri seti ile sınıflandırma ve evre tahmini için Rastgele Orman, Destek Vektör Makineleri, Karar Ağaçları, Naive-Bayes ve K-En Yakın Komşu(k=5) ve K-En Yakın Komşu(k=7) modelleri eğitilmiştir. Elde edilen sonuçlara göre Rastgele Orman ve Destek Vektör Makineleri en iyi performansları sergilemiştir. Rastgele Orman modeli, %70,4 doğruluk ve %67,2 F1-skoru ile en başarılı makine öğrenmesi modeli olarak belirlenmiştir. Destek Vektör Makineleri modeli ise, %68,5 doğruluk ve %67,2 F1-skoru ile benzer bir performans göstermiştir.

LSTM modelinin eğitimi için hazırlamış olduğumuz veri seti; eğitim için %80, doğrulama ve test için %20 olacak şekilde bölünmüştür. Çalışmamızda LSTM ve BERT modelleri kullanılmıştır. Ayrıca, BERT modelinin Türkçe versiyonu olan BERTürk, çok dilli BERT tabanlı model olan XLM-RoBERTa ile de deneyler yapılmıştır. Bu modellerin performansları analiz edilmiş ve en iyi sonuçlar BERTürk modeli ile elde edilmiştir. BERTürk modeli, %82 doğruluk ve %83 F1-skoru ile Alzheimer hastalığının evrelerini en doğru şekilde tahmin eden model olmuştur. Bu model, dil tabanlı yöntemlerin Alzheimer hastalığının tespiti ve evrelemesinde etkin bir şekilde kullanılabileceğini göstermektedir.

Çalışmanın sonuçlarına göre, SMOTE uygulaması, veri setindeki sınıf dengesizliğini gidermede ve modelin bazı sınıflarında performans artışı sağlamada yardımcı olmuştur. Ancak, özellikle Evre 2 için performans kayıpları yaşanmıştır.

Genel olarak, bu çalışmada Alzheimer hastalığının evrelerinin tahmini amacıyla kullanılan modeller arasında en iyi performansı gösteren model, Türkçe diline özel olarak eğitilmiş BERTürk modeli olmuştur. En başarılı makine öğrenmesi modeli ise Rastgele Orman ve Destek Vektör Makineleridir.

Sonuçlara göre, kullanılan veri seti sınırlı olsa da, elde edilen bulgular bu yöntemlerin Alzheimer hastalığının tanısı ve takibinde umut verici olduğunu göstermektedir. Çalışmamızda doğruluk oranı olarak daha yüksek değerlere ulaşılmış olsa da, Alzheimer hastalığı tespiti ve evre tahminlemesinde yapılan doğru tahminler kadar yanlış tahminler de kritik öneme sahip olduğundan F1-Skor değeri önceliklendirilmiştir. Makine öğrenmesi metotlarında Rastgele Orman ve Destek Vektör Makineleri %67,2 F1-Skoru oranlarıyla en başarılı iki model olmuştur. Bu modellerin en yüksek başarıya ulaşması için eğitiminde kullanılan öznitelikler karşılaştırmalı sonuçlar ile incelenmiş ve en başarılı öznitelikler seçilmiştir. Derin öğrenme metotlarının karşılaştırmalı sonuçlarına baktığımızda ise %83 F1-Skor oranıyla BERTürk modeli, Alzheimer hastalığının evrelerini en doğru şekilde tahmin etme potansiyeli gösteren model olmuştur. Daha iyi sonuçlar için farklı derin öğrenme modelleri ile deneyler yapılmıştır. Bu kapsamda LSTM, BERT, BERTürk ve XLM-RoBERTa gibi farklı derin öğrenme modelleri farklı çalışma sayıları ile (epoch) en iyi sonuçlar edilmeye çalışılmıştır. Ayrıca, sonuçlarda iyileşme sağlanması amacıyla yaygın olarak kullanılan veri dengeleme yöntemi olan SMOTE yöntemi de denenmiştir. Ancak, yapılan denemelerde SMOTE yöntemiyle herhangi bir iyileşme sağlanamamıştır. Bu nedenle, çalışmada SMOTE yöntemi kullanılmamıştır.

Bu sonuçlar, dil ve demografik özellikler kullanılarak Alzheimer hastalığının sınıflandırma başarısının önemli ölçüde artırılabilirliğini göstermektedir. Gelecek çalışmalarda, kullanılan veri setinin genişletilerek model performanslarının başarıları artırılabilir.

- [1] C. Güngen, T. Ertan, E. Eker, R. Yaşar, F. Engin, “Reliability and validity of the standardized mini mental state examination in the diagnosis of mild dementia in turkish population,” *Turk psikiyatri dergisi= Turkish journal of psychiatry*, vol. 13, no. 4, pp. 273–281, 2002.
- [2] U. of California. “Dementia looks different in the brains of latinos.” Accessed: 2023-11-08. (Nov. 2023), [Online]. Available: <https://www.universityofcalifornia.edu/news/dementia-looks-different-brains-latinos>.
- [3] M. Scholl, “Call for special issue papers: Advances in alzheimer’s disease: Deadline for manuscript submission: January 31, 2022,” *Brain connectivity*, vol. 11, no. 9, pp. 691–691, 2021.
- [4] L. Castro-Aldrete, M. V. Moser, G. Putignano, M. T. Ferretti, A. Schumacher Dimech, A. Santucci Chadha, “Sex and gender considerations in alzheimer’s disease: The women’s brain project contribution,” *Frontiers in Aging Neuroscience*, vol. 15, p. 1105620, 2023.
- [5] L. E. Hebert, J. Weuve, P. A. Scherr, D. A. Evans, “Alzheimer disease in the united states (2010–2050) estimated using the 2010 census,” *Neurology*, vol. 80, no. 19, pp. 1778–1783, 2013.
- [6] M. Prince, R. Bryce, E. Albanese, A. Wimo, W. Ribeiro, C. P. Ferri, “The global prevalence of dementia: A systematic review and metaanalysis,” *Alzheimer’s & dementia*, vol. 9, no. 1, pp. 63–75, 2013.
- [7] H. Gurvit *et al.*, “The prevalence of dementia in an urban turkish population,” *American Journal of Alzheimer’s Disease & Other Dementias®*, vol. 23, no. 1, pp. 67–76, 2008.
- [8] J. Rasmussen, H. Langerman, “Alzheimer’s disease—why we need early diagnosis,” *Degenerative neurological and neuromuscular disease*, pp. 123–130, 2019.
- [9] A. Soni, B. Amrhein, M. Baucum, E. J. Paek, A. Khojandi, “Using verb fluency, natural language processing, and machine learning to detect alzheimer’s disease,” in *2021 43rd annual international conference of the IEEE engineering in medicine & biology society (EMBC)*, IEEE, 2021, pp. 2282–2285.
- [10] A. Ševčík, M. Rusko, “A systematic review of alzheimer’s disease detection based on speech and natural language processing,” in *2022 32nd International Conference Radioelektronika (RADIOELEKTRONIKA)*, IEEE, 2022, pp. 01–05.

- [11] E. J. Paek, L. L. Murray, “Quantitative and qualitative analysis of verb fluency performance in individuals with probable alzheimer’s disease and healthy older adults,” *American journal of speech-language pathology*, vol. 30, no. 1S, pp. 481–490, 2021.
- [12] A. Balagopalan, B. Eyre, J. Robin, F. Rudzicz, J. Novikova, “Comparing pre-trained and feature-based models for prediction of alzheimer’s disease based on speech,” *Frontiers in aging neuroscience*, vol. 13, p. 635 945, 2021.
- [13] T. Searle, Z. Ibrahim, R. Dobson, “Comparing natural language processing techniques for alzheimer’s dementia prediction in spontaneous speech,” *arXiv preprint arXiv:2006.07358*, 2020.
- [14] H. Goodglass, E. Kaplan, S. Weintraub, *BDAE: The Boston diagnostic aphasia examination*. Lippincott Williams & Wilkins Philadelphia, PA, 2001.
- [15] P. Kalafatoğlu, “Alzheimer hastalığında sözel akıcılık becerilerinin incelenmesi,” M.S. thesis, Anadolu University (Turkey), 2015.
- [16] A. K. Troyer, M. Moscovitch, G. Winocur, “Clustering and switching as two components of verbal fluency: Evidence from younger and older healthy adults,” *neuropsychology*, vol. 11, no. 1, p. 138, 1997.
- [17] *Ffmpeg is the leading multimedia framework, able to decode, encode, transcode, mux, demux, stream, filter and play pretty much anything that humans and machines have created*. <https://ffmpeg.org> [Accessed: (13.04.2024)], 2024.
- [18] H. Face. “Bert-base-turkish-sentiment-cased.” Accessed: 2024-03-08. (2024), [Online]. Available: <https://huggingface.co/savasy/bert-base-turkish-sentiment-cased>.
- [19] P. C. Sen, M. Hajra, M. Ghosh, “Supervised classification algorithms in machine learning: A survey and review,” in *Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018*, Springer, 2020, pp. 99–111.
- [20] B. Charbuty, A. Abdulazeez, “Classification based on decision tree algorithm for machine learning,” *Journal of Applied Science and Technology Trends*, vol. 2, no. 01, pp. 20–28, 2021.
- [21] G. Biau, E. Scornet, “A random forest guided tour,” *Test*, vol. 25, pp. 197–227, 2016.
- [22] S. Chen, G. I. Webb, L. Liu, X. Ma, “A novel selective naive bayes algorithm,” *Knowledge-Based Systems*, vol. 192, p. 105 361, 2020.
- [23] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, A. Lopez, “A comprehensive survey on support vector machine classification: Applications, challenges and trends,” *Neurocomputing*, vol. 408, pp. 189–215, 2020.
- [24] A. Shokrzade, M. Ramezani, F. A. Tab, M. A. Mohammad, “A novel extreme learning machine based knn classification method for dealing with big data,” *Expert Systems with Applications*, vol. 183, p. 115 293, 2021.

- [25] Ö. İnik, E. Ülker, “Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri,” *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, vol. 6, no. 3, pp. 85–104, 2017.
- [26] A. Graves, S. Fernández, J. Schmidhuber, “Multi-dimensional recurrent neural networks,” in *International conference on artificial neural networks*, Springer, 2007, pp. 549–558.
- [27] S. Hochreiter, J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [28] F. A. Gers, J. Schmidhuber, F. Cummins, “Learning to forget: Continual prediction with lstm,” *Neural computation*, vol. 12, no. 10, pp. 2451–2471, 2000.
- [29] H. Sak, A. W. Senior, F. Beaufays, “Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition,” *arXiv preprint arXiv:1402.1128*, 2014.
- [30] Z. Yin, M. Zhao, Y. Wang, Y. Yang, J. Zhang, “Detecting cognitive impairments by incorporating multiple emotional signals,” *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 5, pp. 1191–1201, 2017.
- [31] J. Devlin, M.-W. Chang, K. Lee, K. Toutanova, “Bert: Pre-training of deep bidirectional transformers for language understanding,” *arXiv preprint arXiv:1810.04805*, 2018.
- [32] S. Schweter, “Berturk-bert models for turkish,” *Zenodo*, vol. 2020, p. 3 770 924, 2020.
- [33] P. von Platen, *Wav2vec2 large xlsr turkish demo*, <https://huggingface.co/patrickvonplaten/wav2vec2-large-xlsr-turkish-demo>, Erişim tarihi: 28 Ağustos 2023, 2022.
- [34] G. Göknaar, *Wav2vec2 large xlsr 53 turkish*, <https://huggingface.co/gorkemgoknar/wav2vec2-large-xlsr-53-turkish>, Erişim tarihi: 28 Ağustos 2023, 2022.
- [35] A. Türkkkan, *Wav2vec2 large xlsr 53 turkish*, <https://huggingface.co/aniltrkkn/wav2vec2-large-xlsr-53-turkish>, Erişim tarihi: 28 Ağustos 2023, 2022.
- [36] Ceyda, *Wav2vec2 large xlsr 53 turkish*, <https://huggingface.co/ceyda/wav2vec2-large-xlsr-53-turkish>, Erişim tarihi: 29 Ağustos 2023, 2022.
- [37] Dündar, *Wav2vec2 large xlsr 53 turkish*, <https://huggingface.co/dundar/wav2vec2-large-xlsr-53-turkish>, Erişim tarihi: 29 Ağustos 2023, 2022.
- [38] Ö. Gündes, *Wav2vec2 large xlsr 53 turkish*, <https://huggingface.co/ozcangundes/wav2vec2-large-xlsr-53-turkish>, Erişim tarihi: 29 Ağustos 2023, 2022.
- [39] Cahya, *Wav2vec2 base turkish artificial cv*, <https://huggingface.co/cahya/wav2vec2-base-turkish-artificial-cv>, Erişim tarihi: 29 Ağustos 2023, 2022.

- [40] M. Poyraz, *Wav2vec2 xls-r 300m cv7 turkish*, <https://huggingface.co/mpoyraz/wav2vec2-xls-r-300m-cv7-turkish>, Eriřim tarihi: 26 Eylül 2023, 2022.
- [41] M. Poyraz, *Wav2vec2 xls-r 300m cv8 turkish*, <https://huggingface.co/mpoyraz/wav2vec2-xls-r-300m-cv8-turkish>, Eriřim tarihi: 26 Eylül 2023, 2022.
- [42] A. Conneau *et al.*, “Unsupervised cross-lingual representation learning at scale,” *arXiv preprint arXiv:1911.02116*, 2020.
- [43] Y. Liu *et al.*, “Roberta: A robustly optimized bert pretraining approach,” *arXiv preprint arXiv:1907.11692*, 2019.
- [44] A. Vaswani *et al.*, “Attention is all you need,” *arXiv preprint arXiv:1706.03762*, 2017.



TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. E. Akarsu, Z. Huseynli, B. Bilgiç, and B. Diri, “Alzheimer’s Disease Detection and Dataset Creation from Spontaneous Speech,” 32nd IEEE Conference on Signal Processing and Communications Applications (SIU 2024), 16-18 May 2024, Tarsus, Turkey.

