

Makine Öğrenme Algoritmaları Kullanarak Ses Verilerinde Hastalık Tespiti

Disease Detection in Audio Data by Using Machine Learning Algorithms

Duygu Çokay¹ 

Engin Şahin² 

¹ Çanakkale Onsekiz Mart Üniversitesi, Bilgisayar Mühendisliği Bölümü, Türkiye, e-mail: sonmez_duygu@hotmail.com

² Çanakkale Onsekiz Mart Üniversitesi, Bilgisayar Mühendisliği Bölümü, Türkiye, e-mail: enginsahin@comu.edu.tr

Öz

Hastalıkların ileri evrelerde tespit edilmesi iyileşme oranlarını düşürür, tedavi sürecini zorlaştırır, iyileşme maliyetini artırır. Bu nedenle hastalıkların erken evrelerde tespit edilmesi önemlidir. Günümüzde makine öğrenmesi, yapay zeka, derin öğrenme yöntemleri; sağlık alanında, tıbbi veri analizi ve hastalık tespiti amacıyla yaygın şekilde kullanılmaktadır. Ses kısıklığı toplumda yaygın görülen şikayetlerden biridir. Ses kısıklığına neden olan ses teli polipi, gırtlak kanseri, akut larenjit, ses teli felci gibi çeşitli hastalıklar mevcuttur. Bu hastalıkların ortak noktası ses kısıklığı olmasına rağmen nedenleri, tedavi süreçleri, riskleri farklılık gösterir. Bu çalışmada, ses kısıklığına neden olan farklı hastalıkların, ses verileri kullanılarak, patolojik ve endoskopik muayeneden önce sınıflandırılmasının yapılması amaçlanmıştır. Çalışmada Saarland Üniversitesi Fonetik Enstitüsü tarafından oluşturulan Saarbruecken veri tabanından elde edilen ses verileri kullanılmıştır. Reinke ödemi olan, larenjit, kanser ya da kanser öncesi lekeleme tanısı bulunan, polip, ses teli felçli ve sağlıklı hastalardan oluşan toplamda 652 kişiye ait ses verisi üzerinde k-En Yakın Komşu, Naive Bayes, Karar Ağacı, Destek Vektör Makinesi, Rassal Orman olarak beş farklı makine öğrenme algoritmasıyla sınıflama yapılmış elde edilen sonuçlar karmaşıklık matrisi kullanılarak karşılaştırılmıştır. Elde edilen sonuçlara göre hastalıklı-sağlıklı ses ayırımında en yüksek doğruluk oranı 0,79 ile SVM algoritmalarından elde edilmiştir.

Anahtar kelimeler: Makine öğrenmesi, Ses işleme, Sınıflandırma algoritmaları, Hastalık tespiti, Polip, Larenjit, Kanser

*Bu çalışma yazarın Çanakkale Onsekiz Mart Üniversitesi Bilgisayar Mühendisliği Anabilim dalında hazırladığı aynı isimdeki yüksek lisans tezinden üretilmiştir.

* Bu çalışma Çanakkale Onsekiz Mart Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince Desteklenmiştir. Proje Numarası: **FYL-2023-4610**

Citation/Atf: ÇOKAY, D. & ŞAHIN, E. (2024). Makine Öğrenme Algoritmaları Kullanarak Ses Verilerinde Hastalık Tespiti. *Kuantum Teknolojileri ve Enformatik Araştırmaları*. 2(2): 61-71, DOI: 10.70447/ktve.2422

Corresponding Author/ Sorumlu Yazar:
Duygu Çokay
E-mail: sonmez_duygu@hotmail.com



Bu çalışma, Creative Commons Atif 4.0 Uluslararası Lisansı ile lisanslanmıştır.
This work is licensed under a Creative Commons Attribution 4.0 International License.

Abstract

Detecting diseases at advanced stages reduces recovery rates, complicates the treatment process, and increases the cost of recovery. Therefore, it is important to detect diseases at early stages. Nowadays, machine learning, artificial intelligence, and deep learning methods are widely used in the field of healthcare for medical data analysis and disease detection. Hoarseness is one of the common complaints in the community. Various diseases cause hoarseness, such as vocal cord polyps, laryngeal cancer, acute laryngitis, and vocal cord paralysis. Despite the commonality of hoarseness, these diseases have different causes, treatment processes, and risks. This study aims to classify different diseases that cause hoarseness using audio data before pathological and endoscopic examination. The audio data used in this study were obtained from the Saarbruecken database created by the Saarland University Institute of Phonetics. Classification was performed on audio data from a total of 652 individuals, including those diagnosed with Reinke's edema, laryngitis, cancer or pre-cancerous lesions, polyps, vocal cord paralysis, and healthy individuals. Five different machine learning algorithms were used: k-Nearest Neighbor, Naive Bayes, Decision Tree, Support Vector Machine, and Random Forest. The obtained results were compared using a confusion matrix. According to the results, the highest accuracy rate in distinguishing between diseased and healthy audio was 0.79, achieved by the SVM algorithm.

Keywords: Machine learning, Speech processing, Classification algorithms, Disease detection, Polyp, Laryngitis, Cancer

1. GİRİŞ

Hastalıkların erken evrelerde tespit edilmesi, tedavi süreçleri açısından oldukça önemlidir. Erken teşhis hastalıkların ilerlemesini engelleyebilir, daha etkili tedavilerin uygulanmasını sağlayabilir. Erken teşhisin önemi özellikle kanser gibi hastalıkların tedavisinde belirgindir [1]. Kanser gibi hastalıkların erken aşamalarda tespit edilmesi tedavi başarısını arttırabilir. Bu nedenle Dünya Sağlık Örgütü hastalıkların erken evrede tespitine önem vermektedir.

Günümüzde makine öğrenmesi, yapay zeka, derin öğrenme yöntemleri sağlık alanında tıbbi veriler içerisinde hastalıkları yakalamak ve analiz etmek için yaygın şekilde kullanılmaktadır. Hasta verileri karmaşık ve büyük boyutlu verilerdir. Çoklu veriler üzerinde sınıflama yaparken makine öğrenme algoritmaları hızlı ve yüksek doğruluk oranları elde etmemizi sağlar [2]. Araştırmalar çalışan nüfusun yaklaşık %10'unun ve genel nüfusun %3-%9'unun hayatının herhangi bir döneminde ses kısıklığı ile ilgili bir sorunla karşılaştığını göstermektedir [3].

Ses teli hastalıklarının tanısı; uzman doktor tarafından fiziki muayene, endoskopik muayene, akustik analiz gibi farklı muayeneler ayrı ya da birlikte yapılarak konulur. Sadece ses kısıklığı üzerinden tanı koymak hekim için zordur ve

yanlış tanıya neden olabilir. İnsan kulağının algılayabileceği ve ayırt edebileceği ses özellikleri sınırlıdır. Bu nedenle ses kısıklığı şikayeti ile gelen hasta için hasta hikayesi ve fiziki muayene dışında farklı testler, muayeneler gerekebilir. Endoskopik muayene için gerekli tıbbi donanımın maliyeti yüksektir ve kullanılması uzmanlık gerektirir. Birinci basamak sağlık hizmetleri veren kuruluşlarda (Aile hekimleri vb.) tanısının konması zordur. Ses verisini tanıyıp olası hastalıkları analiz edebilen ve tanı koymada destek sağlayan algoritmalar hekimlerin tanı koymasını kolaylaştırabilir, hatalı tanı oranının azalmasında yardımcı olabilir.

Literatürde ses verileri üzerinde makine öğrenme algoritmaları ve farklı yapay zeka algoritmaları ile sınıflama yapmayı amaçlayan çalışmalar vardır.

Dankovichova vd., [7] yaptıkları çalışmada nörolojik hastalıklar, enfeksiyonlar, doku değişiklikleri gibi nedenlerle seste meydana gelen bozulmaları tespit etmeyi amaçlamışlardır. Çalışmada Saarland Üniversitesi tarafından hazırlanmış ses verilerini kullanmışlardır. Kullanılan 194 sesin 94 ü disfoni (bozuk ses), 100'ü sağlıklı bireylere ait seslerdir. Çalışmada sınıflama yapmak için Destek Vektör Makinesi (SVM) [4], Rastgele Orman (RF) [5], k-En Yakın Komşu (k-NN) [6] algoritmaları kullanılmıştır. Yapılan çalışmada algo-

ritmaların başarı sonuçları %80,3, %80,6, %86,2 olarak bulunmuřtur. Elde edilen sonuçların doęruluk oranlarının yüksek olmasına raęmen alıřmanın eksik yanları, rneklem sayısının kk olması ve algoritmaların sesleri patolojik konuşma bozukluęu var (disfoni) ve saęlıklı ses olarak ayırmasıdır.

Minh Pham ve arkadaşlarının [9] yaptıęı alıřmada kullanılan ses verileri Tayvan'da bulunan Far Eastern Memorial Hastanesi'nden (FEMH) elde edilmiřtir. 50 normal ses rneęi ve vokal nodller, polipler ve kistler, vokal paralizi gibi yaygın ses bozuklukları rneęi bulunmaktadır. alıřmada SVM, RF, kNN ve Gradyan Arttırma (GDA) [8] algoritmaları kullanılmıřtır. Elde edilen sonuçlarda SVM algoritmasının doęruluk oranı %64, RF algoritmasının doęruluk oranı %66, kNN algoritması doęruluk oranı %66, GDA algoritmasının doęruluk oranı %67 olarak tespit edilmiřtir. Yapılan alıřma hastalıkları sınıflamada başarılı sonuçlar vermiřtir. Veri setinin kk olması alıřmanın eksik yndr.

Huiyi Wu ve arkadaşları [10] yaptıkları alıřmada evriřimli sinir aęları kullanılarak saęlıklı ve saęlıksız sesi ayırmayı amalamıřtır. alıřmada Saarbrecken Ses Veritabanı kullanılmıřtır. 482 saęlıklı 482 patolojik tanılı hastaların doęal tonda ve yalnız /a/ sesleri kullanılmıřtır. Elde edilen sonuçlara gre sınıflama başarı oranları eęitim veri setinde, doęrulama veri setinde ve test veri setinde sırasıyla %88, %66, %77 olarak llmřtr. Eęitim veri setinde elde edilen doęruluk doęrulama ve test veri setinden daha iyidir. Bu durum ařırı uyum (overfitting) sorununu ortaya koymaktadır.

Fahad Taha AL-Dhief ve arkadaşları [12] yaptıkları alıřmada Saarland niversitesi Fonetik Enstits tarafından hazırlanan Saarbrecken Ses Veritabanını kullanmıřlardır. alıřmada yalnızca /a/ sesinden oluřan 600 ses verisi kullanılmıřtır. alıřmada saęlıklı ve patolojik (hastalıklı ses) in birbirinden ayrılması amalanmıřtır. alıřmada evrimii Sıralı Ařırı ęrenme Makinesi (OSELM) [11] algoritması kullanılmıřtır. Elde edilen sonuçlar, maksimum doęruluk, duyarlılık ve zgnlk oranlarının sırasıyla %85, %87 ve %87 olduęunu gstermektedir .

Wei Wang ve arkadaşları [14] ses teli polipleri-

nin ses verisi zerinden sıkıřtırılmıř algılama (Compressed sensing) [13] ve SVM algoritması kullanarak tahmin edilmesini saęlayan bir alıřma gerekleřtirmiřlerdir. alıřmada 13 ses teli polipli ve 13 ses teli polipi olmayan hasta olmak zere 26 hastanın ses verisi kullanılmıřtır. Yapılan alıřmada ses sinyali sıkıřtırılmıř algılama teorisi ile yeniden oluřturulmuř ve elde edilen veri destek vektr makineleri yntemi ile sınıflandırılmıřtır. Saęlıklı ve polip sahibi hastaların frekans bileřenlerinin farklı olduęu ve hastanın boęaz polipi olduęunda ses sinyallerindeki dřk frekans bileřeninin daha belirgin şekilde deęiřtięi grlmřtir. Hastaların frekans bileřenleri boęaz polipi olduęunda deęiřebilmektedir. Dolayısıyla, ses sinyallerinin frekans bileřen enerjisi, boęaz polipi tespiti iin zellik olarak kullanılabilir. Deneysel sonuçlara gre alıřma polip varlıęını tespit etmede başarılıdır. alıřmanın eksik yn kullanılan veri setinin kk olmasıdır.

Abdullah H. Al-Nefae ve arkadaşları [15] yaptıkları alıřmada, parkinson hastalıęının ses verisi zerinden tespit edilmesi amalanmıřtır. Arařtırmada k-NN, SVM, RF, Lojistik Regresyon (LR) [16] ve AdaBoost [17] algoritmaları kullanılmıřtır. Bu sınıflandırıcılar, konuşma verilerinden ıkarılan birok fonetik zellik kullanılarak eęitilmiřtir. Elde edilen sonuçlara gre LR algoritması %86, k-NN algoritması %92, SVM algoritması %95, RF algoritması %95, AdaBoost algoritması %93 başarı gstermiřtir. Bu sonuçlar, makine ęrenme yntemlerinin parkinson bireyleri saęlıklı bireylerden ayırt etmede yüksek performans sergiledięini gstermektedir.

Michele Giuseppe Di Cesare ve dięerleri [18], akıllı telefonlarla kaydedilen ses rneklere zerinden eřitli makine ęrenimi yntemleri kullanılarak saęlıklı ve patolojik sesleri ayırt etmeyi incelemiřlerdir. VOICED veri seti kullanılarak yapılan alıřmada, MFCC yntemi ile ses znitelikleri ıkarılmıř ve k-NN yntemi %98,3 doęrulukla en yksek performansı gstermiřtir. Bu bulgular, ses bozukluklarının erken tespiti ve srekli izlenmesi iin akıllı telefonların etkin kullanım potansiyelini vurgulamaktadır.

Verma ve dięerleri [19] yaptıkları alıřmada MFCC ve temel frekans ve spektral centroid kul-

lanarak ses bozukluğu tespiti yapan yenilikçi bir yöntem üzerinde çalışmışlardır. Bu yöntemde, akustik özellikler üzerine eğitilmiş bir yapay sinir ağı (ANN) [20] ve MFCC özellikleri üzerine eğitilmiş bir uzun kısa süreli bellek (LSTM) modeli birleştirilmiştir. Ardından, ANN ve LSTM modelleri tarafından üretilen olasılıklar bir araya getirilerek XGBoost'a [21] girdi olarak kullanılmıştır. Bu yöntem, bir sesin bozuk olup olmadığını daha doğru bir şekilde tespit ederek yüksek doğruluk sağlamıştır. Bu yaklaşım, mevcut tekniklerin ötesine geçerek %95,67 doğruluk, %95,36 duyarlılık, %96,49 özgüllük ve %96,9 F1 skoru ile umut verici sonuçlar elde etmiştir.

Bu çalışmada ses kısıklığına neden olan reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelene, polip, ses teli felci hastalıklarına sahip hastaların ses verileri makine öğrenme algoritmalarıyla sınıflandırılmıştır. Sınıflandırmada k-NN, NB [22], Karar Ağaçları DT [23], SVM ve RF algoritmaları kullanılmıştır. Her makine öğrenme algoritması öncelikle sesleri sağlıklı-hasta olarak iki sınıfa ayırmıştır ve başarı sonuçları karmaşıklık matrisiyle hesaplanmıştır. İkinci olarak her makine öğrenme algoritması için hastalıklar reinke ödemi, akut larenjit, kanser ve kanser öncesi evre, polip, ses teli felci, sağlıklı olmak üzere 6 sınıfa ayrılmıştır. Algoritmaların başarı sonuçları karşılaştırılmıştır.

2. KURAMSAL ÇERÇEVE

2.1.Ses Kısıklığına Neden Olan Hastalıklar

2.1.1 Reinke Ödemi

Reinke ödemi, ses tellerinin ortasındaki iç yüzeyi kaplayan ve titreşimleri oluşturan yumuşak doku tabakasında ortaya çıkan bir hastalıktır. Ses tellerinin şişmesine neden olur ve bu durum da ses kısıklığına yol açar [24].

Reinke ödeminin sigara kullanımı, reflü hastalığı, solunum yolu enfeksiyonları, sesi kötüye kullanma gibi çeşitli sebepleri olabilir. Reinke ödemi tedavisinde hastalığın nedenine göre sigarayı bırakma, ses istirahati, ses terapisi, cerrahi müdahale gibi farklı yöntemler izlenebilir [25].

2.1.2 Akut Larenjit

Akut larenjit genellikle virüs nedenli ses tellerinin ve üst solunum yollarının iltihaplanmasıdır.

Soğuk algınlığı veya viral enfeksiyonlarla ortaya çıkar. Soğuk algınlığı, grip gibi hastalıklarla birlikte ortaya çıktığı için kış mevsimlerinde sıklıkla görülür ve tekrar eder. Ses kısıklığı, ses kaybı, boğaz ağrısı, kuru öksürük, boğazda yanma gibi belirtileri vardır. Akut larenjit genellikle belirtiler temel alınarak teşhis edilir. Fiziksel muayene esnasında doktor genellikle boğazı kontrol eder. Tanı koyma süreci diğer ses kısıklığı hastalıklarına göre nispeten kolaydır. Tedavisi genellikle semptomları hafifletmeye yöneliktir [25].

2.1.3.Ses Teli Polipi

Ses teli polipleri sık görülen ses teli rahatsızlıklarından biridir. Ses teli polipleri genellikle ses tellerinin temas ettiği yüzeylerde oluşan, dokular üzerinde gelişen küçük yumuşak kitlelerdir. Genellikle ses tellerinin aşırı kullanımı ve kötü kullanımı ile gelişir. Ses teli polipleri larinksin en yaygın iyi huylu lezyonlarıdır [26].

2.1.4.Gırtlak Kanseri

Gırtlak kanseri larenks denilen solunum yollarının üst bölgesinde oluşan bir tür kanserdir. Kanser larenks bölgesinin herhangi bir yerinde gelişebilir. Gırtlak kanseri akciğer kanserinden sonra solunum yollarındaki ikinci yaygın kanserdir [27]. Gırtlak kanserinin en belirgin belirtileri ses kısıklığı veya ses değişiklikleri, kulak ve boğaz ağrıları, yutmada ve nefes almada zorlanmadır.

2.1.5.Ses Teli Felci

Ses teli felci sinir hasarı sonucu ses tellerinin normal hareketlerini kaybetmesi durumudur [28]. Bu sinir hasarı ses tellerini kontrol eden farklı sinirlerden kaynaklanabilir. Ses telleri normalde nefes alırken açılır, konuşma halinde kapanır. Ancak ses teli felci durumunda ses tellerinden biri ya da ikisi de hareket edemez.

Ses teli felcinin en yaygın belirtisi ses kısıklığı veya ses kaybıdır. Ses teli felci sesin yoğunluğunu, kalitesini de olumsuz etkileyebilir. Ses teli felcinin yutmada ve nefes almada zorlanma, boğaz ağrısı ve boğazda hassasiyet gibi farklı belirtiler de gözlemlenebilir [29].

2.2 Makine Öğrenme Algoritmaları

Makine öğrenmesi, insan zekasını taklit ederek tasarlanmış, çevredeki ortam verilerinden öğrenerek yeni örnekler için çıkarsama yapan he-


saplamalı bir algoritma dalıdır. Makine öğrenme algoritmalarının genelleme yeteneği örüntü tanıma, bilgisayarla görü, hesaplamalı biyoloji, tıbbi tanıma gibi birçok alanda başarılı şekilde kullanılmaktadır [30].

Yapılan çalışmada makine öğrenme algoritmaları ile sınıflama yapılması amaçlanmıştır. Çalışmada kullanılan makine öğrenme algoritmaları aşağıda açıklanmıştır.

2.2.1. k- En Yakın Komşu (k-Nearest Neighbors)

Basit ve kolay uygulanan bir denetimli öğrenme algoritmasıdır. Sınıflandırma ve regresyon problemlerinde kullanılır. Algoritma yeni bir veri noktasını sınıflandırmak veya tahmin etmek için çevresindeki en yakın komşuları kullanır. Sınıflandırılması planlanan veri k sayısı kadar komşularına bakılarak çoğunluğun üyesi olduğu sınıfa dahil edilir [31].

Şekil 1. k-En Yakın Komşu Algoritması [32]



k-NN algoritmasında bir diğer önemli değer k sayısıdır. k sayısının farklı değerleri sınıflamayı değiştirebilir. k sayısının belirlenmesinde veri setinin boyutu, veri noktalarının dağılımı önemli rol oynar.

2.2.2. Naive Bayes

Naive bayes algoritması bayes teorisine dayanan olasılık tabanlı bir sınıflama algoritmasıdır. Bayes teoremi bir durumun gerçekleşmesi olasılığını, durumun gözlemlenmesinden önceki olaylara bakarak hesaplar [33].

Bayes teoreminin formülü şu şekildedir:

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (1)$$

Formülde,

$P(A|B)$: B olayının gerçekleştiği durumda A olayının gerçekleşme olasılığını temsil eder.

$P(B|A)$: A olayının gerçekleştiği durumda B olayının gerçekleşme olasılığını temsil eder.

$P(A)$: A olayının olasılığını temsil eder.

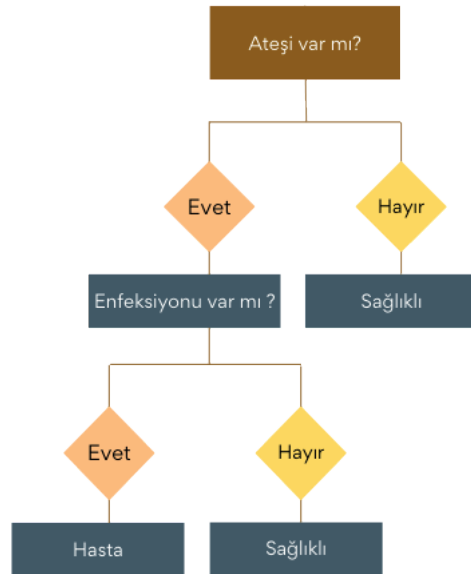
$P(B)$: B olayını temsil eder.

NB algoritması eğitim ve veri setlerini kullanarak sınıflar arası ilişkileri öğrenir. Sınıflama yapabilmek için eğitim veri setinin özelliklerini analiz eder. Bu özellikler kelime frekansları, belirli kelime öbekleri gibi metinsel ya da sayısal değerler olabilir. Sonrasında test verileri noktaları için sınıflar belirlenir. Algoritma her bir sınıf için ait olma olasılığını hesaplar. En yüksek olasılığa sahip olan sınıf seçilir.

2.2.3. Karar Ağaçları (Decision Tree)

DT yaygın kullanılan, basit ve kolay anlaşılır makine öğrenme algoritmalarından biridir. DT etiketlenmiş veri kümesi üzerinden oluşturulur. Etiketlenmiş verilerin desen analizleri yapılır ve yeni verileri sınıflandırmak ya da tahmin etmek için ağaç yapısı şeklinde modeller oluşturulur, her düğümde belli bir kurala dayalı karar alınır.

Şekil 2. Karar Ağaçları



2.2.4. Destek Vektör Makineleri (Support Vector Machine)


Sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenimi modelidir. Denetimli bir öğrenme modelidir. SVM algoritmasında amaç doğrusal olarak ayrılabilir iki sınıfı birbirinden ayırmaktır. SVM algoritması, verileri en iyi şekilde ayıran veya tahmin eden bir hiper-düzlem elde etmeye çalışır. SVM algoritmasının temel fikri, sınıflar arasındaki en geniş aralığı (maksimum margin) elde etmektir [34].

2.2.5. Rassal Orman (Random Forest)

RF algoritması Leo Breiman ve Adele Cutler tarafından geliştirilen, sınıflandırma ve regresyon problemlerinde kullanılabilen bir denetimli öğrenme modelidir [35].


RF algoritması birden fazla karar ağacını (decision tree) bir araya getirerek çalışır ve bu ağaçların sonuçlarını bir araya getirerek bir tahminde bulunur.

Şekil 3. RF Algoritması [36]



3. METARYAL VE YÖNTEM

Şekil 4. Çalışmanın özeti



Çalışmada veri alma ve veri işlemede sağladığı kolaylıklar nedeniyle Python programlama dili kullanılmıştır. Ses dosyalarını yükleme, ses verilerini dönüştürme, sesin özelliklerini çıkarma işlemleri için librosa kütüphanesi kullanılmıştır. Verilerin analiz edilmesi, veri çerçevelerinin

oluşturulması, verilerin tablolar, grafikler ve görseller şeklinde ifade edilebilmesi için Pandas kütüphanesi, veriler üzerinde matematiksel işlemlerin yapılabilmesi için NumPy kütüphanesi kullanılmıştır. Makine öğrenme algoritmaları için Scikit-learn kütüphanesi kullanılmıştır. Verilerin görselleştirilmesi için Matplotlib kütüphanesi kullanılmıştır. Çalışmada 12th Gen Intel(R) Core(TM) i5 2.50 GHz işlemci ve 32 gb ram kapasiteli bilgisayar kullanılmıştır.

3.1. Kullanılan Veri Seti

Çalışmada Saarland Üniversitesi Fonetik Enstitüsü tarafından oluşturulan ve <https://stimmdb.coli.uni-saarland.de/> sitesinde çevrimiçi paylaşılan Saarbruecken Ses Veritabanı kullanılmıştır. Saarbruecken veritabanı 71 farklı patolojiyi içeren zengin bir veritabanıdır. Veritabanında 2000'den fazla bireyin ses kayıtları vardır. Hastalardan alınan ses kayıtları /i/, /a/, /u/ sesleri şeklinde normal yüksek ve alçak ses tonlarında wav formatında kaydedilmiştir. Kayıtlar 50 kHz örnekleme frekansında ve 16-bit çözünürlükte, "wav" uzantısı ile kaydedilmiştir.

Çalışmada 176 ses teli felci hastasına ait 1581 ses verisi, 82 larenjit tanılı hastaya ait 738 ses verisi, 35 kanser öncüsü lezyon veya kanser hastasına ait 315 ses verisi, 27 polip tanılı hastaya ait 243 ses verisi, 34 reinke ödemi tanılı hastaya ait 306 ses verisi ve 298 sağlıklı hastadan alınan 2682 ses verisi olmak üzere toplamda 652 hastaya ait 5865 ses verisi veri seti olarak kullanılmıştır. Çalışmada kullanılan sesler cinsiyet ve yaşa göre ayrılmamış patolojik sınıftaki tüm sesler veri setine dahil edilmiştir.

Çizelge 1. Çalışmada kullanılan veriler ve sayıları

Çalışma Kapsamında Kullanılan Veri Seti		
Hastalıklar	Hasta Sayısı	Ses Dosyası Sayısı
Ses teli felci	176	1581
Larenjit	82	738
Kanser öncüsü lezyon veya kanser	35	315
Polip	27	243
Sağlıklı	298	2682
Reinke ödemi	34	306
Toplam	652	5865

3.2. Veri Ön İşleme

Veri ön işleme veri setlerinin temizlenmesi, düzenlenmesi ve hazırlanması sürecidir. Bu adım, modelin verimli bir şekilde eğitilmesini sağla-

mak ve modelinizin performansını artırmak için önemlidir.

Makine öğrenimi modellerini eğitmeden önce, veri özellikleri standartlařtırmak veri setindeki özelliklerin dağılımını standart bir hale getirir ve modelin daha iyi performans göstermesini sağlar. Özellikler arasındaki büyük farklar, modelin doğruluğunu olumsuz etkileyebilir. Farklı ölçeklerdeki özellikler arasında model karşılařtırması yaparken, özelliklerin standartlařtırılmış olması, modellerin doğru bir şekilde karşılařtırılmasını sağlar. Bu nedenle makine öğrenme algoritmaları öncesi veri standardizasyonu yaygın bir uygulamadır. Yapılan çalışmada yüklenen veri seti üzerinde eğitim ve test verisi olarak bölünmeden önce standartlařtırma işlemi yapılmıştır.

Şekil 5. Veri standartlařtırmanın kodla gösterimi

```
# accuracy artırmak için verileri scale etme
scaler = StandardScaler()
X = scaler.fit_transform(np.array(X))

# train_test_split ile test ve train setleri oluşturma
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=0)
```

3.3.Öznitelik Çıkarımı

Ses verisinde öznitelik çıkarımı, ses sinyallerinden anlamlı özelliklerin çıkarılması işlemidir. Bu özellikler, ses verisini sayısal bir formata dönüřtürerek makine öğrenimi modellerinin anlayabileceği bir şekilde getirir. Sesin özelliklerini elde etmemizde kullanılan bazı ses özellikleri vardır. Örneğin ses dosyaları genellikle dalga formunda gelir ve bu dalga formu, örnekleme frekansı ve bit derinliđi gibi özelliklere sahiptir.

Çalışmada ses verisi elde edildikten sonra öznitelik çıkarımı için Mel-Frekans Öznitelik Katsayıları (MFCC) yöntemi kullanılmıştır. MFCC sesin frekans içeriđini temsil etmek için birçok konuşma tanıma sisteminde yaygın olarak kullanılan bir özelliktir [37]. MFCC, bir ses sinyalinin özelliklerini temsil etmek için kullanılan bir dizi katsayıdır ve bu katsayılar sesin frekans ve zaman özelliklerini temsil eder. MFCC, insan kulađı ölçeđine dayanan Mel ölçeđini kullanarak frekans alanında temel alan konuşma tanıma sistemlerinde kullanılan en popüler özellik çıkarım tekniklerinden biridir [38].

Mel-Frekans Öznitelik Katsayıları ses sinyallerinin zaman-frekans alanındaki özelliklerini yaka-

lamak için ses sinyalinin kesilmesi, pencereleme, Fourier dönüřümü, Mel-Frekans Filtre Bankası Uygulaması, logaritmik dönüřüm olmak üzere bir dizi adımdan geçer. Bu aşamaların sonunda her çerçeve için bir MFCC vektörü elde edilir. Bu vektörler, ses sinyalinin zaman içindeki deđişimini temsil eder ve makine öğrenimi modelleri için girdi olarak kullanılabilir.

3.4.Ses verisinin Bölünmesi ve Modelin Eğitilmesi

Bu tez çalışmasında veri seti eğitim ve test verisi olarak %80 ve %20 oranlarında bölünmüřtür. Verilerin bölünmesinde scikit-learn kütüphanesinde 'train_test_split' fonksiyonu kullanılmıştır. Eğitim ve test verisi oluşturulurken rastgelelik kontrolü için kullanılan 'random_state' parametresi 0 olarak belirlenmiştir. DT, k-NN, NB, SVM ve RF olmak üzere 5 algoritma reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sađlıklı sınıflara ayrılan ses verileri üzerinde kullanılmıştır. Algoritmaların her biri öncelikle tüm ses verileri içerisinde yalnızca sađlıklı sesleri ayırmıştır. Başka bir ifadeyle her bir makine öğrenme algoritması ile öncelikle sađlıklı-sađlıksız ses ayrımı yapılmıştır. Sonrasında her bir makine öğrenme algoritması ses verilerini ses patolojilerine göre ayırmıştır.

3.5 Modelin Deđerlendirilmesi

Çalışmada elde edilen sonuçlar karmařıklık matrisi kullanılarak deđerlendirilmiştir. Karmařıklık matrisi algoritmaların performansını deđerlendirmek için kullanılan bir deđerlendirme aracıdır. Karmařıklık matrisi gerçek sınıf tanımlarını ve çalışılan modelin tahminlerini kullanarak dört kategori elde etmemizi sağlar:

- 1.True Pozitif (TP): Gerçekte pozitif olan örneklerin, model tarafından doğru şekilde pozitif olarak tahmin edilmesidir. (Hasta kişilerin hasta sınıfında tanımlanması)
- 2.False Pozitif (FP): Gerçekte negatif olan örneklerin model tarafından yanlış tanımlanarak pozitif olarak tahmin edilmesidir. (Sađlıklı olan kişilerin hasta sınıfında tanımlanması)
- 3.True Negatif (TN): Gerçekte negatif olan örneklerin model tarafından doğru olarak negatif

sınıfında tanımlanmasıdır. (Sağlıklı olan kişilerin sağlıklı sınıfında tanımlanması)

4.False Negatif (FN): Gerçekte pozitif olan örneklerin model tarafından yanlış tahmin edilerek negatif olarak tanımlanmasıdır. (Hasta kişilerin yanlışlıkla sağlıklı olarak tanımlanması)

Karmaşıklık matrisi doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skoru gibi performans ölçümleri hesaplamak için kullanılmaktadır ve aşağıda formülleri verilmektedir [39].

$$\text{Doğruluk (accuracy)} = \frac{1}{k} \sum_{i=1}^k \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \quad (2)$$

$$\text{Hassasiyet (precision)} = \frac{1}{k} \sum_{i=1}^k \frac{TP_i}{TP_i + FP_i} \quad (3)$$

$$\text{Duyarlılık (recall)} = \frac{1}{k} \sum_{i=1}^k \frac{TP_i}{TP_i + FN_i} \quad (4)$$

$$F1 = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (5)$$

Burada TP_i , TN_i , FP_i ve FN_i ; i etiketi için sırasıyla gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatifin sayısıdır. Ayrıca k toplam etiketlerin sayısıdır.

4.ARAŞTIRMA BULGULARI

4.1. k-En Yakın Komşu Algoritmasından Elde Edilen Sonuçlar

k-NN algoritmasının sağlıklı ve hasta sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 2. k-NN algoritmasının sağlıklı-hasta sınıflandırma sonuçları

Algoritma Adı	Doğruluk	Hassasiyet	Duyarlılık	F1
k-NN	0,76	0,79	0,76	0,77

k-NN algoritmasının veri setindeki reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sağlıklı sınıflarının sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 3. k-NN algoritmasının hastalık sınıflandırma sonuçları

Hastalık	Doğruluk	Hassasiyet	Duyarlılık	F1
Felç	0,65	0,68	0,65	0,66
Larenjit	0,55	0,59	0,55	0,57
Kanser	0,60	0,65	0,60	0,62
Polip	0,40	0,43	0,40	0,42
Reinke Ödemi	0,42	0,42	0,42	0,42
Sağlıklı	0,76	0,73	0,76	0,74

4.2. Naive Bayes Algoritmasından Elde Edilen Sonuçlar

NB algoritmasının sağlıklı ve hasta sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir. Çalışmada Gaussian Naive Bayes sınıflandırıcısı kullanılmıştır.

Çizelge 4. NB algoritmasının sağlıklı-hasta sınıflandırma sonuçları

Algoritma Adı	Doğruluk	Hassasiyet	Duyarlılık	F1
Naive Bayes	0,64	0,65	0,73	0,69

NB algoritmasının veri setindeki reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sağlıklı sınıflarının sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 5. NB algoritmasının hastalık sınıflandırma sonuçları

Hastalık	Doğruluk	Hassasiyet	Duyarlılık	F1
Felç	0,49	0,43	0,49	0,46
Larenjit	0,19	0,23	0,19	0,20
Kanser	0,01	0,12	0,01	0,03
Polip	0,0	0	0	-
Reinke Ödemi	0,01	0,5	0,01	0,03
Sağlıklı	0,70	0,57	0,70	0,63

4.3. Karar Ağaçları Algoritmasından Elde Edilen Sonuçlar

DT algoritmasının sağlıklı ve hasta sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 6. DT algoritmasının hastalık sağlıklı-hasta sınıflandırma sonuçları

Algoritma Adı	Doğruluk	Hassasiyet	Duyarlılık	F1
Karar Ağaçları	0,66	0,69	0,69	0,69

DT) algoritmasının veri setindeki reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sağlıklı sınıflarının sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 7. DT algoritmasının hastalık sınıflandırma sonuçları

Hastalık (DT)	Doğruluk	Hassasiyet	Duyarlılık	F1
Felç	0,48	0,46	0,48	0,47
Larenjit	0,14	0,26	0,14	0,18
Kanser	0,08	0,19	0,08	0,12
Polip	0,0	0	0	-
Reinke Ödemi	0,05	0,27	0,05	0,08
Sağlıklı	0,78	0,59	0,78	0,67

4.4. Destek Vektör Makinalarından Elde Edilen Sonuçlar

SVM algoritmasının sağlıklı ve hasta sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 8. Destek Vektör Makinaları algoritmasının sağlıklı-hasta sınıflandırma sonuçları

Algoritma Adı	Doğruluk	Hassasiyet	Duyarlılık	F1 skoru
SVM	0,79	0,82	0,78	0,80

SVM algoritmasının veri setindeki reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sağlıklı sınıflarının sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 9. SVM algoritmasının hastalık sınıflandırma sonuçları

Hastalık (SVM)	Doğruluk	Hassasiyet	Duyarlılık	F1 skoru
Felç	0,68	0,67	0,68	0,68
Larenjit	0,45	0,59	0,45	0,51
Kanser	0,48	0,61	0,48	0,54
Polip	0,22	0,42	0,22	0,29
Reinke Ödemi	0,30	0,64	0,30	0,41
Sağlıklı	0,84	0,71	0,84	0,77

4.5. Rassal Orman Algoritmasından Elde Edilen Sonuçlar

RF algoritmasının sağlıklı ve hasta sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 10. RF algoritmasının sağlıklı-hasta sınıflandırma sonuçları

Algoritma Adı	Doğruluk	Hassasiyet	Duyarlılık	F1 skoru
RF	0,77	0,77	0,82	0,79

RF algoritmasının veri setindeki reinke ödemi, akut larenjit, kanser ve kanser öncesi lekelenme, polip, ses teli felci ve sağlıklı sınıflarının sesleri ayırmasında elde edilen doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skorları aşağıda tabloda verilmiştir.

Çizelge 11. RF algoritmasının hastalık sınıflandırma sonuçları

Hastalık (RF)	Doğruluk	Hassasiyet	Duyarlılık	F1 skoru
Felç	0,57	0,64	0,57	0,60
Larenjit	0,23	0,65	0,23	0,34
Kanser	0,14	0,72	0,14	0,23
Polip	0,02	1	0,02	0,04
Reinke Ödem	0,06	1	0,06	0,12
Sağlıklı	0,92	0,60	0,92	0,73

5. SONUÇ VE TARTIŞMA


Yapılan çalışmada öncelikle ses kısıklığına neden olan reinke ödemi, larenjit, kanser ya da kanser öncesi lekelenme tanısı bulunan, polip, ses teli felçli ve sağlıklı hastalardan oluşan toplamda 652 kişiye ait ses verisi kullanılmıştır. Bu veriler üzerinde k-NN, NB, DT, SVM, RF olarak beş farklı makine öğrenme algoritmaları uygulanmıştır. Her bir algoritma için sağlıklı-hastalıklı ses sınıflandırması yapılmış ve sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre hastalıklı-sağlıklı ses ayırmasında en yüksek doğruluk oranı 0,79 ile SVM algoritmalarından elde edilmiştir.

Yaptığımız çalışmada ikinci olarak k-NN, NB, DT, SVM, RF algoritmaları ile reinke ödemi, larenjit, kanser ya da kanser öncesi lekelenme tanısı bulunan, polip, ses teli felçli ve sağlıklı şekilde sınıflama yapılmıştır. Elde edilen sonuçlara göre algoritmaların doğruluk oranları aşağıdaki çizelgede verilmiştir.

Çizelge 12. Algoritmaların hastalıkları sınıflamadaki doğruluk oranları

Hastalık	k-NN	NB	DT	SVM	RF
Felç	0,65	0,49	0,48	0,68	0,57
Larenjit	0,55	0,19	0,14	0,45	0,23
Kanser	0,60	0,01	0,08	0,48	0,14
Polip	0,40	0,0	0,0	0,22	0,02
Reinke Ödemi	0,42	0,01	0,05	0,30	0,06
Sağlıklı	0,76	0,70	0,78	0,84	0,92

Şekil 6. Algoritmaların hastalıkları sınıflama başarıları



Elde edilen sonuçlara göre hastalıkları sınıflamada en iyi sonucu k-NN algoritması vermiştir. Sınıflamada en başarısız algoritma NB algoritmasıdır. Ses verilerinin patolojilerine göre sınıflanmasında tüm algoritmalarda sağlıklı sınıfı en yüksek doğruluk oranı ile ayrılmıştır. Patolojilerine göre sınıflamada tüm algoritmalarda ikinci yüksek doğruluk oranı ses teli felci sınıfını ayırmada tespit edilmiştir. En başarısız sınıflanan ses verisi polip hastalarına aittir. Elde edilen sonuçlara göre doğruluk oranının veri setinde kullanılan ses verilerinin sayısı ile doğru orantılı olduğu gözlemlenmiştir. En yüksek doğruluk oranıyla sınıflanan ‘sağlıklı’ sesler 2682 adet ses verisiyle veri setinin en büyük sınıfını oluşturmaktadır. Benzer şekilde veri setinin en küçük sınıfı olan 243 ses verisiyle polip sınıfı çalışmada en düşük doğruluk oranıyla sınıflandırılmıştır.

Yapılan çalışma farklı makine öğrenme algoritmalarının ses verileri üzerindeki performansını sunmaktadır. Çalışma sağlıklı-hastalıklı ses verilerini ayırmada başarılı sonuçlar vermiştir. Fakat çalışma hastalıkları sınıflamada yetersizdir. Gelecekteki çalışmalarda veri seti genişletilip zenginleştirilerek algoritmaların tekrar çalıştırılması planlanmaktadır. Çalışmada öznitelik çıkarımı yalnızca MFCC ile yapılmıştır. Gelecekteki çalışmalarda farklı öznitelik çıkarım yöntemlerinin sınıflama başarısına etkisi araştırılacaktır. Ayrıca olarak gelecekteki çalışmalarda mevcut sınıflandırma algoritmalarının performansını artırmak için hiperparametre optimizasyonu yapılması planlanmaktadır. Son olarak ise literatürdeki fuzzy (bulanık) parametrelili fuzzy esnek sınıflandırıcılar üzerinde araştırmalar gerçekleştirilip, çalışmanın bu açıdan analizleri yapılacaktır.

KAYNAKÇA

- [1] TC. Sağlık Bakanlığı, *Erken teşhis hayat kurtarır*. <https://www.saglik.gov.tr/TR,19826/erken-teshis-hayat-kurtarir.html>, 2016. (Erişim tarihi:15.04.2024).
- [2] Lundberg, S. M., Nair, B., Vavilala, M. S., Horibe, M., Eisses, M. J., Adams, T., Liston, D.E., Low, D. K. W., Newman, S. F., Kim, J. *Explainable machinelearning predictions for the prevention of hypoxaemia during surgery*, Nature biomedical engineering, 2(10), 749-760, 2018.
- [3] Verdolini, K., Ramig, L. O. *Occupational risks for voice problems*. Logopedics phoniatrics vocolog. 26(1), 37-46, 2001.
- [4] Cortes, C., Vapnik, V. *Support-vector networks*. Machine learning, 20, 273-297, 1995.
- [5] Breiman, L., *Random forests*. Machine learning, 45, 5-32, 2001.
- [6] Cover, T., Hart, P., *Nearest neighbor pattern classification*, IEEE Trans. Inf. Theory, 13, 21-27, 1967.
- [7] Dankovičová, Z., Sovák, D., Drotár, P., Vokorokos, L., *Machine learning approach to dysphonia detection*. Applied sciences, 8(10), 2018.
- [8] Khaneja, N., Reiss, T., Kehlet, C., Schulte-Herbrüggen, T., Glaser, S. J. *Optimal control of coupled spin dynamics: design of NMR pulse sequences by gradient ascent algorithms*. Journal of magnetic resonance, 172(2), 296-305, 2005.
- [9] Pham, M., Lin, J., Zhang, Y. *Diagnosing voice disorder with machine learning*, IEEE International conference on big data (big data), 2018.
- [10] Wu, H., Soraghan, J., Lowit, A., Di Caterina, G. *Convolutional neural networks for pathological voice detection*, 40th Annual International Conference of the IEEE Engineering in medicine and biology society (EMBC), 2018.
- [11] Gandhi, A. M., Shanmugan, S., Gorjian, S., Pruncu, C. I., Sivakumar, S., Elsheikh, A. H., Panchal, H. *Performance enhancement of stepped basin solar still based on OSELM with traversal tree for higher energy adaptive control*. Desalination, 502, 114926, 2021.
- [12] AL-Dhief, F. T., Latiff, N. M. A. A., Malik, N. N. N. A., Sabri, N., Baki, M. M., Albadr, M. A. A., Abbas, A. F., Hussein, Y. M., Mohammed, M. A., *Voice pathology detection using machine learning technique*. IEEE 5th International symposium on telecommunication technologies (ISTT), 2020.
- [13] Donoho, D., L., *Compressed sensing*. IEEE Transa-

- ctions on information theory, 52.4: 1289-1306, 2006.
- [14] Wang, W., Chen, Z., Mu, J., Han, T. *Throat polyp detection based on compressed big data of voice with support vector machine algorithm*, Eurasip journal on advances in signal processing, 1-6, 2014.
- [15] Al-nefaie, A. H., Aldhyani, T. H., Koundal, D.. *Developing system-based voice features for detecting parkinson's disease using machine learning algorithms*. JDR. 2024. Vol. 3(1). DOI: 10.57197/JDR-2024-0001.
- [16] Menard, S.. *Applied logistic regression analysis*. Sage Publications, Inc., 2002, <https://doi.org/10.4135/9781412983433>.
- [17] Schapire, Robert E. *Explaining adaboost*. Empirical inference: festschrift in honor of Vladimir N. Vapnik. Berlin, Heidelberg, Springer Berlin Heidelberg, p. 37-52 2013.
- [18] Di Cesare, M. G., Perpetuini, D., Cardone, D., Merla, A., *Assessment of voice disorders using machine learning and vocal analysis of voice samples recorded through smartphones*. BioMedInformatics, 4.1: 549-565, 2024.
- [19] Verma, V., Benjwal, A., Chhabra, A. *A novel hybrid model integrating MFCC and acoustic parameters for voice disorder detection*, *Sci Rep* **13**, 22719, 2023.
- [20] Zhang, Z., Zhang, Z. *Artificial neural network*. In: Multivariate time series analysis in climate and environmental research, Springer, pp.1-35, 2018.
- [21] Chen, T., *Xgboost: extreme gradient boosting*. *R package version 0.4-2,1.4*: 1-4, 2015.
- [22] Rish, I., *An empirical of the naive bayes classifier*. IJCAI 2001 workshop on empirical methods in artificial intelligence. 41-46, 2001.
- [23] Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J. *Classification and regression trees*, 3rd ed., CRC Press: Wadsworth, OH, USA, 1998.
- [24] Jones, N. N., Song, S. A. *Reinke edema*, StatPearls Publishing, pp. 2-5, 2023.
- [25] Deem, J. F., Miller, L. *Manual of voice therapy*, PRO-ED, Inc., pp.77-100, 2000.
- [26] Kleinsasser, O. *Pathogenesis of vocal cord polyps*. Annals of otology, rhinology laryngology, 91(4), 378-381, 1982.
- [27] Cattaruzza, M., Maisonneuve, P., Boyle, P. *Epidemiology of laryngeal cancer*. European journal of cancer part b: oral oncology, 32(5), 293-305, 1996.
- [28] Terris, D. J., Arnstein, D. P., Nguyen, H. H., *Contemporary evaluation of unilateral vocal cord paralysis*. Otolaryngology-head and neck surgery, 107(1), 84-90, 1992.
- [29] Tucker, H. M. *Vocal cord paralysis etiology and management*. The Laryngoscope, 90(4), 585-590, 1980.
- [30] El Naqa, I., Murphy, M. J. *What is machine learning?*, Machine Learning in Radiation Oncology, pp.3-11, Springer, 2015.
- [31] Cover, T., Hart, P. *Nearest Neighbor Pattern Classification*. *IEEE Transactions on Information Theory*, 13(1), 1967, 21-27.
- [32] Towards Data Science, *kNN (k-En Yakın Komşular)*, Erişim Tarihi: [11/05/2024], <https://towardsdatascience.com/knn-k-nearest-neighbors-1-a4707b24bd1d>, 2018.
- [33] Flach, P. A., Lachiche, N. *Naive bayesian classification of structured data*, machine learning, 57, 233-269, 2004.
- [34] Vapnik, V. *The nature of statistical learning theory*, Springer science business media, 267-290, 2013.
- [35] Grömping, U. *Variable importance assessment in regression: linear regression versus random forest*, The American Statistician, 63(4), 308-319, 2009.
- [36] Viswanathan, V. K. *Surface-level understanding of random forest regression*, medium, 2023. <https://medium.com/@vk.viswa/surface-level-understanding-of-random-forest-regression-3bac37e06f3e>
- [37] Young, S. *A review of large-vocabulary continuous-speech*. IEEE signal processing magazine, 13(5), 45, 1996.
- [38] Shen, P., Changjun, Z., Chen, X. *Automatic speech emotion recognition using support vector machine*. Proceedings of 2011 international conference on electronic mechanical engineering and information technology, 2011.
- [39] Memiş, S., Enginoğlu, S., Erkan, U. *Fuzzy parameterized fuzzy soft k-nearest neighbor classifier*. Neurocomputing, 500, pp. 351 – 378, 2022.