



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 29.09.2022
Kabul Tarihi : 25.01.2023

Received Date : 29.09.2022
Accepted Date : 25.01.2023

SOLUNUM SİSTEMİ HASTALIKLARININ TEŞHİSİNE YÖNELİK MAKİNE ÖĞRENMESİ TABANLI ANALİZ PROGRAMI GELİŞTİRİLMESİ

DEVELOPMENT OF MACHINE LEARNING BASED ANALYSIS PROGRAM FOR DIAGNOSIS OF RESPIRATORY SYSTEM DISEASES

Burcu ACAR DEMİRCİ¹ (ORCID: 0000-0002-7328-1267)
Yücel KOÇYİĞİT² (ORCID: 0000-0003-1785-198X)*

^{1,2}Manisa Celal Bayar Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Manisa, Türkiye

*Sorumlu Yazar / Corresponding Author: Burcu ACAR DEMİRCİ, burcu.acar@cbu.edu.tr

ÖZET

Solunum sistemi hastalıkları hem dünyada hem ülkemizde milyonlarca kişinin ölümüne sebep olan tıbbi bir problemdir. Teknolojinin gelişmesi ile ortaya çıkan bilgisayar destekli tanı sistemleri solunum sistemi hastalıklarının erken teşhisinde umut vadetmektedir. Bu çalışmanın amacı sağlıklı ve çeşitli akciğer hastalıklarına sahip bireylerden alınan solunum seslerinin otomatik teşhisi ile hekime yardımcı olan ve Tıp eğitimi gören öğrencilerin solunum seslerini öğrenmesine imkan sağlayan tanı sistemi geliştirilmesidir. Çalışmadaki kullanılan solunum sesleri, Manisa Celal Bayar Üniversitesi Hafsa Sultan Hastahanesi Göğüs Hastalıkları Anabilim dalındaki uzman hekimler tarafından Littman 3200 Elektronik Stetoskop ile kaydedilmiştir. 105 gönüllüden kaydedilen yedi farklı solunum grubuna ait solunum sesleri filtreleme, öznitelik çıkarımı ve sınıflama gibi sinyal işleme yöntemlerine tabi tutularak otomatik teşhis gerçekleştirilme ve teşhis sonucuna göre hastanın sahip olabileceği olası hastalıklar Kullanıcı Ara yüzünde listelenmektedir. Geliştirilen programda kullanılan yöntemlerin eğitilmesi ve başarılarının test edilebilmesi amacıyla veriler, eğitim ve test verisi olarak ayrılmıştır. Eğitime aşamasında geçerlilik yöntemleri kullanılarak eğitim tutarlılığı sağlanmıştır. Test verileri kullanılarak gerçekleştirilen analizler sonucunda Mel Frekansı Kepstral Katsayıları ve Destek Vektör Makineleri birlikte kullanıldığında en yüksek doğruluk oranı %94,5 olarak elde edilmiştir. Yüksek doğruluk oranı ile programın otomatik teşhisi başarılı bir şekilde gerçekleştirdiği kanıtlanmaktadır. Ayrıca Analiz programı Tıp öğrencilerinin kullanımına sunulacak bir diğer hedefine de ulaşmıştır.

Anahtar sözcükler: Solunum sesleri, Filtreleme, Öznitelik Çıkarımı, Sınıflama, Kullanıcı Arayüzü.

ABSTRACT

Respiratory system diseases are medical problem that causes the death of millions of people in the World. Recently, computer aided diagnosis systems are promising in the early diagnosis of respiratory system diseases. The purpose of this study is to develop a diagnostic system that assists the physician with the automatic diagnosis of respiratory sounds from individuals with healthy and varied lung diseases and to allows medical education students to learn their respiratory sounds. In this study, analysis is performed by applying various signal processing methods such as filtering, feature extraction and classification to respiratory sounds. As a result of the analysis, automatic diagnosis is made and possible diseases that the patient may have according to the diagnosis result are listed in the User Interface. The data is divided into training and testing data so that the methods used in the developed program can be trained and tested for their success. Analysis using test data results in the highest accuracy of 94.5% when combined with the Mel Frequency Cepstral Coefficients and Support Vector Machines. High accuracy rate proves that the program successfully performs automatic-diagnosis. The analysis program has been made available to Medical students and so it has achieved another goal.

Keywords: Respiratory sounds, Filtering, Feature Extraction, Classification, User Interface.

ToCite: ACAR DEMİRCİ, B., & KOÇYİĞİT, Y., (2023). SOLUNUM SİSTEMİ HASTALIKLARININ TEŞHİSİNE YÖNELİK MAKİNE ÖĞRENMESİ TABANLI ANALİZ PROGRAMI GELİŞTİRİLMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(1), 126-138.

GİRİŞ

Solunum sistemi hastalıkları hem dünyada hem ülkemizde milyonlarca kişinin ölümüne sebep olan tıbbi problemlerden biridir (World Health Organization, 2015). Toplumların yaş yapısındaki değişim, hareketsiz yaşam stilleri ve sigara içme oranlarının artışı gibi toplumsal faktörler ve hava kirliliği gibi çevresel faktörlerin etkisiyle önümüzdeki yıllarda solunum sistemi hastalıklarında artış beklenmektedir. Bu nedenle solunum yolu hastalıklarının erken teşhisi çok önemli bir araştırma alanıdır. Bilgisayarlı tomografi (BT), solunum fonksiyon testi, göğüs röntgeni ve akciğer oskültasyonu solunum yolu hastalıklarının tanısında etkili yöntemlerdir (Güler vd., 2005).

Oskültasyon bir hastalığın teşhisinde, organların işleyişini kontrol etmek için stetoskop yardımıyla vücut içi seslerin dinlenmesi işlemidir. Akciğer oskültasyonu, solunum sistemi hastalıklarını tespit edilmesinde kullanılan en basit ve ucuz yöntemdir. Yöntemin non-invazif olması, hızlı ve etkili teşhis sağlaması nedeniyle sıklıkla tercih edilmektedir. Oskültasyonun öncelikli amacı, normal solunum seslerini ve solunum sistemi patolojilerinin kabul edilen semptomlarının üzerine bindirilmiş artefaktlar olan ek seslerini tespit etmektir. Ayrıca oskültasyon ile göğsün farklı bölgelerinden elde edilen solunum seslerinin özellikleri (yoğunluk, süre vb.) gözlemlenerek, hastalığın hangi evrede ve hangi bölgede olduğu teşhis edilebilmektedir.

Solunum seslerinin düşük frekanslı karakteristiğe sahip olmaları, seslerin sinyal/gürültü oranının düşük olması, hekimin işitme sistemine ait fizyolojik kaynaklı kısıtlamalar ve hekimin bilgi ve tecrübesinin yeterli olmayışı, hatalı veya eksik hastalık teşhisine neden olmaktadır (Güler vd., 2005). Ayrıca geleneksel ölçüm yöntemlerinde solunum seslerini kaydetme imkânı olmadığı için tedavi boyunca hastanın takibi zorlaşmaktadır. Klasik stetoskoplar yerine gelişmiş dijital sinyal işleme tekniklerini içerisinde barındıran elektronik stetoskopun ortaya çıkışı, ek seslerin otomatik tespiti ve sınıflandırılması için algoritmaların geliştirilmesinde öncü olmuştur. Elektronik stetoskop teknolojisinde yalnızca daha iyi sensör ve akustik kuplaj tekniklerinin kullanılmasıyla değil, aynı zamanda elektronik sinyal iletimi, kuvvetlendirme ve gürültü azaltma yöntemlerinin kullanılmasıyla sürekli bir ilerleme kaydedilmiştir. Elektronik stetoskop kullanımı ile oskültasyon analogdan dijitale evrilmiştir ve bilgisayar üzerinden depolama, analiz ve görselleştirmeyi mümkün kılmıştır. Birçok çalışma, dijital oskültasyondan veri ve algoritmalar açısından yararlanmayı amaçlamaktadır. Stetoskopun hafızasına kaydedilen sesler, CORSA (Computerized Respiratory Sound Analysis) sistemleri kullanılarak analiz edilmek üzere bilgisayara aktarılır ve teşhis amaçlı kullanılır. Günümüzde CORSA sistemlerinin yaygın olarak kullanımına bağlı olarak göğüs hastalıkları alanında yapılan çalışmalar giderek artış göstermektedir. Spesifik bir hastalığa sahip olan ek solunum sesleri birçok çalışmada sağlıklı solunum sesleri ile karşılaştırılmıştır.

Corbera vd. (2004) yaygın görülen astım hastalığını teşhis amacıyla sibilan ronküs solunum sesine odaklanmışlardır. Çalışmada 15 sağlıklı kişi ve 16 astım hastasından spirometre ile kaydedilen solunum sesleri kullanılarak hırıltılı ve sağlıklı sesler arasındaki önemli farklılıkları tespit etmektedir (Homs-Corbera vd. 2004). Bahoura (2009) çalışmasında 12 sağlıklı kişi ve 12 astım hastası olmak üzere toplam 24 bireye ait solunum sesini kullanarak hastalık teşhisini %96,4 hassasiyetle gerçekleştirmiştir (Bahoura, 2009). Serbes vd. (2011) yaptıkları çalışmada solunum sesi olarak sağlıklı ve ral seslerini kullanmıştır. Ral seslerinin zamanlama ve oluşum sayısı gibi özelliklerinden akciğer hastalıklarının tipini ve şiddetini öğrenmek için yeni bir öznelik algoritması önermiş ve %97,2 doğruluk oranıyla teşhis sağlamıştır (Serbes vd., 2011).

Maruf vd. (2015) ral solunum seslerini otomatik olarak algılamak için CORSA sistemi önermektedir. Çalışma ral seslerini %97,56 başarı oranıyla otomatik algılamaktadır (Maruf vd., 2015). Lozano vd. (2016b) sağlıklı ve sibilan ronküs seslerini otomatik olarak teşhis etmek amacıyla Ampirik Mod Ayrışımı (EMD) tabanlı yöntemler önermektedir. Önerilen yöntemler, EMD yönteminin mod karıştırma problemini ortadan kaldırmakta ve yüksek enerji konsantrasyonu, yüksek zaman ve yüksek frekans çözünürlüğü sunmaktadır (Lozano vd., 2016b). Haider vd. (2019) sağlıklı ve kronik obstrüktif akciğer hastalığı (KOA) solunum seslerini sınıflamak için oskültasyon ve solunum fonksiyon testlerinin birlikte kullanılmasını önermektedir (Haider vd., 2019).

Pramono vd. (2019) solunum sırasında sibilan ronküs seslerini otomatik olarak tanımlamayı amaçlarken çeşitli öznelikleri karşılaştırmaktadır. Otomatik hırıltı tanımlamasına yönelik çalışma, farklı özneliklerin doğruluk, güvenilirlik ve hesaplama gereksinimleri açısından gerçekleştirilen analizleri sebebiyle de sonraki çalışmalar için önemli bir referans haline gelmektedir (Pramono vd., 2019). Altan vd. (2020) çok kanallı akciğer seslerini kullanarak KOA hastalığının erken teşhisini amaçlamaktadır. Derin öğrenme algoritması ile gerçekleştirilen sınıflama sonucunda %93,67 doğruluk oranı elde edilmiştir (Altan vd., 2020). Habukawa vd. (2021) günümüz pandemi

koşullarının akciğer hastalarına sahip çocukların üzerindeki olumsuz etkisini azaltmak amacıyla otomatik hırıltı (wheeze) tanıma algoritmasına sahip uzaktan tıbbi bakım imkanı sağlayan yeni ve kullanışlı bir tıbbi cihaz geliştirmiştir. Elde edilen sonuçlar hırıltı tanıma algoritmasının hırıltıyı yüksek doğrulukla tespit ettiğini ve cihazın uzaktan tıbbi bakımda hırıltı yönetimi için faydalı olacağını kanıtlamaktadır (Habukawa vd., 2021). Mukherjee vd. (2021) solunum yolu enfeksiyonuna sahip hastaların solunum seslerini algılamak için bir araç geliştirmiştir (Mukherjee vd., 2021).

Bu çalışma, literatürdeki çalışmalara benzer şekilde sağlıklı ve ek solunum seslerini teşhis etmeyi amaçlamaktadır. Ancak çalışmanın literatürdeki çalışmalardan hem hitap ettiği solunum grubu açısından hem de yöntemsel açıdan farkı mevcuttur. Bu çalışmada altı farklı ek solunum sesi ve sağlıklı solunum sesleri ile otomatik tanılama gerçekleştirilmektedir. Ampirik Mod Ayrıştırma yöntemi istatistiksel analiz ile birleştirilerek yöntemsel farklılık ortaya konulmuştur. Önerilen yöntemin başarısı, frekans analizi ve kepsral analiz ile karşılaştırılmıştır. Kepsral ve frekans analizleri sırasıyla Mel-Frekans Kepsral Katsayısı, Dalgacık Paket Dönüşümü ve Güç Spektrum Yoğunluğu yöntemleri kullanılarak yapılmıştır. Literatürde solunum seslerinin sınıflandırılması probleminde farklı sınıflandırıcıların performanslarının karşılaştırılması yaygın bir uygulamadır. Bu çalışma kapsamında Yapay Sinir Ağı, k-En Yakın Komşuluk Algoritması ve Destek Vektör Makinesi yöntemlerinin sınıflama başarısı karşılaştırılmıştır. Tüm bunların yanı sıra çalışmanın en önemli farkı ve katkısı, Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı geliştirilmesinin yanı sıra solunum seslerinin otomatik teşhisi ile hekime yardımcı olan ve Tıp eğitimi gören öğrencilerin solunum seslerini öğrenmesine imkan sağlayan Kullanıcı Arayüzüne sahip olmasıdır.

GEREÇ VE YÖNTEM

Solunum Seslerinin Elde Edilmesi

Solunumun inspirasyon ve ekspirasyon aşamasında solunum yollarındaki gaz basıncının hızlı değişmesi sonucu titreşimler meydana gelir. Titreşimler akciğer dokusundan geçip göğüs duvarına ulaştığında titreşimdeki farklılıklara göre belirli bir genlik ve frekansta solunum sesleri oluşur (Pasterkamp vd., 1997). Solunum sesleri temelde normal ve ek sesler diye ikiye ayrılır. Normal solunum sesleri, herhangi bir patolojik durum olmadığında duyulan seslerdir. Ek solunum sesleri, akciğerlerdeki veya solunum yollarındaki patolojik etkilerden kaynaklanır. Bu çalışmada frotman, stridor, sibilan ronküs, sonor ronküs, squawk ve ral ek sesleri ile sağlıklı seslerden oluşan normal veri seti kullanılmıştır. Sağlıklı akciğer sesi, inspirasyon aşamasında ekspirasyon aşamasına göre daha büyük genlikli ve daha yüksek frekanslı seslerdir. Bu seslerin sinyal frekans bandı 150 Hz ile 1000 Hz arasındadır (Palaniappan vd., 2013).

250ms den uzun süreli ek sesler, sürekli ek sesler olarak adlandırılmaktadır. Sürekli ek sesler frotman, stridor, sibilan ronküs, sonor ronküs ve squawk sesleridir. Sibilan ronküs sesleri ekspirasyon evresinde hava akımının daralmış hava yollarından yüksek hızla geçtiği sırada yaygın duyulan seslerdir. Hastalık şiddetine bağlı olarak inspirasyon ve ekspirasyon evresinde duyulabilen yüksek vurgulu bu seslerin frekans spektrumuna bakıldığında 400 Hz ve üzeri frekanslarda baskın olduğu gözlemlenmiştir. KOAH, kronik-akut bronşit ve astım gibi solunum yollarının tıkanması sonucu sıklıkla gözlemlenmektedir. Sonor ronküs, hava yolunda oluşan aşırı sekresyona bağlı olarak ekspirasyon evresinde duyulan ve 200 Hz ve daha düşük frekansları içeren düşük tepe değerli akciğer sesleridir. Akciğer alanlarında bu seslerin duyulması astım veya KOAH olarak düşünülmektedir. Squawk ek sesi, küçük hava yollarında oluşan ani açılmalarla oluşur. Parankimal akciğer hastalığı, bronşiolitis obliterans, alveolit ve idiyopatik pulmoner fibrozis hastalarında görülür. Frotman, inspirasyon evresinin sonunda ve ekspirasyon evresinin başında iltihaplı plevra yaprakların sürtünmesi sonucu duyulan kaba rale benzeyen ek sestir. Kaba rallerin aksine öksürükle kaybolmayan ve belirginleşen bu ek ses pulmoner emboli, plevral efüzyon, plörit ve kaburga kemiği kırıklarında oluşmaktadır. Stridor, gırtlak veya soluk borusunun darlığı neticesinde oluşan yüksek frekanslı, kaba seslerdir. Genellikle inspirasyon evresinde duyulmaktadır; ancak ekspirasyon evresinde darlığın fazla olduğu durumlarda da duyulabilmektedir. Frekans spektrumunda 1000 Hz frekansında belirgin bir tepe değeriyle fark edilir (Uysal, 2014). Bu ses, trakeada yabancı cisim veya bası durumunda, veyahut laringeal veya trakeal kitle olması durumlarında gözlemlenmektedir.

Sürekli olmayan ek sesler ral olarak adlandırılmaktadır. Raller, süresi 20 ms'den daha kısa olan, kısa patlamalı, geçici, frekans spektrumunda 200-2000 Hz arasındaki frekans bandına yayılan müzikal olmayan seslerdir. Raller birkaç farklı nedenden dolayı oluşabilmektedir. Birincisi, akciğerlerdeki fazla sıvılardan geçen havanın kabarcık yapmasıdır; ikincisi, tıkalı olan hava yollarının aniden açılmasıyla patlama benzeri gürültülü bir ses eşliğinde basıncın ani olarak eşitlenmesidir. Süre ve genlik değerleriyle tanımlanan rallerin sayısı, akciğer hastalığının derecesini, niteliğini ve bölgesel dağılımı gösterir (Demirci, 2019)

Bu çalışma kapsamında uzman hekimler tarafından sağlıklı sesleri de içeren toplam yedi farklı tür solunum sesi kaydedilmiştir. Littman 3200 Elektronik Stetoskop kullanılarak kaydedilen solunum sesleri MATLAB ortamında inspiryum evresinin başladığı andan itibaren 3 tam nefesi kapsayacak şekilde bölünmüş ve çeşitli sinyal işleme tekniklerinin uygulanması için hazır hale getirilmiştir. Bu seslerin işlenmesi üç temel adımdan oluşmaktadır. Bu adımlar sırasıyla; Filtreleme, Öznitelik Çıkarımı ve Sınıflamadır.

Filtreleme

Filtreleme işlemi sinyal işlemenin en temel adımıdır. Sinyalleri analize hazırlayan bu adım arka plan gürültülerinin kaldırılması, gürültü filtrelemesi, sinyallerin uygun aralıkta örneklenmesi ile kaydedilen solunum seslerinin kalitesini arttırmayı amaçlamaktadır. Bu çalışmada solunum seslerine Butterworth, Chebyshev ve Eliptik filtre uygulanmıştır. En iyi sonuç 4. Dereceden Butterworth filtre ile elde edilmiştir.

Öznitelik Çıkarımı

Özellik çıkarımı ile yüksek boyutlu solunum sesleri zaman ve frekans ekseninde analiz edilerek en önemli bileşenleri elde edilmektedir. Çalışmada Ampirik Mod Ayrışımı, Mel frekansı Kepstral Katsayıları, Dalgacık Paket dönüşümü ve Güç Spektrum Yoğunluğu olmak üzere dört farklı öznitelik çıkarım yöntemi tercih edilmiştir.

Ampirik Mod Ayrışımı

Ampirik mod ayrışımı yöntemi (EMD), çok bileşenli doğrusal olmayan ve durağan olmayan sinyallerin analizi için önerilen, Hilbert-Huang Dönüşümünden türetilen bir yöntemdir (Huang vd., 1996). Geleneksel sinyal analizi yöntemlerinin aksine sinyali farklı bir ekseninde incelemeye ihtiyaç duymamaktadır ve ayrıştırmanın bütün adımlarında kullanılan temel fonksiyonlar sinyalin kendisinden türetilmektedir (Lozano vd., 2016). Doğrusal olmayan ve durağan olmayan solunum seslerinin analizi için uygun bir araç olarak düşünülmektedir. Yöntemde solunum sesleri eleme işlemi aracılığıyla İçsel Kip Fonksiyonlarına (IMF) ayrıştırılmaktadır. IMF'ler orijinal sinyalden türetilen salınımsal sinyallerdir. IMF bileşenleri istatistiksel analiz fonksiyonları (standart sapma, varyans, mod, enerji, entropy ve ortalama güç) ile birleştirilmekte ve öznitelikler elde edilmektedir.

Mel Frekansı Kepstral Katsayıları

Ses analizinde sıklıkla tercih edilen Mel frekansı kepstum katsayıları yöntemi (MFCC) insan kulağının frekans seçiciliği göz önüne alınarak geliştirilmiştir (Sunil & Ganesan, 2015). Yöntemde; ses sinyallerinin alçak frekans bileşenlerinin taşıdığı bilginin daha önemli olduğu düşünülerek, sinyaller doğrusal özellik göstermeyen Mel Ölçeğinden geçirilmektedir. Ölçekleme sayesinde MFCC katsayıları ses sinyallerinin yapısal değişiminden daha az etkilenmektedir. Bu çalışmada solunum seslerine MFCC yöntemi uygulanmış ve elde edilen 13 kepstal katsayı istatistiksel analiz fonksiyonları ile birleştirilerek öznitelikler elde edilmiştir.

Güç Spektrum Yoğunluğu

Güç spektrum yoğunluğu (PSD) yöntemi zaman düzlemindeki bir sinyalin genlik bilgisini frekans düzleminde ifade etmeye imkan sağlayan Fourier dönüşümünden türetilen bir analiz yöntemidir. Frekans bileşenlerinin elde etmek için sinyale Fourier dönüşümü uygulanmaktadır. Elde edilen frekans bileşenlerinin mutlak değerinin karesi periyodun iki katına bölünerek sinyalin frekans bandı üzerindeki güç dağılımı hesaplanır (Gengeç, 2012). Bu çalışmada Welch metodu kullanılarak Güç spektrum yoğunluğu hesaplanmıştır.

Dalgacık Paket Dönüşümü

Dalgacık dönüşümü solunum sesleri gibi doğrusal olmayan ve durağan olmayan sinyallerin zaman-frekans analizinde sıkça kullanılan dönüşüm yöntemidir (Rioul & Vetterli, 1991). Dalgacık dönüşümünde pencere görevini ana dalgacık fonksiyonları üstlenir. Ana dalgacık fonksiyonları dönüşüm işlemi süresince hem ölçeklenmekte hem de ötelenmektedir. Dalgacık dönüşümünde pencere fonksiyonunun genişliği sabit değildir; yüksek frekanslar için dar pencere genişliği, düşük frekanslar için ise geniş pencere büyüklüğü kullanılmaktadır. Dalgacık dönüşümünde farklı pencere genişliği kullanılması sayesinde zaman ve frekans ekseninde çözünürlük artmaktadır. Dalgacık dönüşümü kullanılan sinyal yapısına göre değişiklik göstermektedir. Sürekli zaman sinyalleri için sürekli dalgacık dönüşümü, ayırık zaman sinyalleri için ise ayırık dalgacık dönüşümü kullanılmaktadır. Dalgacık paket dönüşümü (WPA) ayırık dalgacık dönüşümü tabanlı bir yöntemdir (Bahoura, 2006). Coifman ve Winkerhauser tarafından önerilen yöntemde sinyallerin hem yaklaşık katsayıları hem de detay katsayıları istenen ayrıştırma seviyesine kadar frekans bantlarına ayrıştırılabilmektedir. Çalışmada dördüncü seviyeye kadar ayrıştırma yapılırken ana dalgacık fonksiyonu olarak

Daubechies (db5) kullanılmıştır. Elde edilen katsayılara istatistiksel analiz fonksiyonları uygulanarak öznelikler elde edilmektedir.

Sınıflama

Bu çalışma kapsamında k-En Yakın Komşuluk Algoritması, Yapay Sinir Ağı ve Destek Vektör Makinesi yöntemleri sınıflama performansları karşılaştırılmıştır.

k- En Yakın Komşuluk Algoritması

k En Yakın Komşuluk Algoritması (k-NN) sınıflama ve regresyon amacıyla kullanılan basit ve kolay bir denetimli öğrenme algoritmasıdır. Yöntem eğitim gerektirmez, kolay gerçekleştirilebilir, yerel bilgilere uyarlanabilir ve gürültülü eğitim verilerine dirençlidir (Göğüş, 2015). Bu üstünlükleri sayesinde diğer makine öğrenmesi algoritmaları arasında popülerliğini koruyan k-NN sınıflayıcı; yeni gelen bir verinin sınıfını belirlemek için veri setindeki eğitim örneklerine olan yakınlığını incelemektedir. Yakınlık tespiti için Öklid, Minkowski veya Manhattan gibi uzaklık denklemleri kullanılmaktadır. Çalışmada k=3 seçilmiş ve Öklid uzaklığı hesaplanarak en yakın üç komşu incelenmiştir. Çapraz doğrulama katsayısı kFold=10 belirlenerek veri on eşit parçaya bölünmüş, her bir parça hem eğitim hem de test için kullanılmaktadır. Çapraz doğrulama ile verideki dağılım ve parçalanmadan kaynaklı sapma ve hata minimum hale gelmektedir.

Yapay Sinir Ağı

Yapay Sinir Ağı (ANN), insan beyinin çalışma ve düşünebilme yeteneğinden ilham alınarak geliştirilen, öğrenme sürecini matematiksel modelleyebilen yazılımlardır. Biyolojik sinir hücrelerini taklit eden yöntemde bilgilerin işlenmesi paralel olarak gerçekleşmektedir (Elmas, 2016). Paralel işleme dolayısıyla bir birimde oluşan hatanın sistemi etkileme oranı düşüktür. Yapay Sinir Ağları öğrenme ve genelleme yeteneğine sahiptir. Öğrenme sürecinde eğitim örneklerinin giriş ve çıkış bilgileri sisteme tanıtılmaktadır. Problemi öğrenen sinir ağı, hücreler arasındaki bağlantıları ve bağlantı ağırlıklarını amaca uygun olarak güncellemektedir. Genelleme, eğitim veya öğrenme sürecinde karşılaşılmayan test örneklerinin girişleri için ağı oluşturduğu tepkidir. Bu özellikleri sayesinde yöntem veri ilişkilendirme ve yorumlama, sınıflama, tahmin ve modelleme problemleri gibi karmaşık problemlerin çözümünde sıklıkla tercih edilmektedir. Yapay sinir ağı modelleri oluşturulurken çözümlen istenen probleme göre nöronların bağlantı şekli, toplama ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması belirlenmelidir. Çalışma kapsamında solunum seslerinin sınıflanması için ileri beslemeli Çok Katmanlı Algılayıcı ağ yapısı tercih edilmiştir. İleri beslemeli ağlarda giriş nöronları ile çıkış nöronları arasında tek yönlü bağlantı mevcuttur. Bu ağ yapısında gecikme söz konusu olmamaktadır. Bu çalışmada Levenberg-Marquardt öğrenme algoritması tercih edilmiştir. Bu öğrenme algoritması maksimum komşuluk düşüncesi üzerine kurulmuş en az kareler hesaplama yöntemidir. Gauss-Newton ve Grandyent Descent algoritmalarının en iyi özelliklerinden oluşan algoritma iki algoritmanın kısıtlamalarını kaldırır ve daha hızlı sonuç üretir.

Destek Vektör Makineleri

Danışmanlı bir öğrenme algoritması olan Destek Vektör Makineleri (SVM) yöntemini, Vladimir Vapnik 1992 yılında sınıflandırma ve regresyon analizi problemlerini çözmek üzere geliştirmiştir (Vapnik, 1998). SVM yöntemi yapısal risk minimizasyonu prensibine göre çalışan bir optimizasyon algoritmasıdır. Yöntemin en büyük başarı nedeni sınıflandırma problemini kareli optimizasyon problemine dönüştürerek çözmesidir. Bu sayede öğrenme aşamasında işlem yükü azalmakta ve hızlı çözüm sağlanmaktadır. Yöntem yerel çözümlere takılmama ve yüksek genelleme yeteneği sayesinde ses tanıma, yazı, nesne ve görüntü tanıma problemlerine ait karmaşık veri setlerinde ve çözümlenmesi zor örüntülerin tanınmasında sıklıkla tercih edilir. (Başer & Apaydın, 2015). SVM iki sınıfı birbirinden en uygun şekilde ayıran hiper-düzlemi tahmin etme esasına dayanmaktadır.

Kullanıcı Arayüzü

Bu çalışmada, MATLAB App Designer kullanılarak tasarlanan kullanıcı arayüzü, solunum seslerinin otomatik teşhisi ile hekime yardımcı olmayı ve tıp eğitimi gören öğrencilere solunum seslerini öğretmeyi amaçlamaktadır. Arayüzü oluşturan üç ana pencereden aşağıdaki gibidir;

- i. Giriş Penceresi
- ii. Eğitim ve Tanıtım Penceresi
- iii. Hakkında Penceresi

Giriş Penceresi

Solunum seslerinin otomatik teşhisi bu pencerede gerçekleştirilmektedir. Giriş penceresi dört ana bölümden oluşmaktadır;

i. Hasta Bilgileri Bölümü

Bu bölüm solunum sesinin ait olduğu hastaya ait bilgilerin girişi için tasarlanmıştır. Hastanın TC kimlik numarası, cinsiyet, yaş, kilo ve meslek bilgilerinin yanı sıra hastalığa neden olabilecek biomass maruziyeti, sigara kullanımı gibi bilgileri sisteme girilmektedir. Girilen bilgiler 'Sonuçları Kaydet' butonu aracılığıyla xlsx formatında kaydedilebilmektedir.

ii. Solunum Veri Girişi Bölümü

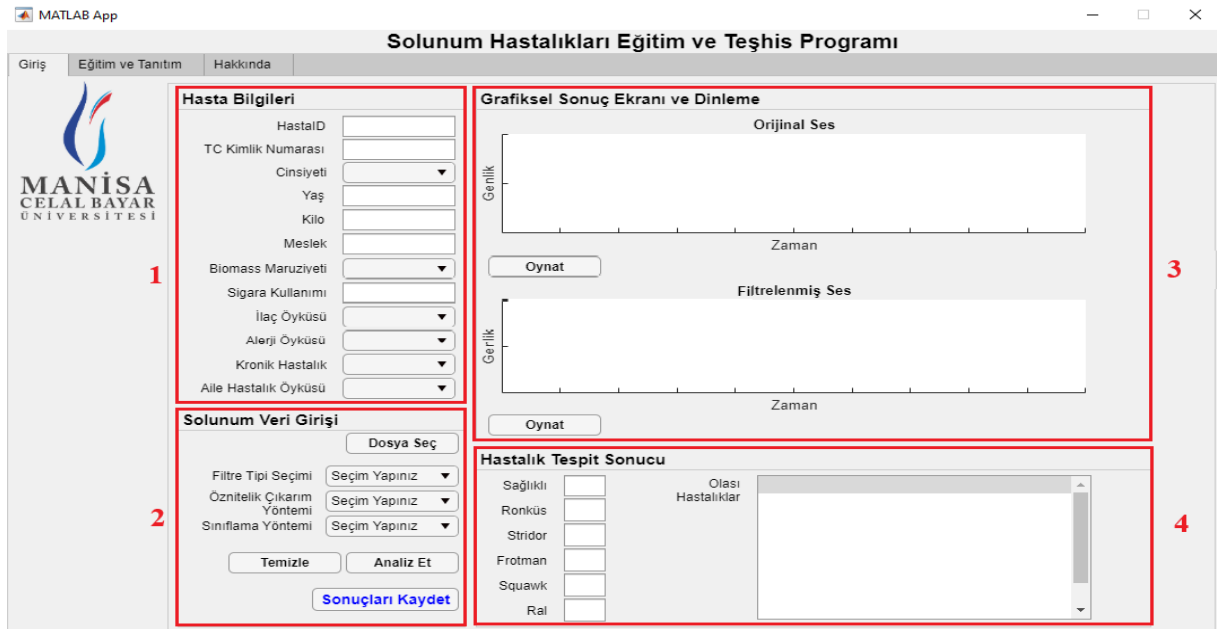
İlgili bölümde solunum sesinin sisteme girilmesi ve teşhis amacıyla kullanılacak filtre tipi, öznitelik çıkarım yöntemi ve sınıflama yöntemlerinin seçimi gerçekleştirilmektedir. Otomatik teşhisi istenen solunum sesi 'Dosya Seç' butonuyla seçilmektedir. 'Filtre Tipi Seçimi' butonunda Butterworth, Chebyshev ve Eliptik Filtre seçenekleri mevcuttur. Seçeneklerden biri seçilerek teşhisi istenen solunum seslerindeki gürültüler giderilmektedir. Filtrelenen solunum sesinin önemli özniteliklerinin çıkarılması için 'Öznitelik Çıkarım Yöntemi' butonu kullanılmaktadır. Özniteliklerin çıkarılması EMD, MFCC, PSD ve WPA seçenekleri ile gerçekleştirilmektedir. Yöntemlerden birinin uygulanması ile solunum sesinin en önemli öznitelikleri elde edilmektedir. Öznitelikler 'Sınıflama Yöntemi' butonunda bulunan ANN, k-NN ve SVM yöntemleri ile sınıflanmaktadır. 'Analiz Et' butonuna basıldığında yapılan seçimlere göre solunum sesi teşhisi başlamaktadır. 'Temizle' butonuyla yapılan seçimler sıfırlanabilmektedir.

iii. Grafikselsel Sonuç Ekranı ve Dinleme Bölümü

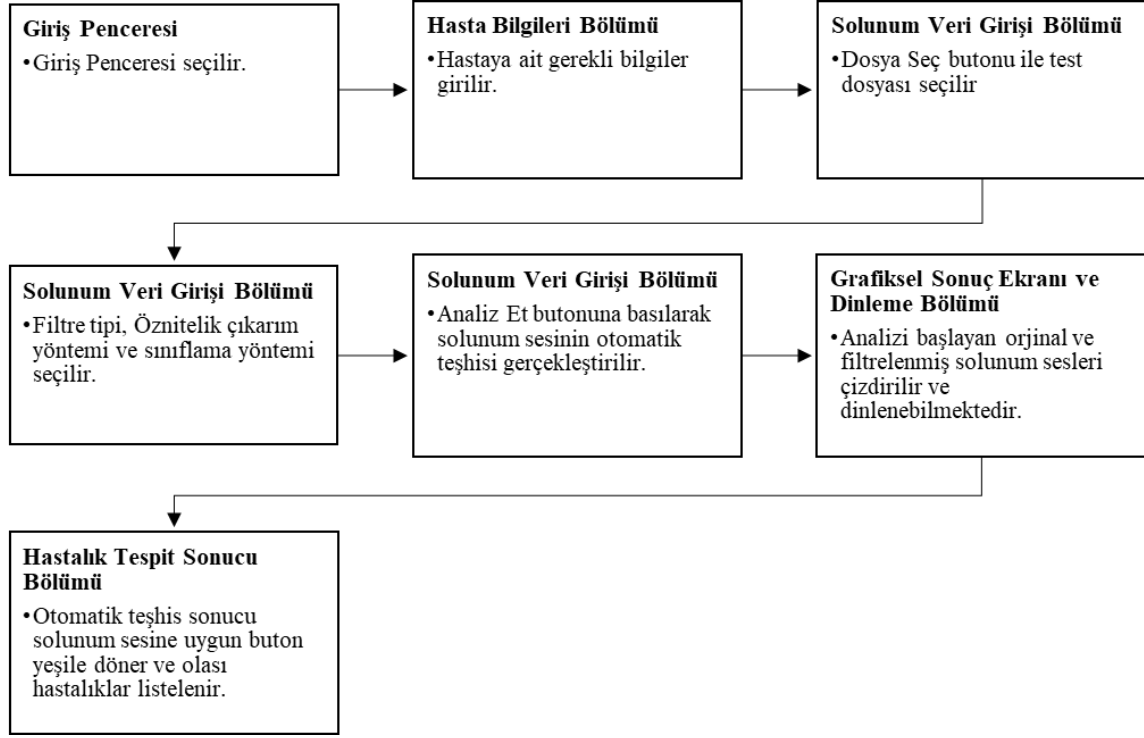
Bu bölüm, solunum veri girişinde teşhisi istenen orijinal solunum sesi ile filtrelenerek gürültülerden arındırılan solunum sesinin görselleştirilmesi ve dinlenmesine imkan sağlamaktadır.

iv. Hastalık Tespit Sonucu Bölümü

Teşhis edilen solunum sesine ait analiz sonucu 'Hastalık Tespit Sonucu' bölümünde gösterilmektedir. Analiz sonucu ses sağlıklı ise sağlıklı butonu, hasta ise mevcut hastalığa ait buton yeşile dönmektedir. Ve solunum sesine göre hastanın sahip olabileceği olası hastalıklar görülme sıklıklarına göre listelenmektedir. Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı Giriş Penceresinin bölümlerine ait görsel Şekil 1'de görülmektedir. Giriş Penceresinin işleyişini anlatan ve otomatik tanılama sırasında sırasıyla hangi işlemlerin uygulanacağını belirten blok diyagram ise Şekil 2'de belirtilmektedir.



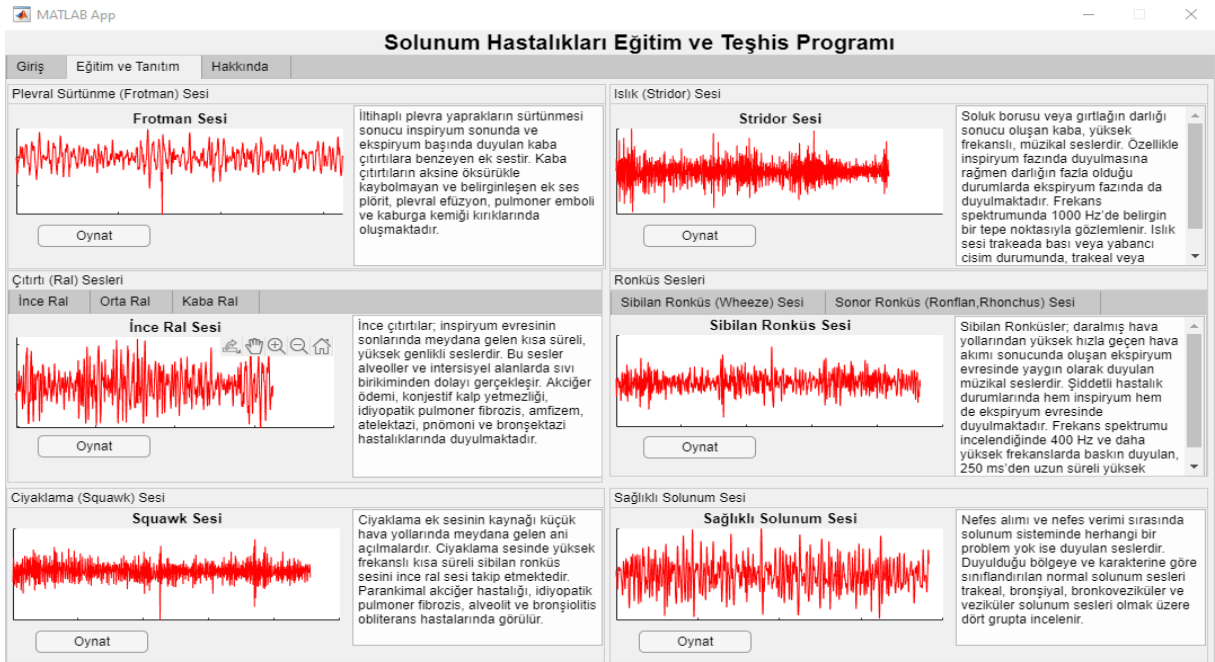
Şekil 1. Giriş Penceresi Bölümleri



Şekil 2. Otomatik Teşhisin İşleyişine Ait Blok Diyagram

Eğitim ve Tanıtım Penceresi

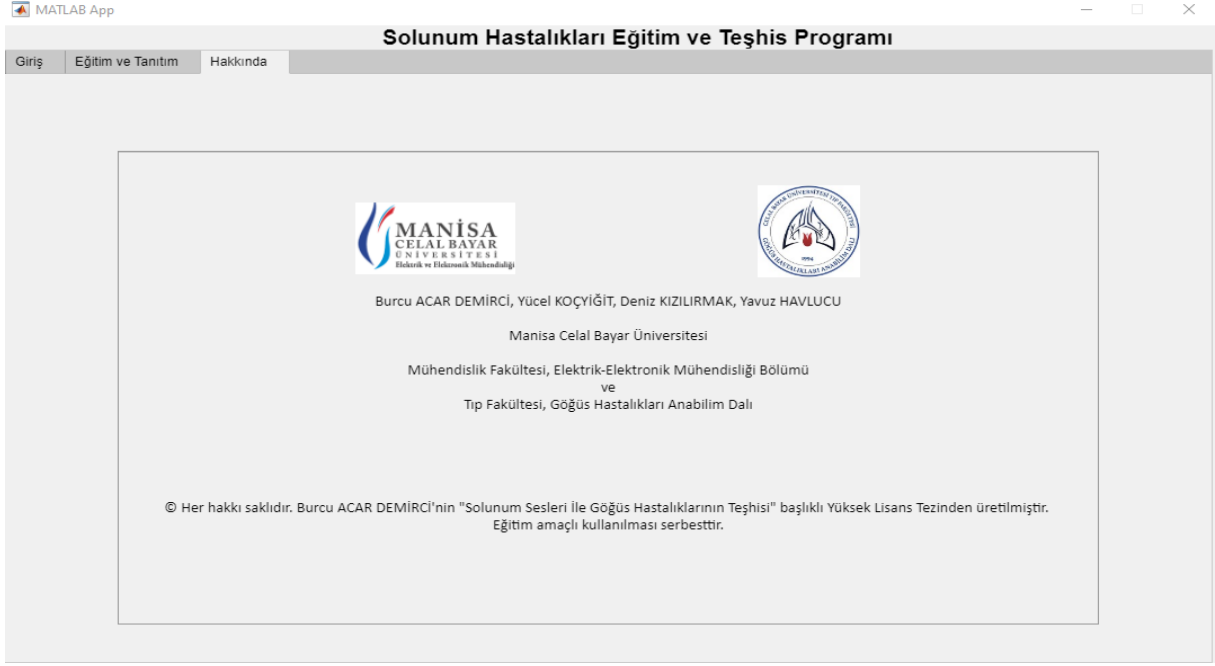
Eğitim ve tanıtım penceresi tüm ses gruplarına ait sesleri öğretmek amacıyla tasarlanmıştır. Solunum sesini dinlemeye ve hakkında bilgi edinmeye imkan sağlamaktadır. İlgili solunum sesinin neden oluştuğu, hangi hastalıklarda sıklıkla duyulduğu gibi genel bilgilere yer verilmiştir. Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı Eğitim ve Tanıtım Penceresine ait görsel Şekil 3’de verilmiştir.



Şekil 3. Eğitim ve Tanıtım Penceresi

Hakkında Sekmesi

Bu sekmede gerçekleştirilen projeye ait bilgiler yer almaktadır. Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı Hakkında Penceresine ait görsel Şekil 4’de verilmiştir.




Şekil 4. Hakkında Penceresi

BULGULAR VE SONUÇ

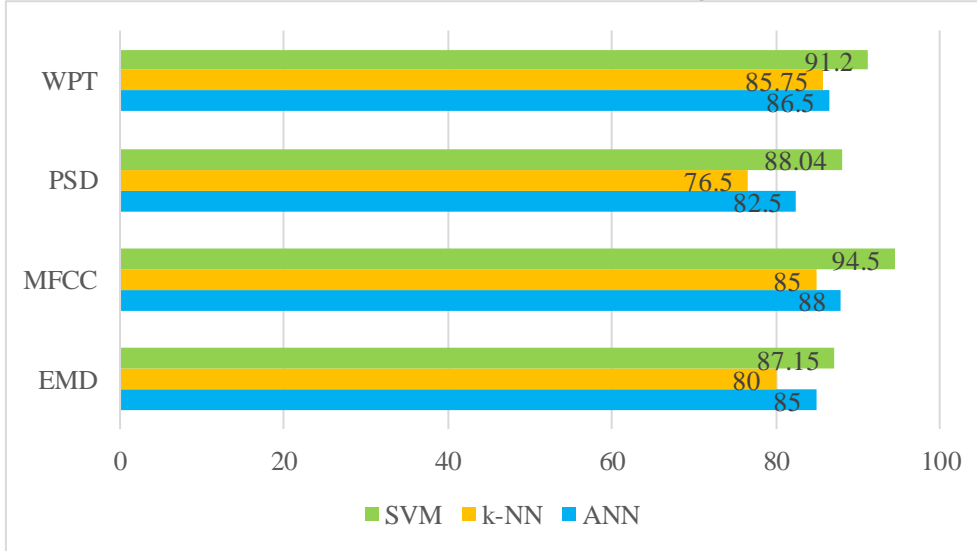
Bu çalışmada geliştirilen ‘Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı’ ile solunum sesleri otomatik teşhis edilmektedir. Programda kullanılan solunum sesleri Manisa Celal Bayar Üniversitesi, Hafsa Sultan Hastahanesi Göğüs Hastalıkları Anabilim Dalında uzman hekimler tarafından kaydedilmiştir.

Programda kullanılan yöntemlerin başarısını değerlendirmek için öncelikle yedi farklı hastalık tipine ait solunum sesi filtreleme işleminden geçirilmiştir. Filtrelenen solunum seslerine öznitelik çıkarım yöntemleri uygulanarak solunum seslerinin önemli bileşenleri elde edilmiştir. Öznitelik olarak adlandırılan bu önemli bileşenler sınıflama yöntemleri ile gruplara ayrılmıştır. Solunum sesleri, ANN sınıflayıcı için %80 Eğitim ve %20 Test verisi olacak şekilde ayrılırken k -NN ve SVM sınıflayıcıları için k Fold=10 belirlenerek 10 kat çapraz doğrulamaya tabi tutulmuştur. Otomatik teşhis sırasında kullanılabilir yöntemlerin solunum seslerini sınıflama başarısı önem arz etmektedir. Test verilerinin sınıflama başarılarına ait doğruluk oranları Tablo 1, Tablo 2 ve Tablo 3 de verilmektedir. Tablolarda verilen başarı oranlarını elde etmek için sınıflama yöntemleri 10 kez çalıştırılmış ve ortalamaları alınmıştır. En başarılı sınıflama sonuçları Butterworth filtre uygulanan solunum sesleri ile elde edilmiştir. Butterworth Filtre uygulanan solunum seslerinde en başarılı öznitelik çıkarım yöntemi MFCC ve en başarılı sınıflama yöntemi SVM olarak tespit edilmiştir. Bu yöntemler birlikte kullanıldığında %94,5 doğruluk oranı elde edilmiştir.


Tablo 1. Chebyshev Filtre ile Elde edilen Başarı Oranları



Tablo 2. Butterworth Filtre ile Elde edilen Başarı Oranları



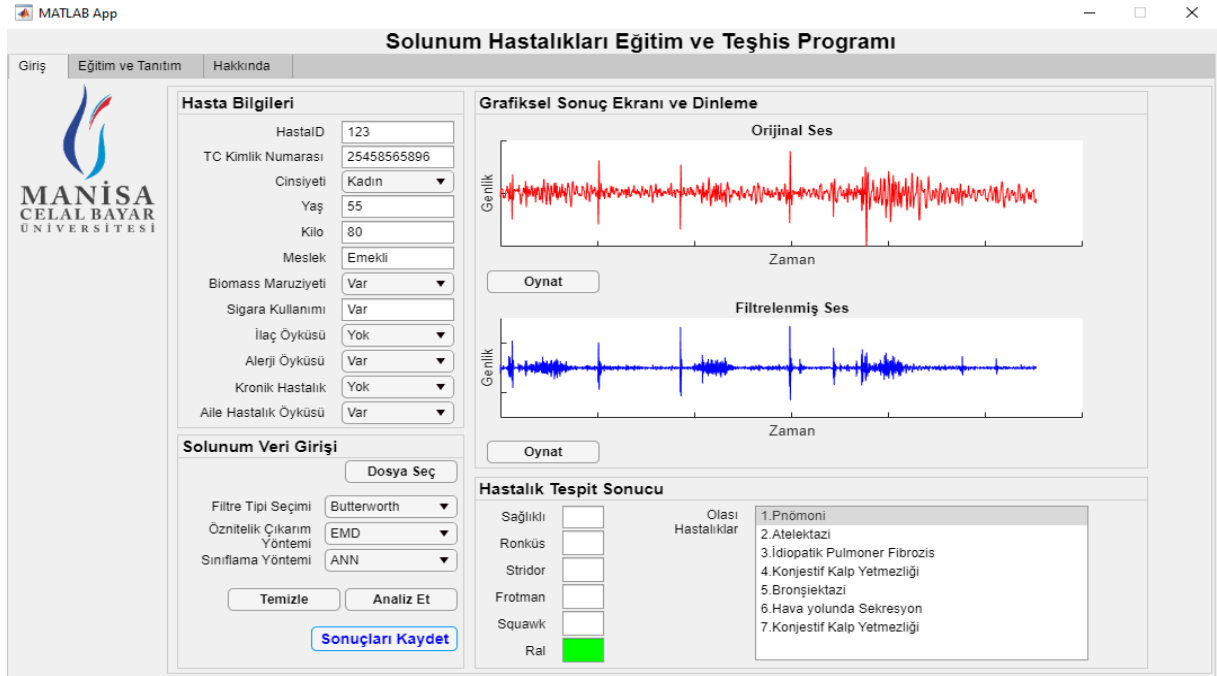
Tablo 3. Eliptik Filtre ile Elde edilen Başarı Oranları



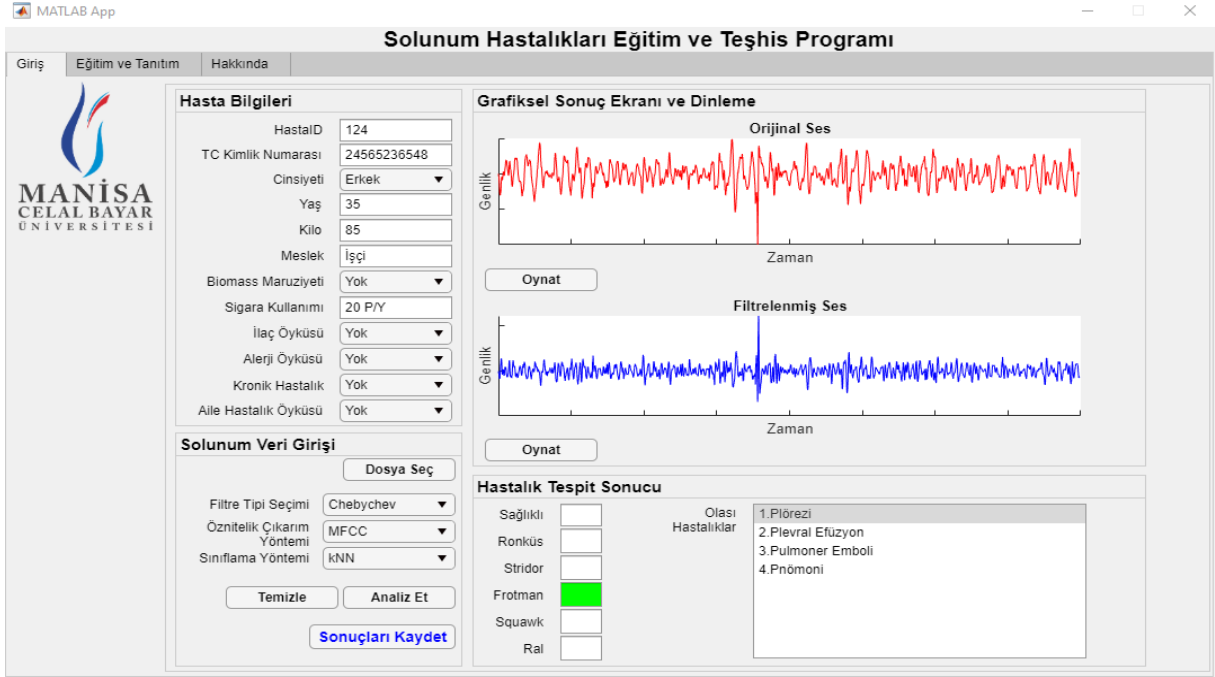
Kullanıcı Arayüzünde ise durum biraz daha farklıdır. Eğitimde kullanılmayan test verisi veya yeni kaydedilmiş bir solunum sesi Dosya Seç butonuyla programa dahil edilmektedir. Dahil edilen bu sesin seçilen yöntemlere bağlı öznelikleri elde edilmektedir. Elde edilen öznelikler önceden eğitilmiş sınıflayıcı modeller kullanılarak sınıflanmaktadır.

‘Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı’ çalıştırıldığında Şekil 5, Şekil 6 ve Şekil 7 görselleri elde edilmektedir. Kişisel verilerin korunumu açısından hastaya ait TC kimlik no verileri rastgele girilmiştir.

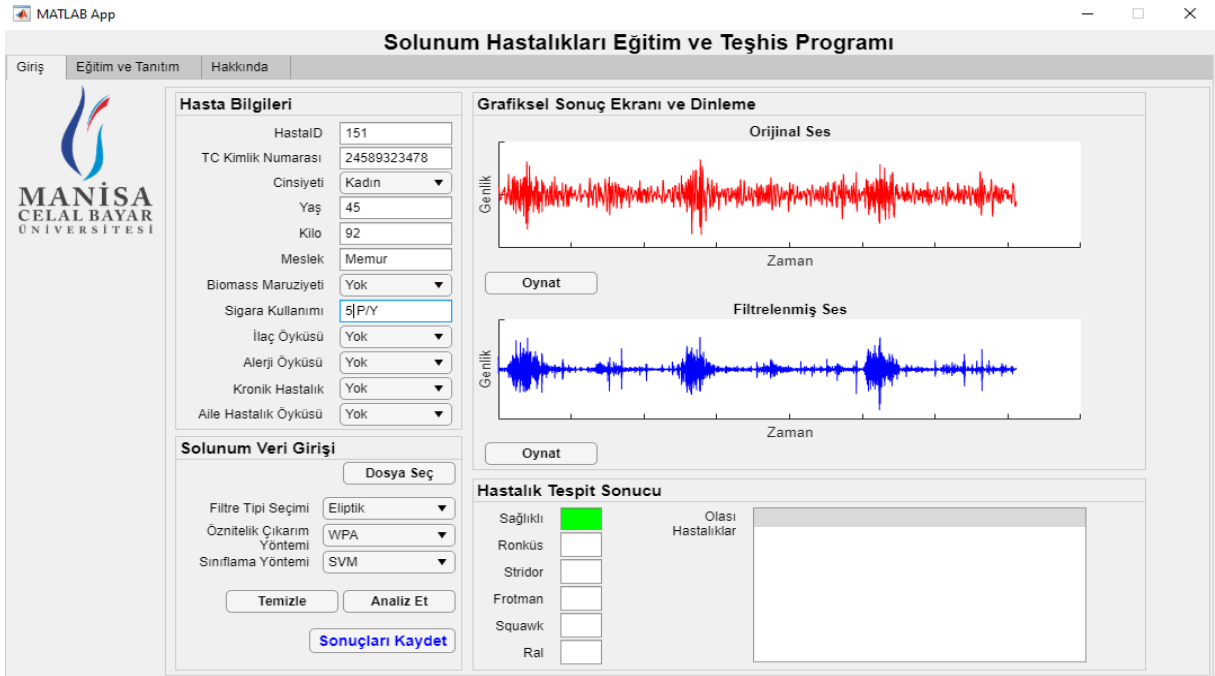
- i. Şekil 5’de 123 no’lu hastaya ait veriler mevcuttur. Butterworth Filtre, EMD öznelik çıkarım yöntemi ve ANN sınıflayıcı seçilerek analiz edilen hastanın Ral solunum sesine sahip olduğu tespit edilmiştir. Hastanın sahip olabileceği hastalıklar ‘Olası Hastalıklar’ bölümünde verilmiştir.
- ii. Şekil 6’da 124 no’lu hastaya ait veriler mevcuttur. Chebyshev Filtre, MFCC öznelik çıkarım yöntemi ve k -NN sınıflayıcı seçilerek analiz edilen hastanın Frotman solunum sesine sahip olduğu tespit edilmiştir. Hastanın sahip olabileceği hastalıklar ‘Olası Hastalıklar’ bölümünde verilmiştir.
- iii. Şekil 7’de 151 no’lu hastaya ait veriler mevcuttur. Eliptik Filtre, WPA öznelik çıkarım yöntemi ve SVM sınıflayıcı seçilerek analiz edilen solunum sesinin sağlıklı olduğu tespit edilmiştir.



Şekil 5. 123 Nolu Hastaya Ait Örnek



Şekil 6. 124 Nolu Hastaya Ait Örnek



Şekil 7. 151 Nolu Hastaya Ait Örnek

TARTIŞMA

Bu çalışmanın amacı geliştirilen 'Solunum Sistemi Hastalıklarının Teşhisine Yönelik Makine Öğrenmesi Tabanlı Analiz Programı'nın başarısını vurgulamak ve geliştirilen erken tanı sisteminin tanıtılmasıdır. MATLAB ortamında tasarlanan Kullanıcı Arayüzü farklı hastalıklara ait solunum sesleri örneklerini içermektedir. Bu örneklere farklı filtreler, öznelik çıkarım ve sınıflama yöntemleri uygulanarak solunum sesinin tipi ve bu sese ait olası hastalıklar listelenmektedir. Yöntemlerin başarıları açısından değerlendirme yapılacak olursa en başarılı filtre Butterworth filtresidir. MFCC yöntemi ile elde edilen öznelikler sınıflama sırasında daha başarılı sonuçlar üretmiştir. En başarılı sınıflama sonucu MFCC ve SVM yöntemleri birlikte kullanıldığında elde edilmiştir.

Sonraki çalışmalarda arayüz üzerinde solunum seslerinin parçalara ayrılarak dinlenebilmesi ve analiz edilebilmesinin yanı sıra solunum sesi örneklerinin artırılması amaçlanmaktadır. Solunum sesleri arttıkça çalışmanın başarısının artacağı öngörülmektedir.

TEŞEKKÜR

Çalışmaya destek olan Manisa Celal Bayar Üniversitesi Hafsa Sultan Hastanesi Göğüs Hastalıkları Anabilim Dalı üyelerine teşekkür ederiz.

MADDİ DESTEK

Bu çalışma Manisa Celal Bayar Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi [Proje No. 2017-191] tarafından desteklenmiştir. Bu çalışma kapsamında kaydedilen solunum sesleri 20.10.2017 tarih ve 20.478.486 numaralı etik kurul onayı ile alınmıştır.

KAYNAKÇA

Altan, G., Kutlu, Y., & Allahverdi, N. (2020). Deep learning on computerized analysis of chronic obstructive pulmonary disease. *IEEE Journal of Biomedical and Health Informatics*, 24(5), 1344–1350. <https://doi.org/10.1109/JBHI.2019.2931395>

Bahoura, M. (2006, May). Separation of crackles from vesicular sounds using wavelet packet transform. In 2006 IEEE International Conference on Acoustics Speed and Signal Processing Proceedings,(pp. 1076-1079). <https://doi.org/10.1109/ICASSP.2006.1660533>

Bahoura, M. (2009). Pattern recognition methods applied to respiratory sounds classification into normal and wheeze classes. *Computers in Biology and Medicine*, 39(9), 824–843. <https://doi.org/10.1016/j.combiomed.2009.06.011>

Başer, F., & Apaydın, A. (2015). Sınıflandırma amaçlı destek vektör makinelere lojistik regresyon ile karşılaştırılması. *Anadolu Üniversitesi Bilim Ve Teknoloji Dergisi - B Teorik Bilimler*, 3(2), 53–65. <https://doi.org/10.20290/btdb.67263>

Demirci, B. A. (2019). Solunum sesleri ile göğüs hastalıklarının teşhisi. Yüksek Lisans Tezi. Manisa Celal Bayar Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Manisa 104s.

Elmas, Ç. (2016). Yapay Zeka Uygulamaları (3rd ed.). Seçkin Yayıncılık. <https://www.seckin.com.tr/kitap/n/224686494/title/yapay-zeka-uygulamaları-cetin-elmas.html>

Gengeç, Ş. (2012). Akciğer seslerinden işaret işleme teknikleri kullanılarak özellik çıkarma ve sınıflandırma. Yüksek Lisans Tezi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı, Kayseri 116 s.

Göğüş, F. Z. (2015). Biyomedikal seslerin analizi ve sınıflandırılması. Yüksek Lisans Tezi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Konya 126 s.

Güler, I., Polat, H., & Ergün, U. (2005). Combining neural network and genetic algorithm for prediction of lung sounds. *Journal of Medical Systems*, 29(3), 217–231. <https://doi.org/10.1007/s10916-005-5182-9>

Habukawa, C., Ohgami, N., Arai, T., Makata, H., Tomikawa, M., Fujino, T., Manabe, T., Ogihara, Y., Ohtani, K., Shirao, K., Sugai, K., Asai, K., Sato, T., & Murakami, K. (2021). Wheeze recognition algorithm for remote medical care device in children: validation study. *JMIR Pediatric and Parenting* 2021;4(2):E28865 <https://Pediatrics.Jmir.Org/2021/2/E28865>, 4(2), e28865. <https://doi.org/10.2196/28865>

Haider, N. S., Singh, B. K., Periyasamy, R., & Behera, A. K. (2019). Respiratory Sound Based Classification of Chronic Obstructive Pulmonary Disease: a Risk Stratification Approach in Machine Learning Paradigm. *Journal of Medical Systems*, 43(8). <https://doi.org/10.1007/s10916-019-1388-0>

- Homs-Corbera, A., Fiz, J. A., Morera, J., & Jané, R. (2004). Time-frequency detection and analysis of wheezes during forced exhalation. *IEEE Transactions on Biomedical Engineering*, 51(1), 182–186. <https://doi.org/10.1109/TBME.2003.820359>
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Yen, N., Tung, C. C., & Liu, H. H. (1996). The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Royal Society of London Proceedings Series A*, 454(1), 903–995. <https://doi.org/10.1098/rspa.1998.0193>
- Lozano, M., Fiz, J. A., & Jané, R. (2016a). Automatic differentiation of normal and continuous adventitious respiratory sounds using ensemble empirical mode decomposition and instantaneous frequency. *IEEE Journal of Biomedical and Health Informatics*, 20(2), 486–497. <https://doi.org/10.1109/JBHI.2015.2396636>
- Lozano, M., Fiz, J. A., & Jané, R. (2016b). Performance evaluation of the hilbert-huang transform for respiratory sound analysis and its application to continuous adventitious sound characterization. *Signal Processing*, 120, 99–116. <https://doi.org/10.1016/j.sigpro.2015.09.005>
- Maruf, S. O., Azhar, M. U., Khawaja, S. G., & Akram, M. U. (2015, December). Crackle separation and classification from normal respiratory sounds using gaussian mixture model. In 2015 IEEE 10th International Conference on Industrial and Information Systems (ICIIS 2015) (pp. 267–271). <https://doi.org/10.1109/ICIINFS.2015.7399022>
- Mukherjee, H., Sreerama, P., Dhar, A., Obaidullah, S. M., Roy, K., Mahmud, M., & Santosh, K. C. (2021). Automatic lung health screening using respiratory sounds. *Journal of Medical Systems*, 45(2). <https://doi.org/10.1007/s10916-020-01681-9>
- Palaniappan, R., Sundaraj, K., Ahamed, N., Arjunan, A., & Sundaraj, S. (2013). Computer-based respiratory sound analysis: a systematic review. *IETE Technical Review*, 33(3), 248–256. <https://doi.org/10.4103/0256-4602.113524>
- Pasterkamp, H., Kraman, S. S., & Wodicka, G. R. (1997). State of the art respiratory sounds advances beyond the stethoscope. *American Journal of Respiratory and Critical Care Medicine*, 156, 974–987. <https://doi.org/10.1164/ajrccm.156.3.9701115>
- Pramono, X. A. R., Intiaz, S. A., & Rodriguez-Villegas, E. (2019). Evaluation of features for classification of wheezes and normal respiratory sounds. *PLoS One*, 14(3): e0213659.
- Rioul, O., & Vetterli, M. (1991). Wavelets and signal processing. *IEEE Signal Processing Magazine*, 8(4), 14–38. <https://doi.org/10.1109/79.91217>
- Serbes, G., Sakar, C. O., Kahya, Y. P., & Aydin, N. (2011, August). Feature extraction using time-frequency/scale analysis and ensemble of feature sets for crackle detection. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE) (pp. 3314–3317). <https://doi.org/10.1109/IEMBS.2011.6090899>
- Sunil, N. K. B., & Ganesan, R. (2015). Adaptive neuro-fuzzy inference system for classification of respiratory signals using cepstral features. *International Journal of Applied Engineering Research*, 10(28), 22121–22125. <http://www.ripublication.com/Volume/ijaerv10n28spl.htm>
- Uysal, S. (2014). Ses Analizi İle Hastalık Teşhisi. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programı, İstanbul 82s.
- Vapnik, V. N. (1998). Statistical learning theory. Wiley.
- World Health Organization. (2015). WHO World Health Statistics. http://apps.who.int/iris/bitstream/10665/170250/1/9789240694439_eng.pdf?ua=1&ua=1 Accessed 05.03.23.