



AREL ÜNİVERSİTESİ SAĞLIK BİLİMLERİ DERGİSİ

JOURNAL OF HEALTH SCIENCES AREL UNIVERSITY

Web sayfası (Homepage): <https://dergipark.org.tr/tr/pub/arsagbil>



Araştırma makalesi

Mobil Alt Yapılar ile Spirometri Sonuçlarının Hesaplanması ve Nefes, Fonasyon, Öksürük Seslerinden Akciğer Hastalıklarının Tespiti

Oğuzhan Aydemir^{1*}, Gökhan Aydemir², Sude Cansu Turgut³

¹Haliç Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul, Türkiye
E-mail: oguzhan.aydemir@nisantasi.edu.tr Orcid: 0000-0002-1611-0947

²Haliç Üniversitesi, Çocuk Hastalıkları ve Sağlığı Bölümü, İstanbul, Türkiye E-mail: gokhanaydemir@halic.edu.tr
Orcid: 0000-0001-9655-0530

³New Senses Uzay Teknoloji ve Sağlık Araştırmaları A.Ş., İstanbul, Türkiye
E-mail: sudecansutrgt@outlook.com Orcid: 0000-0003-4993-7905

ÖZET

Bu çalışmada, zorlu vital kapasitesinin mobil alt yapılar ile hesaplanarak “Forced Expiratory Volume” (FEV- Zorlu Ekspiratuvar Volümü) ve “Forced Vital Capacity” (FVC - Zorlu Vital Kapasite) değerlerinin oluşan desibel farkından tespit edilmesi ve ses öznitelik vektörleri kullanılarak yapay sinir ağları yardımı ile nefes, fonasyon ve öksürük ses verileri ile ilişki kurularak akciğer hastalıklarının tespit edilmesi amaçlanmıştır. Çalışmamızda, zorlu vital kapasitesinin tespitinde desibel türünden güç farkını hesaplamak ve astım gibi hastalıkları tespit edecek bir yapay zekâ geliştirerek bu değerlerden faydalanan bir algoritma geliştirmek üzere mobil bir yöntem geliştirilmiştir. Spirometrik sonuçları elde edebilmek için öncelikle ortamın desibel türünden gürültüsü her test önce belirlenmiştir. Çalışmamızda güçlü ekspirasyon sonucu oluşan yeni gürültü desibel türünden hesaplanmıştır. FEV değeri, net güç farkının (Nefes Kalibrasyonu-Ortam Kalibrasyonu) hesaplanarak çıkan sonucun LOGe alınması ile sonuçlandırılmıştır. Çalışmamızda, geliştirdiğimiz yapay zekanın yararlanacağı spirometri değerlerinin zorlu vital solunum sonrası oluşan güç farklılıklarını desibel cinsinden anlamlandırarak oluşturduğumuz matematiksel bir uyumlama ve semptom sezgilime modeli yer almaktadır. Ayrıca iki farklı veri kümesinden oluşturulan yeni bir veri kümesi kullanılmış olup; bu yeni veri kümesi içerisindeki her bir sesin, “Mel Frequency Cepstral Coefficients” (MFCC - Mel Frekans Cepstral Katsayıları) Mel frekans cepstral katsayıları çıkarılan ve png formatında spectrogram grafiklerine dönüştürülmüştür. Resim formatına dönüştürülmüş sesler, derin öğrenme algoritmalarından “Convolutional Neural Networks” (CNN - Evrimsel Sinir Ağları) ağı ile sınıflandırılmıştır. Bu çalışmada, güçlü vital solunum sonrası FEV ve FVC değerleri geliştirilen matematiksel formülle hesaplanarak yapay zekamızın akciğer kaynaklı hastalıkların teşhisinde kullanılabilecek şekilde yararlanması sağlanmıştır. Ayrıca mobil alt yapılar ile elde edilen bu değerlerin klasik tıbbi literatüre bağlı kalınarak ön değerlendirme ile bazı hastalıklar yönünden değerlendirilebileceği sonucuna vardık.

Anahtar Kelimeler: Ekspirasyon, MFCC, Yapay zekâ, Zorlu vital kapasite

Calculation of Spirometry Results with Mobile Infrastructures and Detection of Lung Diseases from Breathing, Phonation and Cough Sounds

ABSTRACT

This study aims to calculate forced vital capacity with mobile infrastructures and determine FEV and FVC values from the resulting decibel difference, and to detect lung diseases by establishing a relationship with breathing, phonation and cough sound data with the help of artificial neural networks using sound feature vectors. In our study, a mobile method was developed to calculate the power difference in decibels in determining forced vital capacity and to develop an algorithm that uses these values by developing artificial intelligence to detect diseases such as asthma.

Başvuru: 2 Ekim 2023 **Kabul:** 19 Ekim 2023

***Sorumlu yazar:** oguzhan.aydemir@nisantasi.edu.tr

Dergi maili: sbfdergisi@arel.edu.tr

Dergi kısaltmalar: Arel Ü. S. Bil. Derg.

J. H. Sci. Arel U.

To obtain spirometric results, the ambient noise in decibels was determined before each test. In our study, the new noise resulting from strong expiration was calculated in decibels. The FEV value was concluded by calculating the net power difference (Breathing Calibration-Environment Calibration) and taking the result as LOGe. Our study includes a mathematical adaptation and symptom detection model that we created by interpreting the power differences that occur after forced vital breathing in decibels of the spirometry values that the artificial intelligence we developed will benefit from. Additionally, a new dataset created from two different datasets was used: The MFCC (Mel Frequency Cepstral Coefficients) Mel frequency cepstral coefficients of each sound in this new data set were extracted and converted into spectrogram graphics in png format. The sounds converted into picture format were classified with Convolutional Neural Networks (CNN) network, one of the deep learning algorithms. In this study, FEV and FVC values after intense vital breathing were calculated with the developed mathematical formula, enabling our artificial intelligence to diagnose lung-related diseases. We also concluded that these values obtained with mobile infrastructures could be evaluated in terms of some diseases with preliminary evaluation by adhering to the classical medical literature.

Keywords: Expiration, MFCC, Artificial intelligence, Forced vital capacity

1. GİRİŞ

Her canlı gibi insanoğlu da yaşamı boyunca hep bir olay akışı içerisinde hareket etmektedir. Hayatın olağan yoğunluğu içerisinde, uyuyup uyanır, besin ihtiyacı duyumsar, bir yerden bir yere hareket ederiz. Bilinçli gerçekleşen bu sürekliliğe, vücudumuzda senkronize bir şekilde uyum gösterir. Örneğin, hızlı bir tempoda hareket edersek, nefes alıp verişimiz bu hıza uygun hale gelir ya da uyku halinde metabolizmamız yavaşlar. Bunların dışında vücudumuzun hem günlük eylemlerimizle bir senkronizasyon oluşturduğunu hem de kendi içerisinde bir senkronizasyonla hareket ettiği açıktır. Buna en iyi örnek, nefes alıp vermenin de içinde bulunduğu solunum sistemidir. Solunum sisteminin kandaki karbondioksit (CO₂) gazını oksijen (O₂) ile değiştirme yeteneği, insan fizyolojisi açısından önemlidir (Wikipedia, 2023). İstanbul İl Sağlık Müdürlüğü ve Medipol Üniversitesi etik izni ile oluşturulan kontrol gruplarından veri toplanmıştır. Çalışma için Sağlık Bakanlığı onayı etik izin öncesi alınarak klinik veri toplama çalışmalarına başlanmıştır. Çalışmamızın hedefi, tidal volüm kapasitesinin mobil alt yapılar ile hesaplanarak FEV ve FVC değerlerinin, desibel türünden tespit edilmesini sağlayan matematiksel bir metot ile ses öznitelik vektörleri kullanılarak yapay sinir ağları yardımı ile nefes, fonasyon ve öksürük sesinden akciğer hastalıklarının teşhis amacıyla sınıflandırılmasıdır.

Akciğer volüm ve kapasiteleri yaş, cinsiyet ve boy uzunluğu ile değişkenlik gösterebilmektedir (Ankara Üniversitesi, 2023). Ölçüm sırasındaki pozisyon, kişinin antrene olup olmaması, kilo hatta ırk gibi faktörler, ortam sıcaklığı ve basıncı gibi fiziksel durumlar akciğer volümleri üzerine etkilidir (Ankara Üniversitesi, 2023). Dinamik solunum fonksiyon testleri, belirli bir zaman aralığında akciğer ekspirasyon ve inspirasyon sırasında volüm ve kapasiteleri ölçülerek veya ekspirasyon ve inspirasyon akım hızları hesaplanarak bulunur (Ankara Üniversitesi, 2023). En çok kullanılan dinamik solunum fonksiyon testleri şunlardır:

- 1. Zorlu vital kapasite (forced vital capacity, FVC):** Hızlı bir nefes vermeyele akciğerlerden çıkarılabilecek toplam hava miktarıdır; bu, nötr pH'ı korurken kendinizi mümkün olduğunca nefes almaya zorlayarak gerçekleştirilir. Tipik koşullarda inspirasyon 2 saniye sürdürüldüğü ve ekspirasyon 3 saniyede tamamlandığı için (solunum frekansı ortalama 12/dk), zorlu ekspirasyon hacmi (FEV) ve birinci, ikinci ve üçüncü anlar (FEV1, FEV2, FEV3) de belirlenir. Bu değerlerin FVC'ye göre yüzdesel payları anlamlıdır (%FEV1/FVC, FEV2/FVC ve FEV3/FVC). Tipik değerlerin alt sınırları sırasıyla %80, 85 ve 95'tir. Bunlardan en önemlisi ve en sık kullanılanı, %FEV1/FVC oranıdır (Ankara Üniversitesi, 2023).
- 2. Maksimal ekspirasyon akım volüm eğrisi ve ekspirasyon akım hızları:** Zorunlu ekspiratuar akış eğrisi şu şekilde elde edilir: Dinamik solunum fonksiyon testinin spirometri diyagramının x eksenini, zorlu vital kapasitede toplam vital kapasiteden başlayarak ekshale edilen hava miktarıdır ve y eksenini akış hızıdır (Ankara Üniversitesi,

2023). Maksimum ekspiratuar akış, kuvvetli bir şekilde nefes verirken dışarı verilen hava akışının maksimum olduğu değerdir.

- 3. Maksimum solunum kapasitesi (maksimum istemli ventilasyon, maximum voluntary ventilation, MVV):** 1 dakikadaki maksimum spontan ventilasyondur. 12-15 saniyelik bir testle ölçülür. Normal akciğer ventilasyonu, 6 L/dk'dır. Bu değer, teorik olarak VC (Vital Kapasite) x 30'a kadar çıkabilmektedir. Ancak eğitimsiz bireylerde bu değer maksimum değer yaklaşık %68'i kadar olabilirken eğitimli bireylerde %75'e çıkabilmektedir.

Solunum fonksiyon testleri, solunum yolu hastalıklarının teşhisine yardımcı olur. Birçok solunum yolu hastalığında, VC ve MVV azalır. Ancak hava yollarının içinde veya dışında oluşan lezyonlar (obstrüktif akciğer hastalığı) nedeniyle hava yolu direncinin artması durumunda RV'de artış, FVC ve FEV/FVC oranında azalma gözlenir. İspirasyon sırasında göğüs veya akciğerlerin genişleme yeteneğinin sınırlı olduğu hastalıklarda (restriktif akciğer hastalığı), VC'deki azalmaya FEV/FVC oranında bir değişiklik ve akciğer hacminde azalma eşlik etmez (Ankara Üniversitesi, 2023). Spirometreler ile ölçülebilen akciğer hacim ve kapasiteleri ise literatürde genel olarak aşağıda yer aldığı gibi açıklanır;

Akciğer hacimleri

- 1. Soluk Volümü (Tidal Volume, VT):** Soluk hacmi, yaklaşık olarak 500 ml'dir (Kocer ve ark., 2023). %70'i alveollere ulaşır ve anatomik ölü bölge ise yaklaşık 150 ml'dir.
- 2. İspirasyon Yedek Volümü (Inspiratory Reserve Volume, IRV):** Yaklaşık 3000 ml olup normal bir inspirasyonu takiben alınabilen maksimum hava miktarıdır.
- 3. Ekspirasyon Yedek Volümü (Expiratory Reserve Volume, ERV):** Maksimum hava miktarı 1100 mL olup normal bir ekspirasyonu takiben çıkarılabilen maksimum hava miktarıdır.
- 4. Rezidüel Volüm (Residual Volume, RV):** Hiçbir koşulda akciğerlerden çıkarılamayan hava miktarı olup yaklaşık 1.200 ml'dir. Spirometreler ile direkt olarak ölçülemez.

Akciğer Kapasiteleri

- 1. İspirasyon Kapasitesi (Inspiratory Capacity, IC):** Normal bir ekspirasyon sonrasında alınabilen maksimum hava volümü olup $IC = VT + IRV$ formülü ile ifade edilir (Kocer ve ark., 2023).
- 2. Fonksiyonel Rezidüel Kapasite (Functional Residual Capacity, FRC):** Normal bir ekspirasyonu takiben akciğerlerde kalan hava volümü olup $FRC = ERV + RV$ formülü ile ifade edilir (Ankara Üniversitesi, 2023).
- 3. Vital Kapasite (Vital Capacity, VC):** Derin bir inspirasyonu takiben çıkarılabilen toplam hava volümü olup $VC = IRV + VT + ERV$ formülü ile ifade edilir (Ankara Üniversitesi, 2023).
- 4. Total Akciğer Kapasitesi (Total Lung Capacity, TLC):** Derin bir inspirasyonu takiben akciğerlerdeki toplam hava volümü olup $TLC = IRV + VT + ERV + RV$ formülü ile ifade edilir (Kocer ve ark., 2023).

Bu çalışmada ise 1000 kişilik gönüllü grubundan yararlanılan mobil bir yöntem test edilmiştir. Geliştirilen teknik ile tidal volüm kapasitesinin mobil alt yapılar ile hesaplanarak FEV ve FVC değerlerinin desibel türünden hesaplanması ve ses öznitelik vektörleri kullanılarak yapay sinir ağları yardımı ile nefes, fonasyon ve öksürük sesinden akciğer hastalıklarının tespit edilmesi amaçlanmıştır.

2. GEREÇ VE YÖNTEM

İstanbul İl Sağlık Müdürlüğü'nün 15916306-604.02 sayılı ve 08.09.2020 tarihli izni ile İstanbul il sınırları içerisinde izin alınan kamu hastanelerinde yürütülen araştırmamızda, onam formunu okuyarak onay veren 1000 gönüllü katılımcının ses verileri alınarak SPSS 26 programında derlenmiştir. Kullanılan verilerin oluşturulan kliniklerde toplanması, veri setinin hazırlanışı, veri

seti ile oluşturulan model, modellemede kullanılan derin öğrenme yapıları ve oluşturulan mobil uygulama arayüzü olmak üzere süreç 4 basamakta yürütülmüştür.

Yapay zekâ algoritmaları, görevle ilgili bilgileri kodlayan sinyallerin işlenmesine dayanır. Bu sinyaller farklı nitelikte olabilir ve örneğin, görsel veya işitsel bilgileri kodlayabilir. Ancak, ses verilerine dayalı sağlıkla ilgili yapay zekâ araştırmaları henüz sınırlıdır. İnsan konuşma üretimi, karmaşık anatomik yapıların ve nörolojik kontrolün etkileşimini gerektirdiğinden, hem dil bilgisini (konuşma içeriği) hem de akustik bilgiyi (konuşma kalitesi) kodlar. Bu nedenle, mevcut ses yaklaşımları genellikle konuşma verilerine odaklanır. İnsan konuşma aygıtı tarafından üretilen ses sinyali, basit bir soğuk algınlığından nörolojik bir bozukluğa kadar değişen hastalıklar dahil olmak üzere, çok sayıda çevresel ve dahili faktör tarafından potansiyel olarak farklı seviyelerde etkilenebilir (Milling ve ark., 2021). Ses verileri, dijital işleme ve analiz için ham bir formda kullanılabilir. Bu ham form, bir mikrofon aracılığıyla hava basıncı dalgalarının sürekli ölçümlerine dayanan, zaman ve değer nicelenmiş tek boyutlu bir sinyaldir. Bazı makine öğrenimi algoritmaları, bu ham analog verileri doğrudan işlemek için tasarlanmış olsa da çoğu yaklaşım hala bir dizi ses özelliğinin ilk çıkarımına dayanmaktadır (Milling ve ark., 2021). Geleneksel ses özelliği setleri, uzmanların yönlendirdiği dikkatli bir özellik seçimine dayanır ve genellikle belirli bir görevle potansiyel olarak ilgili olan, teorik akıl yürütme ve/veya pratik deneyime dayalı ses sinyali temsillerinden türetilen özellikleri içerir. Örneğin, COVID-19'lu bir hastanın ve sağlıklı bir kontrolün konuşma spektrogramları karşılaştırıldığında, frekans alanında, çoğunlukla daha az belirgin harmonik imalı yapılarda yansıyan COVID-19'lu hastanın konuşmasındaki artan miktarda kabalığa doğru belirgin farklılıklar ortaya çıkar. Bu durumda, spektral ses sinyali gösterimi, bir yapay zekâ sisteminin solunum hastalıklarını algılamak için uygun özellikleri türetmek için iyi bir temel olarak görülmektedir (Milling ve ark., 2021).

Sinyallerin temel özellikleri genellikle düşük seviyeli tanımlayıcılar (LLD'ler) kullanılarak kısa vadeli olarak yakalanır. Bu LLD'ler, örneğin, temel frekans (F0) olarak bir Mel ölçeğinde kısa vadeli enerji spektrumunu, titreşimi, ışıltıyı veya Mel frekans kepsral katsayılarını (MFCC'ler) ve bunların birinci (Δ) ve ikinci (Δ^2) dereceden türevlerini içerebilir (Milling ve ark., 2021). Daha sonra, daha yüksek seviyeli tanımlayıcılar (HLD'ler), LLD yörüngeleri üzerinden istatistiksel fonksiyonlar olarak hesaplanır ve böylece daha büyük zaman dilimleri üzerinden LLD'leri özetler. Örneğin, “Genişletilmiş Cenevre Minimalist Akustik Parametre Seti” (eGeMAPS), otomatik konuşma analizi görevleri için uzmanlar tarafından seçilen 88 akustik HLD'den oluşan küçük bir standartlaştırılmış settir. Bunun yanı sıra, “Hesaplamalı Paralinguistik Mücadelesi” (ComParE) özellik seti, otomatik konuşma analizi alanındaki en kapsamlı standartlaştırılmış özellik setlerinden birini temsil eder. Bu set, çok sayıda LLD ve istatistiksel fonksiyonların kaba kuvvet kombinasyonu ile üretilen 6,373 akustik HLD içerir. Son zamanlarda, uzman bilgisine bağlı olmayan bir dizi özellik seti artan ilgi görmüştür. Bu tür özellikler, spektrogramlara dayalı derin spektrum özelliklerini içerir ve özellik çıkarımı için ImageNet veya diğer görüntü kütüphanelerinde önceden eğitilmiş CNN'lerin gizli katmanlarını kullanır. Bu yaklaşımlardan bazıları, özellikleri daha da işlemek için ses torbası (BoAW) temsillerini kullanır ve bu sayede sinyal özelliklerini frekansları aracılığıyla zaman içinde özetler. Bu tür yöntemler, konuşma analizi ve hastalık teşhisinde daha etkili sonuçlar elde etme potansiyeli sunar (Milling ve ark., 2021). Çalışmamızda ise yapay zekanın yararlanabileceği bir matematiksel yaklaşım geliştirilmiş olup FEV ve FVC değerleri, desibel farkından hesaplanmıştır. Bu sayede akciğer hastalıklarının sınıflandırılması ve teşhis edilmesini sağlayacak mobil bir yazılım üretilmiştir.

FEV ve FVC değerlerinin hesaplanmasında klinik süreç. İstanbul İl Sağlık Müdürlüğü onayı ile İstanbul Feriha Öz Pandemi Hastanesi, İstanbul Murat Dilmener Acil Durum Hastanesi, İstanbul Sadi Konuk Eğitim ve Araştırma Hastanesi, İstanbul Şehit İlhan Varank Eğitim ve Araştırma Hastanesi ve İstanbul Haseki Eğitim ve Araştırma Hastanesi'nde 15.07.2020 tarihinde başlayarak gönüllü oluşturulan kontrol gruplarında (Tablo 1) hastane tipi spirometri cihazı

kullanılarak toplanan veriler “Statistical Package for the Social Sciences” (SPSS v.26) programında derlenmiştir. Aynı zamanda aynı kontrol grubunda Ipad mini 3 cihazı kullanılarak ortamın desibel cinsinden gürültüsü, akabinde 3 tekrar ile 1. saniye, 2. saniye ve 3. saniye zorlu ekspirasyon verileri alınmıştır. Elde edilen tüm veriler SPSS26 programında kıyaslanarak korelasyon ve regresyon analizleri yapılmıştır.

Yapay zekâ verilerinin toplanmasında klinik süreç. Veri setinin hazırlanması, oluşturduğumuz sistemin başlangıç aşamasıdır. 15.07.2020 tarihinde başlayarak kontrol grubu içerisinde yer alan katılımcılardan, fonasyon (a, u ve i sesi), öksürük sesi ve nefes sesi verilerini topladık. Yapay Zekâ için verimli olduğunu gördüğümüz bu ses verilerini kullanılarak gerçekleştirdiğimiz tasarım, akciğer hastalıklarını tespit ve teşhis etmeye çalıştığımız bir sınıflandırma problemi üzerine kuruluydu. Daha sonra, gerekli olacak meta verileri belirledik. Bunlar sırasıyla; A, u ve i ses dosyası ve matematiksel doğrulama için spirometri değerleridir. Klinik verileri Apple marka Ipad Mini 3’e entegre ettiğimiz ve kendi geliştirdiğimiz mobil yazılımı kullandık. Bu yazılım, ses verilerini toplamamıza yarayan bir kayıt cihazı niteliğindedir.

Veri seti: Hazırlanan veriler, belirli bir bağışçı grubundan toplanmıştır. Her gün ve günde dört kere olmak koşuluyla, her bir bağışçıdan gün içerisinde belirlenen saatlerde hem ses hem de spirometri değerleri alınmıştır. Daha sonra alınan bu değerler kendi oluşturduğumuz sistem içerisinde, sample.csv adlı bir çıktı ile kayıt altına alınmıştır. Ayrıca kontrol grubunda yer alan ve gönüllü onam formunu okuyarak kabul eden gönüllülerden hastane tipi bir spirometre ile zorlu ekspirasyon solunum sonuçları toplanmıştır. Hastane tipi spirometri cihazı ile geliştirdiğimiz yöntemi kıyaslayabilmek için önce desibel cinsinden ortam gürültüsünü akabinde ise gönüllü katılımcının zorlu ekspirasyon solunumu desibel cinsinden ölçülmüştür. Tüm veriler, SPSS 26 programında derlenerek korelasyon ve regresyon analizi ile değerlendirilmiştir. Veri seti oluşturulurken aşağıdaki adımlar izlenmiştir;

1. **Veri ön işleme:** Toplanan ses verileri, ön işleme adımlarıyla temizlenir ve düzenlenir. Gürültü, bozulma veya arka plan sesi gibi istenmeyen öğelerin temizlenmesi veya düzeltilmesi yapılır.
2. **Ses özelliklerinin çıkarımı:** Ses verilerinden çeşitli akustik ve fonetik özellikler çıkarılır. Bu özellikler, Mel frekansı kestral katsayıları (MFCC), enerji, sesin temposu, frekansı ve zaman özellikleri gibi ses sinyalinin karakteristikleri olabilir.
3. **Veri analizi ve modelleme:** Elde edilen ses özellikleri, makine öğrenimi algoritmaları veya derin öğrenme yöntemleri gibi yapay zekâ teknikleri ile analiz edilir. Bu aşamada, sınıflandırma, kümeleme, regresyon veya diğer ilgili yöntemler kullanılarak hastalıkların tanımlayıcı özellikleri belirlenir.
4. **Eğitim ve doğrulama:** Yapay zekâ modeli, eğitim için etiketlenmiş verilerle beslenir ve hastalıkların teşhisini veya belirtilerini öğrenir. Model, doğrulama verileri üzerinde test edilir ve performansı değerlendirilir.
5. **Hastalık teşhisi veya değerlendirme:** Eğitilmiş model, yeni ses verileri üzerinde test edilerek hastalıkların teşhisi veya hastalık belirtilerinin değerlendirilmesi yapılır. Modelin çıktıları, hastalığın olası varlığını, ciddiyetini veya diğer ilgili bilgileri içerebilir.

Csv dosyamızda 3 bilgi üzerine kayıtlar mevcuttur. Bunlar sırasıyla her bir bağışçı için; ses dosyası ve onun bulunduğu klasörün yolu, sesin ait olduğu kişinin oksijen saturasyonu ve nabız sayısıdır. Ses verileri .wav uzantılıdır ve 5 saniyelik bir uzunlukta “a” fonasyon sesinden oluşmaktadır.

Yeni oluşturulan data set. Bu veri setinde tüm veriler label.csv içerisinde tutulmuştur (Şekil 1). Dosya içerisinde bulunan klinik veriler, izin alınan hastanelerde, “Standart Operasyon Prosedürleri” (SOP) ve bilgilendirilmiş hasta onanımına göre doktorlar gözetiminde toplandığı için doğrudur. Veriler önceden işlenmiştir ve hasta demografisi (yaş, cinsiyet, tıbbi geçmiş) ile etiketlenmiştir. Bu veri setinde 1000 hastadan 14210 segmentli öksürük, fonasyon ve nefes veri

örneği sağlanmıştır. Veri dizini, biri orijinal ses kayıtlarını, diğeri ise toplanan ses verilerinin bölümlere ayrılmış versiyonlarını içeren iki farklı klasör içermektedir. Segmentli ses verileri, kayıtlarda göreceli sessizlik dönemleri belirlenerek ve bu sessizliklere göre öksürükler ayrılarak oluşturulmuştur. Segmentli öksürükler 1 saniyelik uzunluklara sahiptirler.

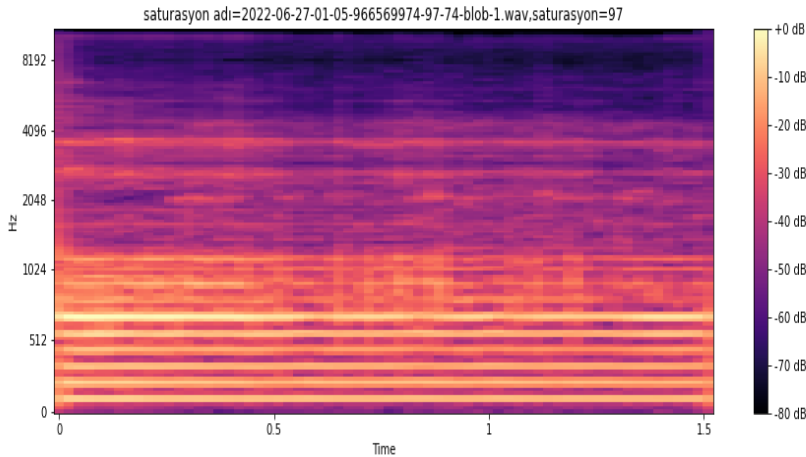
1	sesDosyaAd,Oksijen(%),Nabiz
2	yuklemeler/2022-06-27-01-05-966569974-97-74-blob.wav,97,74
3	yuklemeler/2022-06-27-01-08-558151826-95-125-blob.wav,95,125
4	yuklemeler/2022-06-27-01-15-503234028-98-99-blob.wav,98,99
5	yuklemeler/2022-06-27-02-27-2078543185-98-74-blob.wav,98,74
6	yuklemeler/2022-06-27-04-39-464511572-99-88-blob.wav,99,88
7	yuklemeler/2022-06-27-04-39-1543915557-100-92-blob.wav,100,92
8	yuklemeler/2022-06-27-04-40-1849018560-97-123-blob.wav,97,123
9	yuklemeler/2022-06-27-04-42-1589296090-99-95-blob.wav,99,95
10	yuklemeler/2022-06-27-06-31-1096224329-96-108-blob.wav,96,108

Şekil 1. Oluşturulan veri setinin .csv içindeki kayıtları

Sistemin oluşturulması. Ses ile gerçekleştirilen çalışmamızın veri setlerinden elde edilecek öznelik vektörlerinin sınıf özelliklerini en iyi şekilde kullanılmış olmasına bağlı olduğunu bilerek en iyi ayrımı yapan öznelik olarak MFCC (Mel frekans kepsral katsayıları) seçilmiştir.

Mel-frekans cepstral katsayıları (MFCC'ler). Bir sinyalin Mel frekans kepsral katsayıları (MFCC'ler), bir spektral zarfın genel şeklini kısaca açıklayan küçük bir özellikler dizisidir. MFCC'ler, insan sesinin özelliklerini modeller. MFCC, insan kulaklarının algılamasını taklit eden ve “Hızlı Fourier Dönüşümü” (FFT) tabanlı olarak hesaplanan sayısal analiz tekniği olmakla beraber kullanım oranı yüksek olan öznelik çıkarma yöntemlerindedir (Chauhan ve ark., 2020). Ses sinyalinin kısa zamanlı güç spektrumunun Mel ölçeği üzerindeki ifadesi olarak tanımlanabilir (Durmaz ve ark., 2023). Çalışmamızda ortaya çıkan MFCC grafiklerinden birini Şekil 2’de gösterilmiştir. Frekanstan Mel ölçeğine dönüşüm formülü ise aşağıdaki gibidir;

$$M = 1125 \times \ln(1+(f \div 700)) \quad M \rightarrow \text{Mel ölçeği şeklindedir.}$$



Şekil 2. 2022-06-27-01-05-966569974-97-74-blob-1.wav dosyasına ait MFCC grafiği

3. BULGULAR VE TARTIŞMA

Çalışmamızda, Python programlama dili kullanılmıştır. Seslerin daha anlaşılır ve daha kullanışlı olabilmesi için her bir sesi 1 saniye aralığında ve .wav formatıyla kaydedilmiştir. Ancak her bir sesi, daha iyi bir sonuç elde etmek adına Audacity adlı ses programında, veriler gürültülerden temizlenerek yine 1 saniyelik uzunlukta daha kullanışlı hale getirdik. Bununla

birlikte, her bir ses 22050 Hz ve tek kanallı kaydedildi. Ses dosyalarının adları ilk oluşturulduğu gibi (sesin oluşturulma tarihi- ses dosya numarası) kaydedildi. Audacity programının yanı sıra düzenlenen verileri hem çoğaltmak hem de arka plandaki belli gürültüleri öğretebilmek adına bir manipülasyon yazılımı (toplanan seslerin bazı durumlarda gürültüden arındırılması ya da 60 desibele kadar genel gürültü, hırıltı ekleme) geliştirdik. Geliştirdiğimiz bu yazılım ile veri sayımız, 16330 pozitif ve 14.875 negatif olmak üzere toplam 31.205 sayısına ulaştı. Veri sayımızdaki değişimden sonra ses verilerini, daha kullanışlı bir hâle getirebilmek için elimizdeki ses dosyalarının sessizliklerini temizleyecek ve -1 ile 1 aralığında normalleştirecek bir kod oluşturduk. Veri setini düzenledikten sonra, elimizde olan ses verilerinin eğitimini gerçekleştirdik.

Seçtiğimiz MFCC özniteliğini, iki şekilde kullanma şansımız vardı. Birincisi için, her bir sese etiket atayacaktık (İkili bir sınıflandırma olacağından bu etiketler negatif için 0 ve pozitif için 1 şeklinde olacaktır). Ardından atanılan etiketlerle benzer sonuçlar veren katsayılar eşleştirilerek bir eğitim modeligeliştirilecekti. İkincisi içinse elimizdeki ses verilerinin MFCC'lerinin spectrogram grafiklerinebakılarak görüntü işleme ile bir eğitim modeli geliştirilecektik. Bunların her ikisi için de evrişimli sinir ağı adı verilen CNN ağlarının kullanıldığı bir model eğitilmeliydi.

Evrişimli sinir ağı-CNN. "Evrişimli Sinir Ağı" (ConvNet/CNN), bir giriş görüntüsünü alan, görüntüdeki çeşitli yönlerde/nesnelere önem (öğrenilebilir ağırlıklar ve önyargılar) atayan ve bunları birbirinden ayıran bir "derin öğrenme" algoritmasıdır. ConvNet, diğer sınıflandırma algoritmalarına göre çok daha az ön işleme gerektirir. Filtreler ilkel yöntemler kullanılarak manuel olarak tasarlanmasına rağmen, ConvNet bu filtreleri/özellikleri yeterli eğitimle öğrenebilmektedir (Rubikscore, 2023). ConvNet'in mimarisi insan beyni nöronlarının bağlantı modeline benzer ve görsel korteksin organizasyonundan ilham almıştır. Bireysel nöronlar, uyarılara yalnızca görsel alanın "alıcı alan" adı verilen sınırlı bir alanında yanıt verir. Bu alanların toplamı görüş alanının tamamını kapsayacak şekilde örtüşür. Görüntü verileri genellikle 3 boyuttan oluşur (Rubikscore, 2023). Bu 3 boyut aşağıdaki gibidir:

- Görüntü yüksekliği
- Resim Genişliği
- Renk kanalları

Yukarıdaki listede anlayamayabileceğiniz tek öğe, renk kanallarıdır. Renk kanallarının sayısı, birgörüntünün derinliğini temsil eder ve içinde kullanılan renklerle bağlantılıdır. Örneğin, üç kanallı bir görüntü büyük olasılıkla rgb (kırmızı, yeşil, mavi) piksellerden oluşur. Dolayısıyla,her piksel için 0-255 aralığında rengini tanımlayan üç sayısal değere sahibiz. Renk derinliği 1 olan bir görüntü için, muhtemelen yine 0-255 aralığında her pikseli tanımlayan bir değere sahipgri tonlamalı bir görüntümüz olacaktır (Rubikscore, 2023). Çekilen her bir ses verisinin mel grafikleri desibele bağlı oluşturulmuştur ve img.data adlı klasör içerisinde aynı adla .png uzantısıyla çıkmıştır. Spektrogramların pozitif ve negatif hastalar arasındaki nefes alma farkları, açık bir şekilde görülmektedir. Örneğin negatif bir covid testi gönüllüsünün öksürmesinden sonra hava girişindeki netlik, pozitif bir hastaya kıyasla görülebilir düzeydedir. Gözle bakıldığında, bir covid hastasının öksürük sonrası nefes almasının net olmadığı ve bazı düşük frekanslı seslerin algılandığı görülüyor. Daha sonra verileri tren seti ve test seti olarak ikiye böldük. Oluşturduğumuz spectrogram görsellerini eğitimde %80 ve test setinde %20 oranında bölerek ilerledik. "Image Augmentation" (İmaj Çoğaltma), farklı işleme yöntemleri veya rastgele döndürme, kaydırma, kesme ve döndürme gibi çoklu işlemlerin bir kombinasyonu yoluyla yapay olarak eğitim görüntüleri oluşturur. Modelimizi çok resimle eğitmek yerine Image Augmentation (İmaj Çoğaltma) kullanarak, modelimizi daha az resimle ve modeli farklı açılarla eğitip resimleri modifiye ettik. Keras kütüphanesi, kullanıcıların Image Augmentation işlemini çok kolay bir şekilde anında gerçekleştirmelerini sağlayan bu "ImageDataGenerator" (görüntü verisi büyütme) sınıfına sahiptir.

ImageDataGenerator sınıfı, büyük bir sayısal diziden ve görüntüleri içeren klasörlerden görüntüleri okumak için flow(), flow_from_directory() ve flow_from_dataframe() olmak üzere üç yonteme sahiptir. Ancak çalışmamızda kullandığımız flow_from_directory() yöntemidir. Kullandığımız flow_from_directory() aşağıdaki bağımsız değişkenlere sahiptir.

- a. **Directory (Rehber):** Tüm test görüntülerinin bulunduğu klasörün bulunduğu yol. Örneğin, budurumda eğitim görüntüleri **path_dir** içinde bulunur.
- b. **Shuffle (Karma):** Verilmekte olan görüntünün sırasını karıştırmak için True olarak ayarlanan, aksi takdirde False olarak ayarlanan kısımdır.
- c. **target_size (Hedef Boyutu):** Resim boyutunu ayarlamak için kullanılır.

Bu işlemlerin dışında, “callback” (geri çağırma) değişkenine “early stopping” (erken durma) ataması yaptık. Early stopping, eğitimin daha başarılı olmasını sağlar. En iyi başarıma ulaştıktan sonra eğitimi durdurur. Bizim eğitimimizde de 200 “epoch” (dönem) içerisinde 99. epoch ile en yüksek sonuca ulaştığı için eğitimi durdurmuştur. Bu noktada, artık oluşturduğumuz modeli kaydedip test sonucuna ulaşmalıyız. Kaydedilen model, model klasörü altında model_mel_ses_yeni.h5 şeklinde klasöre çıkarılır. Oluşturulan modelin, test veri seti üzerindeki performansına bakarak modelin ne kadariyi başarımlı gösterdiğini öğrenebiliriz. Elimizdeki modelin performansına bakıldığında sonucun oldukça başarılı olduğu gözle görülmektedir. Modelimiz %99.60’lık bir başarı elde etmiştir. Çalışmamızın sonucunda Yapay Zekâ yazılımımız geliştirilirken aynı kontrol grubundan toplanan spirometri verilerinin elde ettiğimiz ve mobil ortamda topladığımız ses verileri ile uyumu için geliştirdiğimiz formülümüzle uyumlu olup olmadığını anlamak için aşağıda yer alan kontrol grubu oluşturulmuştur:

Oluşturulan Kontrol Grubu

ID	Hastalık adı	Açıklama
1	KOAH	Kronik obstrüktif akciğer hastalığı (KOAH), solunumla akciğerlere alınan havanın kolay bir şekilde dışarı verilememesi şeklinde açıklanabilecek bir akciğer hastalığıdır. Bu duruma neden olan iki süreç kronik bronşit ve amfizemdir.
2	Pnömoni	Zatürre semptomları, bazen hastaneye yatış gerektirecek kadar şiddetli veya fark edilmeyecek kadar az olabilir. Yeni Koronavirüs Hastalığı (COVID-19), gibi bir çok etmen pnömoni gelişmesine sebebiyet verebilir.
3	Astım	Astım, solunum yollarını tıkayan ve nefes almayı zorlaştıran kronik bir hastalıktır.
4	Bronşit	Bronşlar dışarıdan solunum yoluyla aldığımız havayı, kanın oksijenlendirildiği alveol denilen keseciklere taşıyan geniş ve ora genişlikteki hava yollarıdır. Bronşit ise işte bu bronşların birtakım etkenler nedeniyle inflamasyonu, yani yankılanmasıdır.

Oluşturulan kontrol grubunda yer alan kişiler, hastane kontrolleri sonucu pozitif tanı alan ve onam formumuzu imzalayan gönüllülerden oluşturulmuştur. Bu grup içerisinde yer alan herkesi yapay zekâmız tekrar değerlendirerek pozitif tanı alanların hem hastane tipi spirometri cihazı ile sonuçları değerlendirilmiştir hem de oluşturduğumuz mobil alt yapı ile değerlendirilerek sonuçların uyumluluğu izlenmiştir. Bu grubun seçilme nedeni ise zaten spirometrik izlemenin bu kişilerde olağanlaşmasıdır. Zorlu ekspirasyon volümü hesabı yapılırken normal nefes alışverişi sonrası kişinin kendisini zorlayarak hızlı bir ekspirasyonla akciğerlerden çıkarılabildiği toplam hava hesaplanmaktadır. Dolayısı ile ortam değişkeni olarak oluşan gürültüyü ele alırsak desibel farkından başlangıç anı ile sonuç anı arasında bir fark oluşacaktır. Desibel, daima iki değer arasındaki karşılaştırmadır (Wikipedia, 2023). Bunun sonucu olarak da çoğu kez ölçülen güç değeri, değişik olmasına rağmen desibel sayısı aynıdır. Bu sebeple, mobil cihazlar ile elde edilen desibel cinsinden verinin logaritması alınarak aşağıda yer alan formül oluşturulmuştur;

$$FVC = \text{LOGe}(\text{Nefes Kalibrasyonu Sonucu})$$

İstanbul il sınırları içerisinde izin alınan kamu hastanelerinde yürütülen araştırmamızda onam formunu okuyarak onay veren 1000 gönüllü katılımcının ses verileri alınarak SPSS 26 programında derlenen spirometri verileri incelenmiştir. Aşağıda yapılan çalışma sonucunu yansıtmak için rastgele 20 değer tablo halinde paylaşılmıştır (Tablo 1). Mobil uyumlama ile oluşturulan uygulama sonucunda önce ortam gürültüsü ve akabinde normal nefes alışverişi sonrası kişinin kendisini zorlayarak hızlı bir ekspirasyonla akciğerlerden çıkarılabildiği toplam hava (zorlu ekspirasyon volümü) desibel cinsinden ölçülmüş olup yukarıda paylaşılan formül uygulanmıştır. Çıkan “Nefes Kalibrasyonu” sonucuna FVC (Bakınız: FVC sütunu) LOGe uygulanarak (Bakınız: LOGe Mobil FVC sütunu) sonuçları elde edilmiştir. Spirometre ve mobil FVC değerleri korelasyon Şekil 1’de verilmiştir. Ayrıca bu sonuçlara literatürde uygulanan genel formül kullanılarak FEV (Bakınız: FEV 1 sütunu) ve Mobil FEV (Bakınız: FEV Mobil sütunu) değerleri bulunmuştur.

$$FEV1 = A \times FVC + C$$

$$A = 0.84 \text{ ve}$$


$$C = -0.23 (-0.36) \text{ kadın - erkek}$$

Tablo 1. Spirometri ve mobil ölçüm sonuçlarının kıyaslanması

Spirometri Ölçüm Değerleri Mobil Ölçüm Değerleri

No	Cinsiyet	FVC (L)	FEV1 (L)	Nefes Kalibrasyonu (dB)	Ortam Kalibrasyonu (dB)	LOGe (Mobil FVC)	LOGe (Mobil FEV)
1	K	2.67	2.01	24.21	51.46	3.19	2.44
2	K	2.79	2.10	23.70	50.08	3.16	2.42
3	K	2.88	2.19	23.88	58.11	3.17	2.43
4	K	3.03	2.31	24.47	48.80	3.20	2.46
5	K	3.06	2.34	24.51	46.77	3.20	2.46
6	K	3.10	2.37	35.57	45.64	3.57	2.77
7	K	3.25	2.51	30.31	46.40	3.41	2.60
8	K	3.51	2.72	34.98	51.02	3.55	2.75
9	K	3.68	2.86	38.29	48.07	3.65	2.84
10	K	4.07	3.19	36.11	46.51	3.59	2.79
11	E	3.71	2.80	36.59	48.21	3.60	2.70
12	E	4.06	3.09	33.90	53.27	3.52	2.64
13	E	4.08	3.11	35.10	55.96	3.56	2.67
14	E	4.17	3.18	34.98	49.79	3.55	2.66
15	E	4.21	3.22	36.80	45.86	3.61	2.71
16	E	4.35	3.33	39.76	52.69	3.68	2.77
17	E	4.38	3.36	37.80	48.71	3.63	2.73
18	E	4.43	3.40	37.68	48.86	3.63	2.73
19	E	4.46	3.38	33.61	49.52	3.51	2.63
20	E	4.49	3.45	39.77	48.30	3.68	2.77


Spirometre ve mobil FVC değerleri korelasyon analizi Şekil 3’de verilmiştir. Spirometre ve mobil FVC değerleri regresyon analizi Şekil 4’de verilmiştir. Spirometre ve mobil FEV değerleri korelasyon analizi Şekil 5’de verilmiştir. Spirometre ve mobil FEV değerleri regresyon analizi Şekil 6’de verilmiştir.



Gerçekleştirilen korelasyon sonucu yüksek pozitif ilişki bulunmuştur.

$$n=20, \Sigma x=74.38, \Sigma y=69.66, (\Sigma x)^2=5532.3844, \\ (\Sigma y)^2=4852.5156, \Sigma(xy)=260.9443, \\ \Sigma x^2=284.1424, \Sigma y^2=243.294 \\ r = 0.837935989279963$$


Şekil 3. Spirometre ve mobil FVC değerleri korelasyon analizi grafiği



Regresyon Analizi sonucu ise anlamlı değerlendirilmiştir.

$$n=20, \Sigma x=74.38, \Sigma y=69.66, (\Sigma x)^2=5532.3844, \\ (\Sigma y)^2=4852.5156, \Sigma(xy)=260.9443, \\ \Sigma x^2=284.1424, \Sigma y^2=243.294 \\ \text{Fonksiyon: } y = 2.554 + 0.25x$$


Şekil 4. Spirometre ve mobil FVC değerleri regresyon analizi grafiği



Gerçekleştirilen korelasyon sonucu yüksek pozitif ilişki bulunmuştur.

$$n=20, \Sigma x=56.92, \Sigma y=52.97, (\Sigma x)^2=3239.8864, \\ (\Sigma y)^2=2805.8209, \Sigma(xy)=151.6716, \\ \Sigma x^2=166.5354, \Sigma y^2=140.6399 \\ r = 0.730136412166274 \\ \text{Yüksek pozitif ilişki.}$$

Şekil 5. Spirometre ve mobil FEV değerleri korelasyon analizi grafiği



Regresyon Analizi sonucu ise anlamlı değerlendirilmiştir.

$$n=20, \Sigma x=56.92, \Sigma y=52.97, (\Sigma x)^2=3239.8864, \\ (\Sigma y)^2=2805.8209, \Sigma(xy)=151.6716, \\ \Sigma x^2=166.5354, \Sigma y^2=140.6399 \\ \text{Fonksiyon: } y = 2.073 + 0.202x$$

Şekil 6. Spirometre ve mobil FEV değerleri regresyon analizi grafiği

Gerçekleştirdiğimiz çalışma sonucunda zorlu ekspirasyon verilerinin mobil ortamda elde edilebileceğini ve bu değerlerin klasik tıbbi literatüre bağlı kalınarak ön değerlendirme ile bazı hastalıklar yönünden değerlendirilebileceği sonucuna vardık. Solunum yolu dalları, trakea ve bronşların oluşturduğu küçük hava yolları olarak tanımlanan iletken hava yollarını ilgilendiren hastalıkları anlamak mümkün görünmektedir. Bu fraksiyon insan akciğer hacminin %1'ini oluşturur (Ulubay ve ark., 2019). Geriye kalan akciğer hacmi büyük damarlar, bronşiyoller, alveoler septalar ve alveollerden oluşur (Ulubay ve ark., 2019). Proksimal bronşların epiteli bazal ve münöz hücreler içermesine rağmen distal bronşiyollerin duvarları daha ince ve daha basit bir epitelyuma sahiptir (Ulubay ve ark., 2019). Duvardaki kıvrımda önemli ölçüde azalır ve yerini düz kas alır (Tulić ve ark., 2006). Spirometri akciğerlerin fonksiyonel kapasitesini gösterir ve farklı akış değerleriyle ilgili parametreleri inceler (örneğin, FEV1, FVC, FEV1/FVC, FEF %25-75). Çalışmalar KOAH'ın iskemik kalp hastalığı için bir risk faktörü olduğunu, KOAH'lı hastalarda görülme oranının %4-60 arasında değiştiğini bildirmektedir. Bu nedenle, kapsamlı bir akciğer değerlendirmesi yapılmalıdır (Roversi ve Fabbri, 2018). Küçük hava yollarının katıldığı akciğer hastalıkları aşağıdaki gibidir:

1) Primer olarak katıldığı hastalıklar

- Folliküler bronşiolit
- Granümatöz bronşiolit
- Pnömonyoz
- Diffüz panbronşiolit
- Diffüz idiyopatik nöroendokrin hücre hiperplazisi

2) Sekonder olarak katıldığı hastalıklar

- Astım
- KOAH
- Bronşektazi
- Ekstresek allerjik alveolit
- Organize pnömoni Sarkoidoz
- Wegener granülomatozu

Ayrıca FEV1/FVC obstrüksiyonun varlığını tespit etmek için kullanılan bir parametredir (Ulubay ve ark., 2019). Sağlıklı bireylerde, normal değerler %70-80'dir (Ulubay ve ark., 2019). Restriktif hastalıklarda FEV1 ve FVC değerlerinin azalması en önemli göstergedir (Ulubay ve ark., 2019). Bu hastalarda FVC değerlerinin kaybı FEV1 değerlerinden daha fazla olabilir ve dolayısıyla FEV1/FVC değerleri normal, hatta normalden yüksek olabilir (Ulubay ve ark., 2019).

Göğüs duvarı mekaniğinin bozulduğu durumlarda, özellikle de solunum kaslarının tutulduğu durumlarda, oturma ve yatma pozisyonlarında ölçülen FVC ölçümlerinde >%25-30'luk bir azalma, diyaframa tutulumunu gösteren önemli bir bulgudur (Allen ve Ark., 1985; Cotes ve ark., 2006). Solunum kas kuvveti değerlendirmesi maksimum inspiratuar basınç (MIP), maksimum ekspiratuar basınç (MEP) ile ölçülür (Güngör ve ark., 2022).

Solunum asidozu ve hipoksemi hakkındaki bilgilerin spirometri ölçümleriyle elde edildiği görülmektedir. Bora Dinç ve arkadaşlarının "Lobektomi Olgularında Tek Akciğer Ventilasyonunun Değerlendirilmesi" başlıklı çalışmada hipoksemik olguların preoperatif FVC ve FEV1 değerleri incelendiğinde FVC'si yüksek olan olgularda hipoksemi gelişme olasılığının daha yüksek olduğu saptanmıştır (Dinç ve ark., 2018). Aynı çalışmada hipoksemi sırasındaki ve hipoksemi müdahalesi sonrası kan gazları ile ameliyat başlangıcındaki kan gazları karşılaştırıldığında, müdahale sonucunda karbondioksit kısmi basıncı (pCO₂) basıncının daha da düştüğünü gösteren anlamlı sonuçlar elde edilmiştir (Dinç ve ark., 2018). Dolayısıyla çalışmamızdaki tekniklerin daha geniş bir kontrol grubuna uygulanmasıyla, sayılan bozuklukların tanısına yardımcı olacak pek çok açıklama geliştirilebilir. Düşük pH'a eğilim gösteren herhangi bir hastalık asidoz, yüksek pH'a eğilim gösteren herhangi bir hastalık ise alkalozdur (Kurtipek ve ark., 2023). Primer olarak bikarbonat (HCO₃) etkileniyorsa metabolik bozukluk, PaCO₂ etkileniyorsa solunum bozukluğu tanımlanır (Kurtipek ve ark., 2023). Asit-baz bozuklukları, yalnızca patolojik durumların ortaya çıkması durumunda basit kabul edilir (Kurtipek ve ark., 2023). İki veya daha fazla primer bozukluğun varlığı, karışık asit-baz bozukluğunu düşündürür (Kurtipek ve ark., 2023). Genel asit-baz bozukluğu Tablo 2'de verilmiştir.

Tablo 2. Genel asit-baz bozukluğu

Bozukluk	Asıl değişiklik	Kompanzasyon
Solunumsal asidoz	PaCO ₂ ↑	HCO ₃ ↑
Solunumsal alkaloz	PaCO ₂ ↓	HCO ₃ ↓
Metabolik asidoz	HCO ₂ ↓	PaCO ₂ ↓
Metabolik alkaloz	HCO ₃ ↑	PaCO ₂ ↑

Çözeltideki hidrojen iyonu konsantrasyonunun negatif logaritmasıdır. 7,40'lık bir pH, fizyolojik pH olan yaklaşık 40 n mol/L'lik (40X 10⁻⁹ mol/L) bir hidrojen iyonu konsantrasyonunu temsil eder. pH ile HCO₃ ve PaCO₂ değerleri arasında matematiksel bir ilişki vardır (Kurtipek ve ark., 2023). Bunlardan biri veya her ikisi değiştiğinde asit-baz bozuklukları ortaya çıkar (Kurtipek ve ark., 2023). Henderson-Hasselbach denkleminde göre bu formül şu şekilde ifade edilir:

$$pH = pK + \log \frac{HCO_3}{H_2CO_3} \quad pH = 6.1 + \log \frac{HCO_2}{0.03 \times PaCO_2}$$

Araştırmamız sırasında metabolik asidoz veya metabolik alkaloz ile ilgili geliştirdiğimiz tekniklerin çıkarımda bulunmamıza olanak sağladığı sonucuna vardık. Buna göre; Çalıştığımız teknikle üretilen zorlu ekshalasyonun %70 CO₂ ve %30 O₂ mobil FVC değerleri ürettiğini varsayalım. Elde edilen sonuçlar arteriyel değerlerden farklı olsa da solunumsal asidoz veya alkaloz ile yakından ilişkilidir. Ayrıca 0,03xPaCO₂ değeri arttıkça pH değeri düşmektedir. Mobil cihazlardaki bu yorumlama aşağıda Tablo 3'de paylaşıldığı şekilde planlanabilir.

- Normal FVC değeri 3,5 – 4,5 litre olarak kabul edilmektedir. Elde edilen FVC değerinin %70'i CO₂ kabul edilerek, 0,03 ile çarpılır ve çıkan sonuç 0,07 ile 0,09 arasında ise normal değerlendirilir. 0,09'dan büyükse "Solunumsal Asidoz", 0,07'den küçükse "Solunumsal Alkaloz" şüphesi düşünülebilir. Ancak bu alanda derin çalışmaların artırılması gerektiğini düşünmekteyiz.

Literatürde çok sayıda akademik yayın, hastalık bulgularına ait seslerinin sınıflandırılması üzerine odaklanmıştır. Örneğin Sankur ve arkadaşları, sağlıklı ve hastalıklı akciğer seslerini %87 doğrulukla sınıflandırmak için otoregresif bir model kullanmışlardır (Narkhede ve ark., 2023).

Schreur ve arkadaşları yaptıkları çalışmada astımlı ve sağlıklı bireylerde standart sessiz nefes alma ve eforlu egzersiz sırasında hava akışı kayıtlarını, akciğer hacmi değişikliklerini ve akciğer seslerini incelediler. Bir "hızlı Fourier dönüşümü" (HFD) kullanarak akışa bağlı güç spektrumlarını hesapladılar ve varyans analizini kullanarak her spektrum için akciğer ses yoğunluğunu (LSI) belirlediler. Astımlı hastaların nefes verme sırasında LSI değerlerinin daha düşük olduğunu, astımlı hastaların ise sessiz nefes verme sırasında daha yüksek LSI değerlerine sahip olduğunu gözlemlediler (Sankur ve ark., 1994).

Tablo 3. Örnek mobil yorumlama planı

Online Spirometre Sonuçları					
FVC (Mobil)	FEV1 (Mobil)	Nefes Kalibrasyonu (dB)	Ortam Kalibrasyonu (dB)	FEV/FVC (Mobil %)	YORUM
Nefes Kalibrasyonu (LOGe)	(FVC x 0,84)-0,23	dB	dB	(100/FVC) X FEV	*Normal *Solunumsal asidoz şüphesi *Solunumsal alkoloz şüphesi

1995 yılında yapılan bir çalışmada Gavriely, mevcut spirometri akciğer fonksiyon testlerine ek olarak bilgisayarlı akciğer analizinin etkinliğini test etmiş ve göstermiştir (Gavriely ve ark., 1995).

Piirilab (1992) ral seslerinin frekans yoğunluğu seviyelerinde önemli farklılıklar olduğunu gözlemlemiştir (Piirila ve ark., 1992). Başka bir çalışmada, sağlıklı ve hastalıklı akciğerlerde meydana gelen nefes seslerinin HFD spektrumlarında yüksek frekanslarda önemli farklılıklar gözlemlendiği bildirilmiştir (Piirila ve ark., 1991).

Her ne kadar literatürde yapay zekâ odaklı çalışmalar bulunuyor olsa da yapay zekanın desteklendiği bir matematiksel formüle değinilmemiştir. Çalışmamız bu yönü ile yapay zekanın matematiksel formüllere ve klasikleşmiş anatomik güç ölçümleme metotlarına farklı bir bakış açısı sunmaktadır.

Başka bir bakış açısı ile uzay misyonları, uzay turizmi ve öte gezegenlerde kolonileşme çalışmalarının yoğunlaştığı günümüzde, yer çekiminin azaldığı ortamlarda, ses verileri ile analiz yapan, bu verilere göre hastalık sınıflandırması ile teşhise yardımcı olan ya da belki de bağımsız teşhis koyarak tedaviye yardımcı olacak yapay zekâ çalışmalarına bu çalışma çıktıları destek olabilir görüşündeyiz. Çünkü vokal kord kasılmaları, sese bağımlı analiz yöntemlerinin en önemli takip unsurudur. Bu yapı, düşük yer çekimi, yüksek irtifa, çeşitli sebeplerle oluşan basınç durumu (derin deniz etkisi vb.) gibi çevresel faktörlerden etkilenmektedir. Bu sebeple, teşhisin zor olduğu ya da tıbbi makineleşmenin olmadığı her yerde mobil alt yapılar kullanılarak çalışmamızda bahsedilen akciğer hastalıklarının tespiti mümkün olabilir.

Çıkar Çatışması

Açıklanacak herhangi bir çıkar çatışması yoktur.

KAYNAKÇA

Allen, S.M., Hunt, B. and Green, M. (1985). Fall in vital capacity with posture. *British Journal of Disease and Chest*, 79, 267-71.

Ankara Üniversitesi, Solunum Sistemi Fizyolojisi Açık Ders web sitesi, https://acikders.ankara.edu.tr/pluginfile.php/97998/mod_resource/content/0/Solunum-Fiz_AU-Acik-Ders.pdf Son Erişim 26.02.2023.

- Chauhan S.N. Audio Data Analysis Using Deep Learning with Python web sites. <https://www.kdnuggets.com/2020/02/audio-data-analysis-deep-learning-python-part-1.html/> Son Erişim Tarihi: 27.09.2023.
- Cotes, J.E., Chinn, D.J. and Miller, M.R. (2006). *Lung Function: Physiology, Measurement and Application in Medicine*. 6th edn., Blackwell Publishing, Oxford, pp.p.567-569.
- Desibel açıklama sayfası, Wikipedia web sitesi, <https://tr.wikipedia.org/wiki/Desibel> Wikipedia web sitesi. Son Erişim: 27.09.2023.
- Dinç, B., Titiz, T., A. and Keskin, H. (2018). Lobektomi olgularında uyguladığımız tek akciğer ventilasyonunun değerlendirilmesi. *Akdeniz Tıp Dergisi*, 2, 130-136.
- Durmaz A.O. Ses Öznitelik Çıkarımı, Medium Web Sitesi, <https://medium.com/datarunner/librosa-9729c09ecf7a>. Son Erişim: 27.09.2023.
- Gavriely, N. (1995). *Breath Sounds Methodology*. CRC Press, Boca Raton.
- Güngör, N. (2022). Kardiyak rehabilitasyonda değerlendirme: Geleneksel derleme. *Sağlık Bilimleri ve Yaşam Dergisi*, 6(2), 14-27.
- Kurtipek, Ö. Asit-Baz Dengesi ve Kan Gazlarının Değerlendirilmesi, https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKewj5x4T18Kz9AhVhSvEDHYVnD2YQFnoECA8QAQ&url=https%3A%2F%2Fmed.gazi.edu.tr%2Fposts%2Fdownload%3Fid%3D20757&usg=AOvVaw3rVYye5ck15OZMW_B9RxNr. Son Erişim 27.09.2023.
- Kocer, G. Yakınođu Üniversitesi, Solunum Sistemi Fizyolojisi Web Sitesi, http://docs.neu.edu.tr/staff/gunnur.kocer/Solunum%20Sistemi%20Fizyolojisi_3.pdf Son Erişim 27.09.2023.
- Milling, M., Pokorny, F.B., Bartl, K.D. and Schuller, B.W. (2021). Is speech the new blood? Recent progress in ai-based disease detection from audio in a nutshell. *Insights in Health Informatics*, 4, 886615.
- Narkhede, S. Understanding Confusion Matrix. Web Sitesi, <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62/> / Son Erişim Tarihi: 27.09.2023.
- Rubikscore Web Sitesi, <https://rubikscore.net/2018/02/26/introduction-to-convolutional-neural-networks/> Son Erişim Tarihi: 27.09.2023.
- Piirila, P. (1992). Changes in crackle characteristics during the clinical course of pneumonia. *Chest*, 102(1), 176-183.
- Piirila, P., Sovijarvi, A., Kaisla, T., Rajala, H.M. ve Katila, T. (1991). Crackles in patients with fibrosing alveolitis, bronchiectasis, COPD, and heart failure. *Chest*, 99(5), 1076-1083.
- Sankur, B., Kâhya, Y.P., Guler, CE and Engin, T. (1994). Comparison of AR-based algorithms for respiratory sounds classification. *Computers in Biology and Medicine*, 24, 67-76.
- Solunum Sistemi, Wikipedia web sitesi, https://tr.wikipedia.org/wiki/Solunum_sistemi Son Erişim 27.09.2023.
- Tulić, M.K. and Hamid, Q. (2006). New insights into the pathophysiology of the small airways in asthma. *Clinical Chest Medicine*, 27, 41-52.
- Ulubay, G., Dilektaşlı, A.G., Börekçi, Ş., Yıldız, Ö., Kıyan, E., Gemiciođlu, B., Saryal, S. (2019). Turkish thoracic society consensus report: Interpretation of spirometry. *Turk Thorac Journal*, 20(1), 69-89.