



MARMARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



# YAPAY ZEKA İLE KOAH HASTALARININ DURUM ANALİZİ VE İOT İLE SOLUNUM VERİLERİNİN TAKİBİ

MUHAMMED AYDINALP ÖZCAN

523120030

**YÜKSEK LİSANS TEZİ**

Elektrik- Elektronik  
Mühendisliği Bölümü

**DANIŞMAN**

Dr. Öğr. Üyesi Hasan Hüseyin Çelik

İSTANBUL, 2024



**MARMARA UNIVERSITY**  
**INSTITUTE FOR GRADUATE STUDIES**  
**IN PURE AND APPLIED SCIENCES**



**ARTIFICIAL INTELLIGENCE-BASED  
ANALYSIS OF COPD PATIENTS'  
CONDITION AND MONITORING OF**

---

---

**RESPIRATORY DATA WITH IOT**

MUHAMMED AYDINALP ÖZCAN

523120030

**MASTER THESIS**

Department of Electrical and Electronics Engineering

**Thesis Supervisor**

Asst. Prof. HASAN HÜSEYİN ÇELİK

İSTANBUL, 2024

# İÇİNDEKİLER

|  |      |
|--|------|
| İÇİNDEKİLER.....   | i    |
| TEŞEKKÜR .....   | ii   |
| ÖZET .....   | iii  |
| ABSTRACT .....   | iv   |
| SEMBOLLER .....  | v    |
| KISALTMALAR .....  | vi   |
| ŞEKİLLER .....   | vii  |
| TABLO LİSTESİ .....  | viii |
| 1. GİRİŞ .....   | 1    |
| 1.1. Giriş ve Amaç.....  | 1    |
| 1.2. Genel Bilgiler .....  | 3    |
| 1.2.1. KOAH hastalığı ve alevlenme olgusu .....                      | 3    |
| 1.2.2. KOAH süresince kullanılan klinik veriler .....                | 4    |
| 1.2.3. Alevlenmeyi etkileyen faktörler .....                         | 5    |
| 1.2.4. Alevlenmeyi önleme ve tedavi .....                            | 6    |
| 2. MATERYAL VE YÖNTEM .....  | 7    |
| 2.1. Kullanılan Yöntem .....   | 7    |
| 2.2. Veri Setinin Tasarımı ve Karakteristiği.....                    | 7    |
| 2.3. Çıktıların oluşturulması .....                                  | 7    |
| 2.4. Yapay Sinir Ağı Modeli .....                                    | 11   |
| 2.4.1. Performans değerlendirme ölçütleri .....                      | 12   |
| 2.4.2. Tasarlanan yapay sinir ağı modeli .....                       | 14   |
| 2.5. Android Uygulama ile KOAH Hastalarının Verilerinin Takibi ..... | 17   |
| 3. BULGULAR VE TARTIŞMA .....  | 21   |
| 4. SONUÇLAR .....  | 22   |
| 5. KAYNAKLAR.....  | 23   |

## TEŐEKKÜR

Öğrenimim boyunca bilgi, tecrübeleri ile yol gösteren, bana olan inancı ile her türlü manevi desteęi esirgemeyen danışman Sayın Dr. Öğr. Üyesi Hasan Hüseyin ÇELİK hocama,

Dostluęu ve beni cesaretlendirmesiyle her türlü maddi, manevi desteęi esirgememiş Sayın Ahmet Nalbant'a,

Tezim süresince ihtiyacım olan zamanı ve desteęi sağladıkları için HEMA-ADDS Otomotiv ailesine ve İnsan Kaynakları Müdürü Sayın Erdem SOVUKPINAR'a çok teşekkür etmek isterim.

## ÖZET

### YAPAY ZEKA İLE KOAH HASTALARININ DURUM ANALİZİ VE IOT İLE SOLUNUM VERİLERİNİN TAKİBİ

Kronik Obstrüktif Akciğer Hastalığı (KOAH), dünya genelinde giderek yaygınlaşan ve her yıl milyonlarca kişinin ölümüne neden olan tehlikeli bir hastalıktır. Bu yaygınlaşmanın arkasındaki temel faktörler arasında şehirleşme, endüstrileşme, hava kirliliği ve artan tütün kullanımı bulunmaktadır. KOAH hastalığında önemli bir olgu olan alevlenmeler, hastaların prognozunu etkileyerek ciddi sağlık sorunlarına yol açmaktadır. Hastalığın evresi, diğer kronik hastalıklarla ilişkisi, viral enfeksiyonlar, hava kirliliği ve hastanın psikolojik durumu gibi faktörler, alevlenmeleri tetikleyen başlıca etkenlerdir. Bu faktörlerin farklı kombinasyonları nedeniyle alevlenme riskinin kişiselleştirilmiş bir şekilde tahmin edilmesi, hastalığın seyrini kontrol altında tutmak ve ölümcül etkilerini azaltmak açısından büyük bir öneme sahiptir. Bu çalışmada, alevlenmelerin tahmin edilmesi için Yapay Sinir Ağı modeli önerilmektedir. Ağın eğitimi için gerekli veriler, 151 KOAH vakasına ait bilgileri içeren Kore Ulusal Sağlık ve Beslenme İnceleme Araştırması (KNHANES) veri setlerinden elde edilmiştir. Eğitilen yapay sinir ağı modeli, bir ay içindeki alevlenmeleri tahmin etmede 90% başarı göstermiştir. Ayrıca, analiz için gerekli solunum verilerini sağlık sunucularına iletilebilmesi için hastalara ait bilgileri veri depolama alanına aktarabilen bir akıllı telefon uygulaması geliştirilmiştir. Nesnelerin interneti (IoT) teknolojisi kullanan sistemler ile entegre çalışma esnekliğine sahip olan bu tasarım, taşınabilir sağlık, evde sağlık ve akıllı hastane kavramlarına uygun özelliklere sahiptir. Tasarlanan model, bir sonraki ay için alevlenme risk durumunu tespit ederek erken müdahale olanağı sunmaktadır. Hastaların verilerinin uzaktan takibini sağlayan ve risk durumunu analiz eden bu yaklaşım, tedavinin başarısına önemli katkılar sağlamakla birlikte hastane iş yükünü ve sağlık maliyetlerini azaltma potansiyeline de sahiptir.

## **ABSTRACT**

### **ARTIFICIAL INTELLIGENCE-BASED ANALYSIS OF COPD PATIENTS' CONDITION AND MONITORING OF RESPIRATORY DATA WITH IOT**

Chronic Obstructive Pulmonary Disease (COPD) is a perilous condition that is increasingly prevalent worldwide, causing millions of deaths annually. The key factors driving this prevalence include urbanization, industrialization, air pollution, and rising tobacco use. Exacerbations, a significant phenomenon in COPD, lead to serious health complications, affecting the prognosis of patients. Factors such as disease stage, comorbidities, viral infections, air pollution, and the patient's psychological state are major triggers for exacerbations. Personalized prediction of exacerbation risk, considering different combinations of these factors, holds paramount importance in controlling the disease progression and reducing its fatal effects. In this study, we propose Artificial Neural Network model trained to predict exacerbations. The necessary data for training the network were obtained from the Korea National Health and Nutrition Examination Survey (KNHANES) datasets, containing information from 151 COPD cases. The trained artificial neural network model demonstrated 90% success in predicting exacerbations within a month. Additionally, a smartphone application has been developed to transfer patient information to the database, enabling the transmission of respiratory data necessary for analysis to healthcare servers. This design, which integrates with Internet of Things (IoT) technology, offers flexibility in working with systems, aligning with the concepts of portable health, home health, and smart hospitals. The proposed model provides early intervention by detecting exacerbation risk status for the next month. This approach, enabling remote monitoring of patient data and analysis of risk status, not only contributes significantly to treatment success but also has the potential to reduce hospital workload and healthcare costs.

## SEMBOLLER

|                         |                             |
|-------------------------|-----------------------------|
| <b>Z</b>                | : Ağırlıklı giriş           |
| <b>X</b>                | : Giriş                     |
| <b>W</b>                | : Ağırlık matrisi           |
| <b>b</b>                | : Bias, sapma vektörü       |
| <b>n</b>                | : Gözlem sayısı             |
| <b>L(x)</b>             | : Kayıp fonksiyonu          |
| <b>y</b>                | : Gerçek çıkış              |
| <b>y<sup>ort</sup></b>  | : Gerçek çıkışın ortalaması |
| <b>y'</b>               | : Ağın tahmini              |
| <b>y'<sup>ort</sup></b> | : Ağın tahmin ortalaması    |
| <b>A</b>                | : Katman çıkışı             |
| <b>E</b>                | : Hata                      |
| <b>δ</b>                | : Hata gradient, delta      |

## KISALTMALAR

|                |   |
|----------------|---|
| <b>CAT</b>     | : COPD Assessment Test  |
| <b>CCQ</b>     | : Clinical COPD Questionnaire                                   |
| <b>CERP</b>    | : COPD Exacerbation Risk Prediction tool                        |
| <b>EKG</b>     | : Elektrokardiyografi   |
| <b>EQ5D</b>    | : EuroQOL Five Dimension Questionnaire                          |
| <b>FEV1</b>    | : Zorlu Ekspiratuvar Hacim 1. saniye                            |
| <b>FEV1p</b>   | : FEV1'in Normal Beklenene Göre Yüzdesi                         |
| <b>FEVC</b>    | : Zorlu Ekspiratuvar Hacim                                      |
| <b>GOLD</b>    | : Global Initiative for Chronic Obstructive Lung Disease        |
| <b>ICS</b>     | : İnhale Kortikosteroid- Budezonid                              |
| <b>IoT</b>     | : Nesnelerin İnterneti  |
| <b>KNHANES</b> | : Kore Ulusal Sağlık ve Beslenme İnceleme Araştırması           |
| <b>KOAH</b>    | : Kronik Obstrüktif Akciğer Hastalığı                           |
| <b>LAMA</b>    | : Muskarinik Antagonistler                                      |
| <b>LABA</b>    | : Uzun Etkili Beta2-Agonistler                                  |
| <b>MAE</b>     | : Ortalama Mutlak Hata  |
| <b>MSE</b>     | : Ortalama Kare Hata  |
| <b>mMRC</b>    | : Modifiye Edilmiş Tıbbi Araştırma Konseyi Nefes Darlığı Ölçeği |
| <b>R</b>       | : Korelasyon Katsayısı  |
| <b>RMSE</b>    | : Karekök Ortalama Hata   |
| <b>VKİ</b>     | : Vücut Kütle İndeksi   |
| <b>YSA</b>     | : Yapay Sinir Ağları  |

## ŞEKİLLER

|  |    |
|--|----|
| Şekil 1.1. ABCD Değerlendirme aracının gösterimi.....  | 5  |
| Şekil 2.1. Yapay Sinir Ağı yapısı.....   | 12 |
| Şekil 2.2. Tasarlanan YSA modelinin yapısı. ....   | 14 |
| Şekil 2.3. Eğitim, test, doğrulama için her çevrimdeki MSE ve en iyi değer. ....                                 | 15 |
| Şekil 2.4. Eğitim, test, doğrulama ve tüm ağ için R performans sonuçları.....                                    | 16 |
| Şekil 2.5. CERP uygulamasının bilgi girilmesi için geliştirilen arayüzü.....                                     | 18 |
| Şekil 2.6. Kullanıcının geçmişe dönük doldurduğu formları düzenlemesi ve yenisini eklemesini sağlayan sekme..... | 18 |
| Şekil 2.7. Danışman dönüşlerine ulaşılabilen sekme .....   | 19 |
| Şekil 2.8. Danışmanın hasta ile paylaştığı bilgilerin görüntülediği sekme .....                                  | 20 |
| Şekil 2.9. Hastanın program hakkında geri bildirim yapmasını sağlayan sekme.....                                 | 20 |
| Şekil 3.1. Altı farklı çalışma ve tez çalışmasının sonuçlarının doğrulukları.....                                | 21 |
| Şekil 3.2. Oluşturulan sistemin genel yapısı .....   | 22 |

## TABLO LİSTESİ

|   |    |
|---|----|
| <b>Tablo 1.1.</b> FEV1/FEVc<70 olan hastalar için hava akım kısıtlaması sınıflandırması.....  | 4  |
| <b>Tablo 2.1.</b> Seçilen özellikler, etki sabitlerini belirlerken kullanılan kriterler ve özelliklerin ait oldukları gruplar ..... | 9  |
| <b>Tablo 2.2.</b> Ağın performansı .....  | 15 |



# 1. GİRİŞ

## 1.1. Giriş ve Amaç

Dünya genelinde en çok ölüme neden olan üçüncü hastalık KOAH'dır. Yalnızca 2019 yılında KOAH'a atfedilen ölüm sayısının 3.23 milyona ulaştığı tahmin edilmektedir (World Health Organization, 2023). Özellikle hava kirliliğinin yoğun ve tütün kullanımının yaygın olduğu düşük ve orta gelirli ülkelerde görülen KOAH, önemli bir küresel sağlık sorunudur (Global Initiative for Chronic Obstructive Lung Disease, 2023).

KOAH, alevlenmelerle karakterizedir; alevlenme sırasında hastalarda olağan semptomlarda artış ve şiddetlenme görülmektedir. Alevlenmelerin şiddetine bağlı olarak, bu süreç hastanın sağlığına olumsuz etki etmektedir (Bingöl & Çağatay, 2016). Ayrıca önemli finansal yüklerle (Mannino vd., 2023) (Bollmeier ve Hartmann, 2020), sağlık kuruluşlarında ve acil servislerde yoğunluğa neden olmaktadır. Bu nedenle, hastalar için hastalığın seyri boyunca alevlenmelerin kontrolü ve tahmin edilmesi son derece önemlidir. Alevlenme tahmini ve hasta doktor iletişimini geliştirme konusunda IoT teknolojileri ve yapay zeka büyük potansiyel taşımaktadır.

IoT ve iletişim teknolojilerinin ilerlemesiyle birlikte evde sağlık hizmetleri, akıllı hastaneler, taşınabilir sağlık hizmetleri gibi trend kavramlara odaklanan çalışmalar hız kazanmıştır (Rejeb vd., 2023). Bu trend konseptler çerçevesinde KOAH 'a yönelik birçok çalışma yapılmıştır.

Tomasic vd. (2018), KOAH hasta verilerinin uzaktan izlenmesi, veri toplanması, belirleyici faktörler, kullanılan sensörler, cihazlar ve konu paralelinde diğer olgulardan çalışmasında bahsetmiştir. Bu doğrultuda evden sağlık, akıllı hastane, giyilebilir sağlık ürünü konseptleri için IoT, yapay zeka ve telekomünikasyon/iletişim teknolojilerinin gelişmesiyle oluşacak faydalarına yönelik araç ve yöntem sunmuştur.

Sağlık sektöründeki konuya ilginin ve yapılan çalışma sayısındaki artışın paralellik gösterdiği görülmektedir. Bahsedilen bu yenilikçi konseptlerle tümleşik çalışabilen sistem ve uygulamalar, sektörün beklentilerine paralel olması, hasta ile doktor arasındaki iletişime kolaylıklar sağlaması sebebiyle KOAH alevlenme sürecinin kontrolünde de etkin rol oynayabilme potansiyeline sahiptir.

Yapay zeka teknolojisinin gelişmesi, sağlık alanındaki uygulamalara ve çalışmalara da önemli ölçüde yansımaktadır. KOAH tanısı, hastalığın kontrol altında tutulması, şiddeti ve alevlenme tahmini üzerine yapay zeka kullanılarak bir çok çalışma yapılmıştır.

Singh vd. (2022), KOAH hastalarında alevlenme faktörlerini ve alevlenme şiddetlerini tahmin etmek için, makine öğrenimi ve istatistiksel yöntemleri kullanan bir model önermiştir. Çalışma, Gradient boosting, Generalized Linear Model Trees, GUIDE ve Elastic Nest algoritmaları ile yapılmıştır. Çalışma sonucunda alevlenme tahmini başarısı pozitif prediktif değer için %48, negatif prediktif değer için ise %80 olduğu belirtilmiştir.

Zeng vd. (2022), şiddetli KOAH alevlenmelerini tahmin etmek için XGBoost algoritması temelli bir model önermiştir. Önerilen makine öğrenme modelinin şiddetli alevlenmeleri %90'ı aşan doğrulukla tahmin ettiği belirtilmiştir.

Fernández-Granero vd. (2018), alevlenmeleri semptomlar ile tahmin edebilmek için karar ağacı ormanı temelli bir yaklaşım öne sürmüştür. Hastaların solunum seslerini içeren bir veri seti kullanılmış ve alevlenme başlamadan 6 gün öncesine kadar 87.5% başarı ile alevlenme tahmini yapmıştır.

Zarrin vd. (2020), tükürük örnekleri içeren iki veri seti kullanarak XGBoost, Gaussian Naive Bayes, Destek Vektör Makinesi ve Lojistik Regresyon makina öğrenmesi algoritmaları için performans kıyaslaması yapmıştır. Modellerin, 93.33% ve 73.75% arası değişen doğruluk ile başarı gösterdiği belirtilmiştir.

Fernández-Granero vd. (2014), alevlenmeyi tahmin etmek için olasılıksal sinir ağı modeli kullanmıştır. Hastalardan verilerin toplanması için ses ve dokunma destekli özelleştirilmiş cihaz kullanılmıştır. 80.5% alevlenme tahmin başarısı elde edildiği belirtilmiştir.

Wang vd. (2023), KOAH hastası bireyler için bir risk tahmin modeli oluşturmak amacı ile, Lojistik Regresyon, destek vektör makinesi, rastgele orman, XGBoost, Light Gradient Boosting Machine, Natural Gradient Boosting ve yığma makina öğrenmesi algoritmalarını kullanarak algoritmaların performans kıyaslamasını yapmıştır. Risk tahmin modelinde en yüksek performansı 0.805 ile XGBoost algoritmasının gösterdiği kaydedilmiştir.

Bu tezde KOAH alevlenmelerini öngörme ve uzaktan hasta takibini kolaylaştırmayı amaçlayan yapay zeka tabanlı bir sistem geliştirilmiştir. Sistemde alevlenme tahmini, Yapay Sinir Ağı (YSA) kullanılarak gerçekleştirilmiştir. YSA eğitim aşamasında, genel sağlık anketi KNHANES (Korea Disease Control and Prevention Agency, 2010-2015) veri setlerinden çıkartılmış bir veri seti kullanılmıştır. YSA ile üretilen sonuçların bir sağlık merkezine ya da sağlık danışmanına aktarılması ve sağlık danışmanının hasta ile aktif iletişimini sağlamak amacıyla ayrıca bir akıllı telefon uygulaması geliştirilmiştir. Bu uygulama hasta ile sağlık kurumu veya danışmanı arasındaki sürekli iletişimi çevrim içi olarak sağlamaktadır. Bu durum özellikle alevlenmeye doğru giden kritik durumların öngörülmesi açısından önem taşımaktadır. Elde edilen sonuçlar yöntemin başarılı bir şekilde uygulanabildiğini göstermektedir. Önerilen sistem akıllı sağlık hizmetleri ve uzaktan hasta takibi alanlarında gelişmiş ülkelerde görülen güncel uygulamalara paralel bir yaklaşım özelliği göstermektedir.

## **1.2. Genel Bilgiler**

### **1.2.1. KOAH hastalığı ve alevlenme olgusu**

KOAH, genellikle sigara içimi ile ilişkilendirilen, hava yollarında ve akciğerlerde uzun süreli iltihaplanma sonucu gelişen, nefes darlığı, öksürük, balgam üretimi ve zaman zaman alevlenmelerle karakterize edilen bir sağlık sorunudur. KOAH, hava yollarının daralması ve akciğer dokusunun zarar görmesi nedeniyle solunumun zorlaşması ile kendini gösterir. Hastalığın ilerleyici bir seyri vardır ve zamanla solunum yetmezliğine yol açabilir. KOAH, yaşam kalitesini önemli ölçüde etkiler ve ciddi durumlarda yaşamı tehdit edebilir. Sigara içimi, hava kirliliği, maruz kalınan tozlar gibi çevresel faktörler ve genetik yatkınlık KOAH'ın gelişiminde rol oynar. Tedavide sigara bırakma, ilaçlar, solunum egzersizleri ve bazen oksijen tedavisi gibi yöntemler kullanılır. Erken teşhis ve uygun tedavi ile hastalığın ilerlemesi kontrol altına alınabilmektedir (Global Initiative for Chronic Obstructive Lung Disease, 2024).

KOAH hastalığının en önemli olgularından biri alevlenmedir. Alevlenme olgusu hastalığın seyrine ek çeşitli faktörlere bağlı olarak öksürük, balgam şiddeti ve yoğunluğuda artış, nefes darlığı, uyumada zorluk, hırıltılı ve gürültülü nefes alma, aşırı yorgunluk belirtilerinin ağırlaşması bütünü olarak ifade edilmektedir (American Lung

Association, 2023). Alevlenme sürecini kritik yapan durum, alevlenme geçmişi ve şiddetinin prognoza etkisidir, hastaneye yatış gerektiren alevlenme öykülerinin prognoza ciddi etkileri olduğu gözlemlenmiştir (Çolak vd., 2019). Alevlenme süresince akciğer fonksiyonlarında hızlı kayıplar yaşanmaktadır bu durum yaşam kalitesinde bozulmaya, hastalığın şiddetinin artmasına, hastaneye kaldırılma ve ölüm riskine sebep olmaktadır.

Alevlenme enfeksiyöz sebeplerden veya hava kirliliği, sigara kullanımı, göğüs travmaları, sağ ve/veya sol kalp yetmezliği, plörezi, pnömotoraks, metabolik asidoz, pulmoner tromboemboli, aritmiler, uyuşturucu kullanımı ve benzeri sebeplerle ortaya çıkabilmektedir (Soner & Karakurt, t.y.).

### 1.2.2. KOAH süresince kullanılan klinik veriler

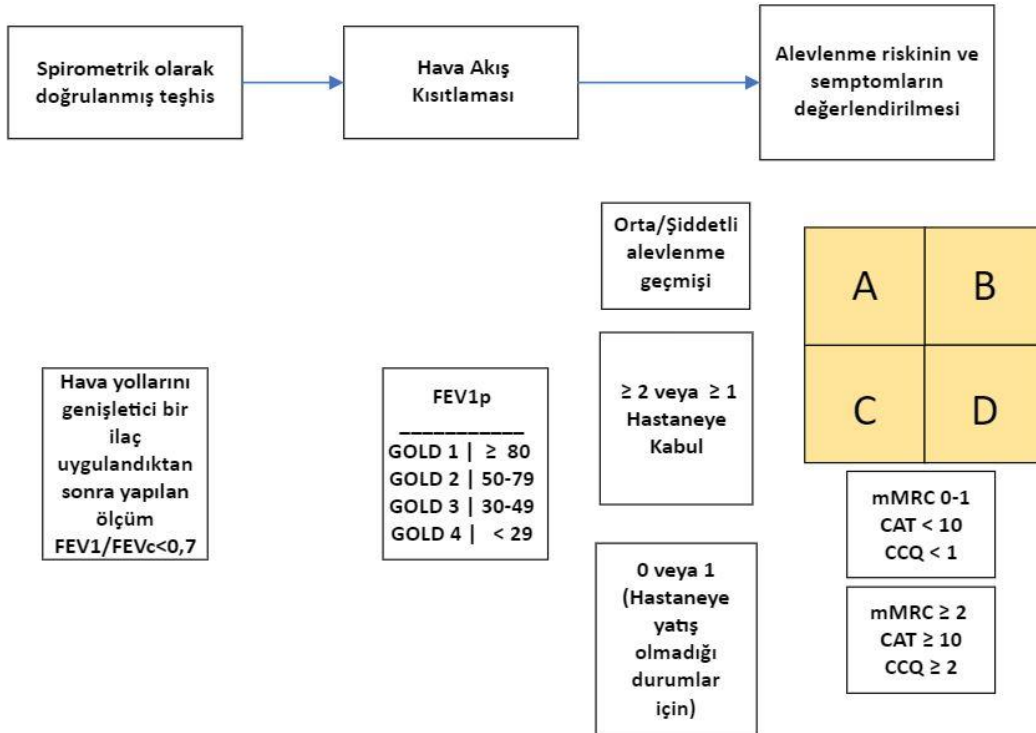
Bahsedilen belirtiler haricinde klinik olarak yapılan solunum testleri ile de KOAH teşhis edilebilir. Ayrıca teşhisin ötesinde KOAH şiddeti, alevlenme olgusu ve prognoza yönelik birçok değerlendirmede solunum verilerinden faydalanılmaktadır. KOAH tanı ve teşhis sürecinde bahsedilen klinik belirtiler bağlamında spirometreden alınan 1 saniyede zorla ekspiratuvar hacim (FEV1), zorlu ekspiratuvar hacim kapasitesi (FEVC), FEV1/FEVC ve FEV1'in normal beklenene göre yüzdesi (FEV1p) gibi solunum verileri büyük önem taşımaktadır. FEV1, FEV1p ve FEV1/FEVC değerlerine göre Global Initiative for Chronic Obstructive Lung Disease (GOLD) 'un oluşturduğu hava akımı kısıtlaması kategorizasyonu Tablo 1.1. 'de verilmiştir. FEV1p değeri, klinik belirtiler bağlamında diğer ölçüm değerleri ile birlikte değerlendirilmektedir (Global Initiative for Chronic Obstructive Lung Disease, 2024).

**Tablo 1.1.** FEV1/FEVc<70 olan hastalar için hava akım kısıtlaması sınıflandırması.

| Durum  | Şiddet | Kriter                     |
|--------|--------|----------------------------|
| GOLD 1 | Hafif  | FEV1p > 80% (tahmin)       |
| GOLD 2 | Orta   | 50% ≤ FEV1p ≤ 80% (tahmin) |

|        |              |                                      |
|--------|--------------|--------------------------------------|
| GOLD 3 | Şiddetli     | $30\% \leq FEV1p \leq 50\%$ (tahmin) |
| GOLD 4 | Çok Şiddetli | $FEV1p < 30\%$ (tahmin)              |

KOAH hastalığının şiddetinin tespiti, hastalığın seyrinin kontrol altında tutulması için gerekli ve önemli bir kriterdir. Bu doğrultuda Tablo 1.1. 'de verilen değerlendirilme kriterine ek olarak KOAH Değerlendirme Testi (CAT), Modifiye Edilmiş Tıbbi Araştırma Konseyi Nefes Darlığı Ölçeği (mMRC) skalası ve Klinik KOAH Anketi Puanlaması (CCQ) da kullanılır. Alevlenme riskinin ve semptomların değerlendirilmesi için bu veriler ABCD değerlendirme aracında değerlendirilir. Değerlendirilen kriterler; spirometrik onaylı teşhis, hava yolu kısıtlaması değerlendirilmesi, FEV1/FEVC, son bir senedeki alevlenme geçmişi ve şiddeti, mMRC ve CAT değerleridir. ABCD değerlendirme aracı Şekil 1.1. 'de görselleştirilmiştir. Araca göre puan verilmekte ve sınıflandırılma yapılmaktadır.



Şekil 1.1. ABCD Değerlendirme aracının gösterimi

### 1.2.3. Alevlenmeyi etkileyen faktörler

Alevlenmenin ciddiyetine bağlı olarak hastanın sağlığı önemli ölçüde etkilenir.

Hastalığın seyrini ve alevlenmeyi etkileyen birçok faktör vardır. Sigara içmenin hem KOAH oluşumunda hem de gelişiminde önemli bir faktör olduğu ve akut alevlenmeler ile doğrudan korelasyonu olduğu bilinmektedir (Wang vd., 2022). Kukrety vd. (2018) yaşlanmanın KOAH hastaları üzerindeki etkilerini gösteren çalışmalar yapmıştır. Shukla vd. (2021), cinsiyet ile KOAH arasındaki ilişkiyi incelemiş, kadın hastaların çeşitli sebeplerle KOAH'a daha yatkın olabileceğini tartışmıştır. Rahi vd. (2023), anksiyete ve depresyonu olan hastalarda akut alevlenmelerin daha sık olduğunu belirtmiştir. Putcha vd. (2022), obez KOAH hastalarında daha yüksek bir mortalite oranı olduğunu göstermiş ayrıca Christensen vd. (2022) çalışmasında kilo kaybının KOAH hastaları için tehlikelerini göstermiştir. Vogelmeier vd. (2021) alevlenmelerin geçmişinin sonraki akut alevlenmelerle ilişkili olduğu ve sonraki alevlenmeleri etkilediğini belirtmiştir. Yaşam koşullarındaki olumsuzlukların da hastalığın alevlenme sürecine etkisi vardır (Donaldson vd., 2015), yaşam kalitesini yansıtan EuroQol- 5 Dimension (EQ5D) indeksi bu sebeple alevlenme için etkin bir gösterge olarak değerlendirilebilir. Komorbiditenin KOAH alevlenmesi ve seyri üzerindeki olumsuz etkisi olduğu da bilinmektedir (Westerik ve diğerleri, 2017).

#### **1.2.4. Alevlenmeyi önleme ve tedavi**

Alevlenmenin şiddetine göre tedavi yöntemleri de değişiklik göstermektedir. Hafif alevlenmeler evde tedavi edilebilmektedir, oksijen saturasyonu ve varsa serum ilaç karışımları önerilmektedir. Orta yani klinikte ve şiddetli yani yoğun bakım tedavilerinde oksijen saturasyonu, artiyel kan gazı, akciğer grafisi, kan testleri, serum ilaç karışımları, balgam gram boyama ve kültür ve Elektrokardiyografi (EKG) istenmektedir. Orta ve şiddetli alevlenmelerde ise hasta durumuna göre farklı antibiyotikler, inhaler ve diğer çözümlere başvurulmaktadır.

Agusti vd. (2014) alevlenmeyi önleme ve tedavi için atılabilecek adımları incelemişlerdir. Bu metotlar; farmakolojik olmayan, farmakolojik ve sistematik şeklinde sıralanmaktadır. Farmakolojik olmayan yöntemler; sigarayı bırakma, akciğer rehabilitasyonu ve aşı ile korunma olarak, farmakoterapi uzun etkili beta2-agonistler (LABA), uzun etkili muskarinik antagonistler (LAMA), LAMA ve LABA kombinasyonları, İn hale kortikosteroid- budezonid (ICS) ve LABA kombinasyonları, üçlü terapi olarak ve sistematik tedavide rofliminast, makrolidler ve kinolonlar, statinler

olarak belirtilmiştir.

## **2. MATERYAL VE YÖNTEM**

### **2.1. Kullanılan Yöntem**

Tez çalışmasında önerilen yapay zeka yaklaşımı için yapay sinir ağı modeli tasarlanmıştır. Eğitim için KNHANES veri setlerinden çıkarılmış bir veri seti kullanılmıştır. Android uygulama AppSheet ile tasarlanmış ve veri depolamak için Google Sheets kullanılmıştır.

### **2.2. Veri Setinin Tasarımı ve Karakteristiği**

KNHANES veri seti, Kore Hastalık Kontrol ve Önleme Ajansı tarafından yapılan beslenme, gelir durumu, yaşam tarzı ve genel sağlık alanlarına yönelik kapsamlı bir ankettir. Veri seti, gelir, sağlık, meslek durumlarına bakılmaksızın katılımcı olmayı kabul eden rastgele kişilerin katılımları ile oluşturulmuştur. 2010-2015 yıllarına ait altı KNHANES veri setinde, 48.000 kişiye ait 747 değerlendirme sorusu kullanılarak toplanmış veriler bulunmaktadır. Bu veriler incelenerek 48.000 katılımcı arasından KOAH hastası olan katılımcılar seçildi. KOAH alevlenmesi ilişkili değerlendirme soruları yani özellikler ve oluşturulan veri seti için uygun olan hastalar seçilerek, alevlenme öngörüsü yapmaya yönelik bir veri seti oluşturuldu. Bu aşamada, benzer durumda ve verileri eksik olan hasta örnekleri çıkartıldı ve veri seti yeniden düzenlendi. Ayrıca veri setinde yer alan metin tanımlı özellikler de sayısal verilere dönüştürüldü. Örneğin veri setinde bulunan cinsiyet özelliği, erkek için 1, kadın için 2 olarak tanımlandı. Sonuç olarak bu çalışmaya özgü 151 KOAH hastasına ait 25 özellik içeren anlamlı bir veri seti oluşturuldu.

### **2.3. Çıktıların oluşturulması**

Veri setinde kullanılan özellikler göz önüne alındığında anketin yapıldığı tarihe göre; anket tarihindeki belirleyici solunum değerlerinin ölçüm sonuçları, önceki iki haftaya dönük depresyon belirtisi, geçen üç aydaki balgam ve öksürük öyküsü, bir önceki ay hasta geçirilen gün sayısı ve diğer özellikler hastanın bir sonraki ay içerisinde alevlenme

tahmini yapılmasına olanak tanımaktadır. Bu husustaki belirleme alevlenme belirtilerine yönelik literatür taraması ve bir sağlık uzmanından alınan bilgiler doğrultusunda yapılmıştır.

Uzmandan alınan bilgiler ve değerlendirmeler ile literatür taraması sonucu tüm özelliklere önem derecesine göre etki sabitleri verilmiştir. Etki sabitleri, sonraki aydaki alevlenmeye etkisine göre; I, II ve III olarak belirli gruplara ayrılmıştır. I. grup etkili, II. daha etkili ve III. grup yüksek etkili olarak kategorize edilmiştir. Her gruptaki özellik etkisine göre ayrıca değerlendirilmiş, etki sabitleri değerlendirme sonucuna göre belirlenmiştir.

Yaşlanmanın akut alevlenmeye etkisi nedeniyle, yaşlı kabul edilen 65 yaş üstü hastalar için 5, 65 yaş altı hastalar için 0 etki sabiti verilmiştir. Cinsiyet ve alevlenme ilişkisi ile ilgili birçok çalışma yapılmıştır fakat bu çalışmalar sigara bağımlılığı, yaşam kalitesi ve diğer faktörlerin oluşumundaki yatkınlığı irdelemektedir. Yaşam tarzı faktörü göz önüne alınarak literatürde yer alan bilgiler doğrultusunda kadınlar için 0.5 ve erkekler için 0 etki faktörü kullanılmıştır. Dislipidemi hastalığının alevlenmeye direkt etkisi incelenerek etki sabiti 1 seçilmiştir. Yüksek tansiyon için etki sabiti 7 seçilmiştir. Felç hastalığının yaşam kalitesine etkisi ve olası felç öyküleri göz önünde tutularak 7 etki sabiti verilmiştir. Miyokard enfarktüsü ve anjina pectoris gibi kalp damar tıkanıklığı hastalıklarına 8 etki sabiti verilmiştir. Nefes kısıtlaması hastalıkları astım ve tüberküloza 11 etki sabiti verilmiştir. Şeker hastalığının alevlenmeye sürecinde dolaylı olarak yani komorbiditelere etkisi olduğu için 2 etki sabiti verilmiştir. Akciğer kanserinin hastalığın sürecine ve alevlenmeye etkisi sebebi ile 17 etki sabiti verilmiştir. Solunum kısıtlamasının artması dolayısı ile KOAH hastalarında görülen depresyon tanısına etki sabiti 6, son iki haftadır depresyonda hissetme durumuna 5 etki sabiti verilmiştir. Sigara bağımlılık seviyelerine göre; hiç sigara içmeyen hastalar için 0, orta seviye bağımlılık için 12 ve yüksek bağımlılık için 17 etki sabiti verilmiştir. EQ5D indeksinde yaşam kalitesi 0 ile 1 aralığında değerlendirilmektedir, 1 en iyi skordur. Bu doğrultuda 1'e tümleyen değer etki sabiti olarak kabul edilmiştir. Vücut Kütle İndeksi (VKİ) 18 'e eşit veya az olan kişiler zayıf, 35'e ve fazlası olan kişiler obez kabul edilmektedir. Obez ve zayıf kişiler için etki sabiti 4, normal kilodaki hastalar için 0 belirlenmiştir. Son bir yıldaki kilo kaybı parametresi için, kilo kaybı yoksa 0, 3-6 kg arası ise 1, 6 kg'dan fazla kilo kaybı var ise etki sabiti 2 olarak tanımlanmıştır. FEV1/FEVC değeri 0.7 'den düşük

olan hastalar için etki sabiti 35 olarak belirlenmiştir. FEV1p parametresi Tablo 1.1. 'de gösterilen GOLD 'un hava akımı kısıtlama tablosuna göre belirlenmiştir. Buna göre FEV1p için etki sabiti 80'den büyük veya eşit ise 0, 80 ile 50 arasında ise 20, 50 ile 30 arasında ise 25 ve 30'dan küçük ise 30 olarak belirlenmiştir. Üç aydan fazla balgam ve üç aydan fazla öksürük öyküsüne sahip hastalar için etki sabiti 4 verilmiştir. Alevlenme öyküsüne sahip hastalar ve alevlenme kaynaklı hastaneye yatış öyküsüne sahip olanlar için etki sabiti 25 verilmiştir. Önceki ay solunum yolları hastalıkları sebebi ile hasta geçirilen gün sayısı için etki sabiti hasta gün sayısına eşit seçilmiştir. Bu etki sabitleri her hasta için toplanarak risk puanı belirlenmiştir. Tablo 2.1' de seçilen özellikler, etki sabitlerini belirlerken kullanılan kriterler ve özelliklerin gruplandırılmaları görülmektedir. Bu şekilde bir sonraki aya yönelik alevlenme risk oranları oluşturulmuştur.

**Tablo 2.1.** Seçilen özellikler, etki sabitlerini belirlerken kullanılan kriterler ve özelliklerin ait oldukları gruplar

| Özellik                      | Etki Sabiti Belirleme Kriteri   | Grup     |
|------------------------------|---|----------|
| •Dislipidemi                 | Dislipidemi tanısı var ise 1, yok ise 0   | I. Grup  |
| •Şeker Hastalığı             | Şeker hastalığı var ise 2, yok ise 0  | I. Grup  |
| •EQ5D Hayat Kalitesi İndeksi | EQ5D indeksinin 1'e tümleyen değerinin 10 katı  | I. Grup  |
| •1 yıldaki kilo kaybı        | Kilo kaybı yok ise 0, 3-6kg arası kilo kaybı var ise 1, 6 kilodan fazla kayıp var ise 2 | I. Grup  |
| •Vücut Kütle indeksi         | VKİ değeri 18'den küçük veya 35'ten büyük ise 4 değil ise 0                             | I. Grup  |
| •3 aydan fazla öksürük       | 3 aydan fazla öksürük var ise 4, yok ise 0  | I. Grup  |
| •3 aydan fazla balgam        | 3 aydan fazla balgam var ise 4, yok ise 0   | I. Grup  |
| •Cinsiyet                    | Erkek için 0, kadın için 0,5  | I. Grup  |
| •Yüksek Tansiyon             | Yüksek Tansiyon hastası ise 7, değil ise 0  | II. Grup |
| •Felç                        | Hasta felçli ise 7, değil ise 0   | II. Grup |
| •Miyokard Enfarktüsü         | Miyokard Enfarktüsü tanısı var ise 8, yok ise 0   | II. Grup |
| •Anjina Pektoris             | Anjina Pektoris tanısı var ise 8, yok ise 0   | II. Grup |

|                   |  |          |
|-------------------|--|----------|
| •Tüberküloz       | Tüberküloz hastalığı var ise 11, yok ise 0 | II. Grup |
| •Astım            | Astım hastalığı var ise 11, yok ise 0      | II. Grup |
| •Depresyon Tanısı | Depresyon tanısı var ise 6, yok ise 0      | II. Grup |

**Tablo 2.1.** devam

| Özellik                             | Etki Sabiti Belirleme Kriteri  | Grup      |
|-------------------------------------|--|-----------|
| •Yaş                                | Hasta 65 yaşından büyük ise 5, değil ise 0   | II. Grup  |
| •Akciğer Kanseri                    | Hasta Akciğer kanseri ise 17, değil ise 0  | III. Grup |
| •Sigara bağımlılık derecesi         | Hasta sigara içmiyor ise 0, orta seviye bağımlı ise 12, aşırı bağımlı ise 17                   | III. Grup |
| •FEV1p                              | FEV1p değeri 80'e eşit veya büyük ise 0, 80-50 arası 20, 50-30 arası 25 ve 30'dan küçük ise 30 | III. Grup |
| •FEV1/FEVC                          | FEV1/FEVC değeri 0.7'den küçük ise 35, küçük değil ise 0                                       | III. Grup |
| •Alevlenme geçmişi                  | Alevlenme geçmişi var ise 25, yok ise 0  | III. Grup |
| •Alevlenme kaynaklı hastaneye yatış | Alevlenme kaynaklı hastaneye yatış geçmişi var ise 25 yok ise 0                                | III. Grup |
| •Geçen ay hasta gün sayısı.         | Solunum yolları hastalıkları sebebiyle geçen ay hasta geçen gün sayısı alınır.                 | III. Grup |

Özellikler arasında bulunan FEV1 değeri FEV1/FEVC ve FEV1p değerlerini hesaplamada kullanıldığı için ayrıca etki sabiti verilmemiştir.

Risk puanlarına göre sonuçlar üç ayrı kademe olarak değerlendirilmiştir. 0-47 arası değerler birinci kademe, 48-91 arası ikinci kademe, 92 ve üstü üçüncü kademeye olarak belirlenmiştir. Burada birinci kademe düşük riskli hasta grubunu ifade etmektedir. Bu grubun sonraki ay içerisinde alevlenme riski yoktur veya düşüktür. İkinci kademe, alevlenme riski taşıyan, uzmanlara başvurarak gerekli önlemlerin alınması gereken risk grubudur. Üçüncü kademe ise yüksek riskli ve sonraki ay içerisinde alevlenme ihtimali yüksek ve acil olarak sağlık kuruluşuna müracaat etmesi gereken gruptur.

## 2.4. Yapay Sinir Ağı Modeli

YSA beynin nöron yapısından esinlenerek tasarlanmış yapay zeka sistemlerdir. Yapay nöronlar bir önceki katmandan gelen girişleri alır ve rastgele ağırlık değerine tabi tutar ve sapma değeri yani bias eklenir bu değer ağın performansını arttırmak için kullanılan bir parametredir, ardından aktivasyon fonksiyonlarına tabi tutularak bir çıkış üretilir. Aktivasyon fonksiyonu çıktının lineer olmamasını sağlamaktadır. Temel olarak giriş katmanı, gizli katman ve çıkış katmanlarından oluşan bir yapıya sahiptir. Giriş katmanı verilen girdileri alır, gizli katmanda ise problemle ilgili desenleri ve temsilleri öğrenir, çıkış katmanında ise sonuç üretilir. Ağ, nöronlar arasındaki ağırlıkları değiştirerek, veriye uyum sağlar (Kabbay, 2022). İleri yayılıma ait denklem Denklem (2.1.)'de gösterilmiştir.

$$Z_n = X_n * W_n + b_n \quad (2.1.)$$

**Z:** Katmanın ağırlıklı girişi, **X:** Giriş, **W:** Ağırlık matrisi, **b:** Bias, sapma vektörü, **n:** gözlem sayısı

Öğrenme sürecinde bir diğer önemli kavram ise geri yayılımdır. Ağın ileri yayılımından sonra ağ geriye doğru yayılarak ağırlık ve sapma parametrelerine optimizasyon yapar. Bu algoritma, ağın hatasını değerlendirir. Ağın çıkışındaki tahminle gerçek değer arasındaki farkı minimize etmek için kullanılır. Denklem (2.2.) Hata fonksiyonu gösterilmiştir, Denklem (2.3.)'de ise geri yayılım algoritmasında sapma ve ağırlık değerlerinin güncellemesi için kullanılan denklem gösterilmiştir.


$$\text{Hata}(E) = L(y_n, A_n) \quad (2.2.)$$

**L(x):** Kayıp fonksiyonu, **y:** Gerçek çıkış, **A:** Katman çıkışı, **E:** hata

$$\frac{\partial E}{\partial Z_n} = \frac{\partial E}{\partial A_n} + \frac{\partial A_n}{\partial Z_n} \quad , \quad \frac{\partial E}{\partial W_n} = A_{n-1}^T * \delta_n \quad , \quad \frac{\partial E}{\partial b_n} = \sum \frac{\partial A_n}{\partial Z_n} \quad (2.3.)$$

**$\delta$ :** Katmandaki hata gradient

Şekil 2.1. 'de giriş katmanı, üç gizli katman ve çıkış katmanına sahip yapay sinir ağı modeli görülmektedir.



Şekil 2.1. Yapay Sinir Ağı yapısı

#### 2.4.1. Performans değerlendirme ölçütleri

Ağın başarısını görmek için çeşitli matematiksel performans değerlendirme ölçekleri kullanılmaktadır. Gerçek çıktı ile ağın oluşturduğu çıktı arasında gerçekleşen hatayı ve korelasyonu anlamak ve yorumlamak için bu ölçütlere ihtiyaç vardır.

Ortalama mutlak hata (MAE), gerçek değerlerle tahmin edilen değerler arasındaki farkların mutlak değerlerinin ortalamasını ölçer. Her bir veri noktasının hata katkısı birbirinden bağımsızdır. MAE'deki değişiklikler lineerdir ve bu nedenle sezgiseldir yani MAE'de farklı hatalar daha fazla veya daha az ağırlıklandırılmaz, skor hataların artmasıyla lineer olarak artar. MAE puanı, mutlak hata değerlerinin ortalaması olarak ölçülür. Denklem (2.4.) 'de MAE'nin formülü gösterilmektedir.

$$MAE = \frac{1}{n} * \sum_{i=1}^n |y_i - y'_i|$$

(2.4.)

$y'$ : Ağın tahmini

Ortalama kare hata (MSE), hataların karelerinin ortalaması ile hesaplanmaktadır. MSE, hataların karelerini alarak daha fazla cezalandırmaktadır, bu, değerlendirmede bir avantaj olarak kabul edilebilir. Fakat bu özellik dolayısı ile aykırı değerler modelin performansını fazla etkilemektedir. Denklem (2.6.) 'da MSE'nin formülü gösterilmektedir.

$$MSE = \frac{1}{n} * \sum_{i=1}^n (y_i - y'_i)^2$$

(2.5.)

Karekök ortalama kare hata (RMSE), hataların karelerinin ortalamasının karekökü alınarak elde edilir. Bu metrik, MSE'de olduğu gibi büyük hatalara daha fazla ağırlık verir. Denklem (2.7.) 'de RMSE'nin formülü gösterilmektedir.

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - y'_i)^2}$$

(2.6.)

Korelasyon (R) iki değişken arasındaki ilişkiyi ölçen bir istatistiksel ölçüdür. Korelasyon sonucu oluşan değer -1 ile 1 arasındadır. R=1, iki değişken arasında tam doğrusal bir ilişki olduğunu ifade eder, R=-1, iki değer arasında ters orantılı bir ilişki olduğunu ifade eder, R=0 ise, iki değer arasında doğrusal bir ilişki olmadığı anlamına gelmektedir. Denklem (2.8.)'de R formülü gösterilmektedir.

$$R = \frac{\sum_{i=1}^n (y_i - y_i^{ort}) * (y'_i - y_i'^{ort})}{\sqrt{\sum_{i=1}^n (y_i - y_i^{ort})^2 * \sum_{i=1}^n (y'_i - y_i'^{ort})^2}}$$

(2.7.)

$y_i'^{ort}$ : Ağın tahmininin ortalaması,  $y_i^{ort}$ :Gerçek çıkışın ortalaması

R-kare, bağımsız değişkenlerin bağımlı değişken üzerindeki toplam varyans içindeki oranını ifade eder. Yani, bir modelin ne kadar iyi uyduğunu ve bağımsız değişkenlerin bağımlı değişkendeki değişkenliği ne kadar açıkladığını gösteren bir ölçüdür. R-kare değeri 0 ile 1 arasında bir değer alır. 1'e ne kadar yakınsa, modelin o kadar iyi uyduğunu ve bağımsız değişkenlerin bağımlı değişkendeki varyansın büyük bir kısmını


açıkladığını gösterir. Denklem (2.9.) 'da R-kare formülü gösterilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - y^{ort})^2}$$

(2.8.)

#### 2.4.2. Tasarlanan yapay sinir ağı modeli


Alevlenme risk tahmini için tasarlanan YSA modeli, gizli katmanda toplam 75 nörona sahiptir. Tasarlanan model Şekil 2.2. 'de gösterilmektedir. Gizli katmandaki nöron sayısı belirlenirken, yapılan deneyler doğrultusunda en iyi performansı veren model esas alınmıştır. Giriş katmanında oluşturulan veri setindeki 25 özellik için 25 giriş bulunmaktadır. YSA model için gerekli eğitim ve test işlemleri MATLAB yazılım ortamında yürütülmüştür. Ağ öğrenme sürecinde geri yayılım algoritmasına ait Scaled Conjugate Gradient optimizasyon çözüm yöntemi kullanılmıştır. Bu yöntem, yapılan deneyler sonucunda en yüksek performansı sağladığı için seçilmiştir. Ağ eğitimi, veri setinden rastgele seçilen %70 veri ile tamamlanmıştır. Veri setinin %15'i doğrulama ve diğer %15'i ise ağ performansını test için kullanılmıştır. Bu aşamada farklı çevrim (epoch) sayıları ile tekrarlı denemeler yapıldı ve eğitim sürecinde en iyi performansı gösteren 17. epoch çözüm olarak kabul edildi. Tasarlanan ağın mimarisi Şekil 2.2.'de gösterilmiştir.



Şekil 2.2. Tasarlanan YSA modelinin yapısı.

Tasarlanan ağ Şekil 2.2.'de görüldüğü üzere 25 girişten oluşmaktadır. Bu 25 giriş hastalara ait veriler Tablo 2.1. 'de bahsedilen özellikleri içeren verilerdir. Daha önce bahsedildiği gibi çıktı üç kademelidir, 0 ile 2 arası değer almaktadır ve bu değer aralığı

bir sonraki ay için alevlenme riskini ifade etmektedir. Her çevrim sonunda ağın ürettiği tahmin sonuçları ve performansı irdelenmiştir. Çalışmalar sonunda en iyi sonucu veren 17. çevrim benimsenmiştir. Şekil 2.3. 'de eğitim, doğrulama ve test için her çevrimdeki MSE değeri gösterilmiştir.



**Şekil 2.3.** Eğitim, test, doğrulama için her çevrimdeki MSE ve en iyi değer.

Şekil 2.3. 'de ortalama kare hata kriteri ile her çevrim değerlendirilmiştir. Görüldüğü üzere test ve doğrulama 5. Çevrimden sonra en iyi değere doğru yaklaşma eğilimine girmiştir. 5. çevrimden sonraki her çevrimde test ve doğrulama veri seti en iyi değere yaklaşarak 17. çevrimde en iyi değerine ulaşmıştır.

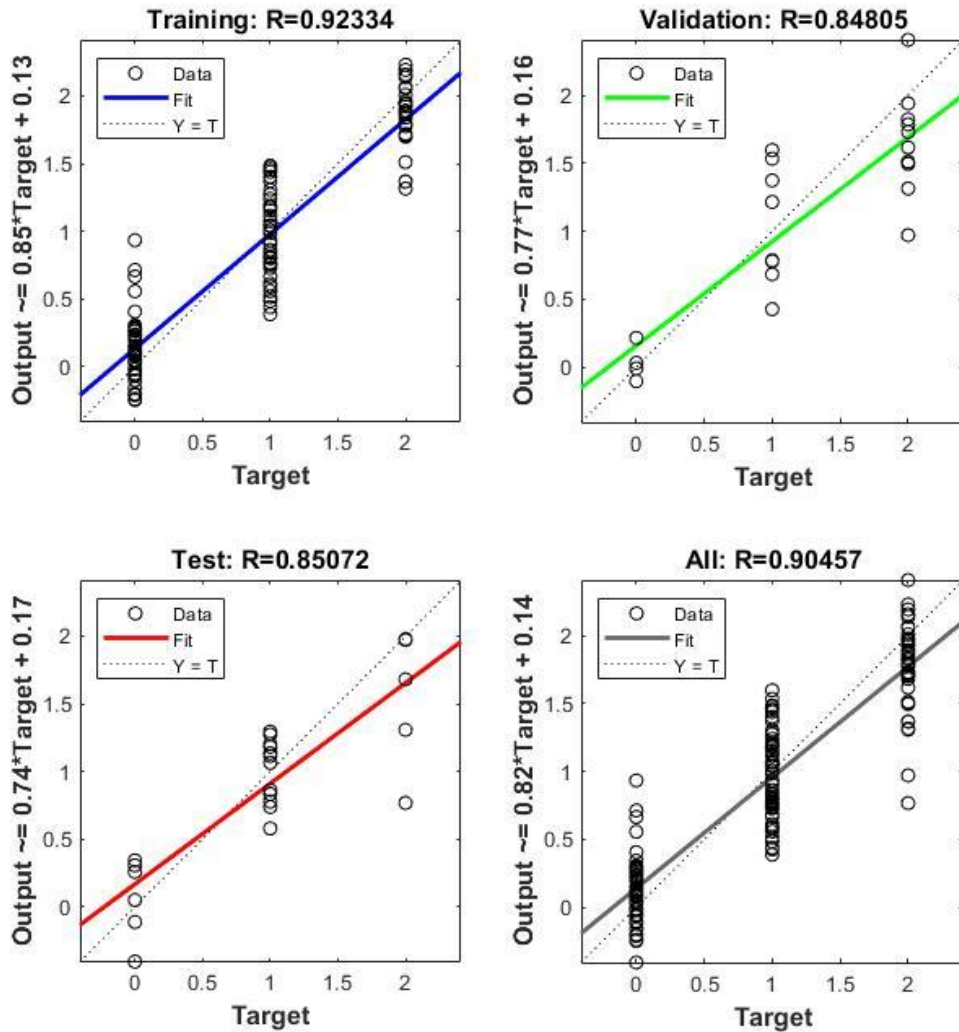
Performans ölçütleri ile ağ değerlendirilmiştir. Tablo 2.2. 'de ağın MSE, RMSE, MAE, ve R-kare için değerlendirme sonuçları gösterilmiştir.

**Tablo 2.2.** Ağın performansı

|          | MSE    | RMSE    | MAE     | R-Kare  |
|----------|--------|---------|---------|---------|
| Sonuçlar | 0.1104 | 0.33226 | 0.23994 | 0.81824 |

Tablo 2.2. 'de ağın performansı performans kriterlerine göre incelenmiştir. MSE büyük hataları ve marjinal değerleri cezalandıran bir performans kriteri olmasına rağmen ağ 0'a yakın yani çok düşük bir hata ortaya koymuştur. RMSEnin de büyük hataları cezalandırmasına karşın ağın bu kriterde de başarılı bir sonuç ortaya koyduğu görülmektedir. R-Kare ölçütünde ise ağ 1'e yakın bir performans göstererek tahmin edilen değerlerin başarısını yani modelin varyansın büyük bir kısmını açıklayabildiğini göstermektedir.

Şekil 2.4. 'de eğitim, test, doğrulama ve tüm ağ için R performans ölçütü sonuçları gösterilmiştir.



Şekil 2.4. Eğitim, test, doğrulama ve tüm ağ için R performans sonuçları

R korelasyon değeri -1 ve 1 arası değer almaktadır, ağın eğitim, test, doğrulama ve tüm

ağ için R değerlerini gösteren Şekil 2.4. 'deki değerlere bakıldığında her bir aşama için tahminin 1'e yakın yani modelin tahminlerinin trendi yakaladığı görülmektedir. R, eğitim için 0.92 iken doğrulama için 0.84, test için 0.85 ve tüm ağ için 0.904 olduğu görülmektedir. Yani modelin tahmin çıktısının tüm veri seti için %90'ı aşan başarısı olduğu görülmektedir.

## **2.5. Android Uygulama ile KOAH Hastalarının Verilerinin Takibi**

YSA modeli için IoT konseptiyle çalışma esnekliğine sahip bir android uygulama prototipi tasarlanmıştır. Evde, eczanede veya bir sağlık kuruluşunda spirometre cihazı ile ölçülen solunum verileri ve hastaya ait diğer veriler android uygulama vasıtasıyla Google Sheets'e aktarılabilir. Tasarlanan arayüz ile YSA tarafından değerlendirilen alevlenme risk seviyesi doktora aktarılacak ardından gereği halinde doktorun tavsiye ve mesajları hasta tarafından alınabilecektir. Prototip uygulaması KOAH Alevlenme Riski Tahmin Aracı (CERP) adı altında tasarlandı. Android uygulama algoritması, uygulama arayüzü ve yöntemi geliştirmeye açıktır ve geri bildirim sekmesinden kullanıcı tasarım hakkında geri bildirim yapabilmektedir. Android uygulama AppSheet platformu kullanılarak geliştirilmiştir. AppSheet, Google'ın eğitim, girişimcilik, iş yönetimi ve diğer alanlarda web ve android tabanlı uygulama geliştirme platformudur. Ayrıca geliştirilen uygulama için Excel, Google Sheets ve CloudSQL gibi veri kaynaklarını veri depolama alanı olarak kullanma olanağı sunulmaktadır. Kullanıcı dostu bir arayüz tasarımı sağlama kolaylığı, çoklu kullanıcı desteği ve kodlama aşamasındaki basitliği nedeniyle AppSheet, prototip uygulama için uygun bir platformdur. Hasta kullanıcı arayüzünde, modelin alevlenme riskinin güncel takibi için yeni ölçüm sonuçlarını girebilmektedir. Diğer bir bölümde ise ölçüm ID'si ve tarihi ile modelin tahmininin ve durum notunun yazılabildiği bir sekme yer almaktadır. Program hakkında bilgi, oturum sonlandırma seçeneği ve geri bildirim kısımlarına uygulamanın sol üst tarafındaki yatay üç çizgiye basarak ulaşılabilir. Veriler, veri depolama alanı olarak seçilen Google Sheets'de depolanarak, Google üyeliği olan ve erişim izinleri verilen kişilerin kolayca erişmesine olanak tanımaktadır. Şekil 2.5. 'de CERP uygulamasının hastanın verilerini depolama alanına iletmesi için doldurması gereken program arayüzü gösterilmektedir.

Bilgileriniz

BMI\*

0,00 - +

FEV1\*

0,00 - +

FEV1p\*

0,00 - +

FEV1/FEVC\*

0,00 - +


Üç Aydan Fazla Öksürük Deneyimi\*

0 - +

Cancel Save

**Şekil 2.5.** CERP uygulamasının bilgi girilmesi için geliştirilen arayüzü.


Şekil 2.6.'da hastanın girdiği bilgileri düzenlemesi, yenisini eklemesi, gerekli görürse kaldırması için geçmişe dönük formları gösteren sekme mevcuttur.



**Şekil 2.6.** Kullanıcının geçmişe dönük doldurduğu formları düzenlemesi ve yenisini eklemesini sağlayan sekme

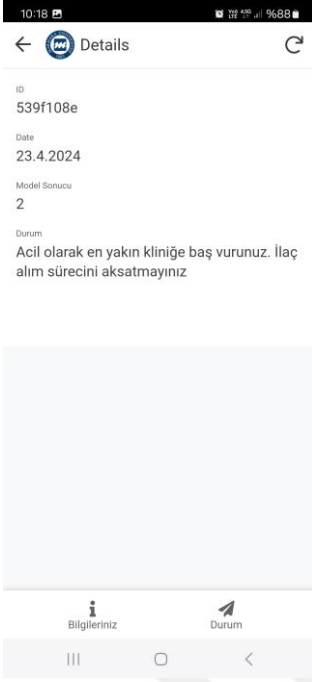
Şekil 2.7. 'de hastanın, danışman tarafından yapılan dönüş varsa ilgili ölçüm ID'si ve

tarihi ile dönüşü görüntülemesine olanak tanıyan “durum” sekmesi gösterilmiştir. Bu sekmedeki danışmanın dönüşleri, danışman tarafından silinmediği sürece geçmişe dönük olarak ilgili ID-tarih ile görüntülenebilmektedir.



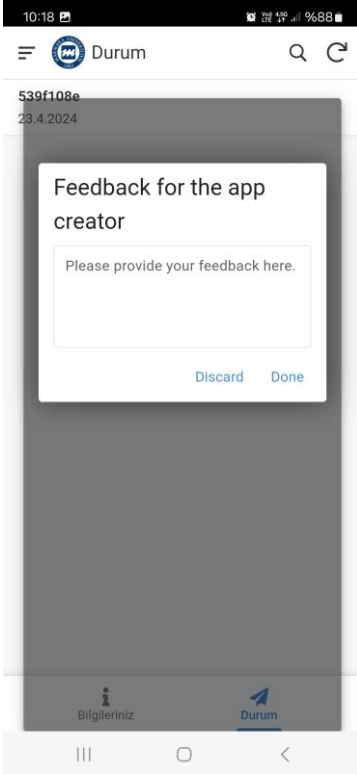
**Şekil 2.7.** Danışman dönüşlerine ulaşılabilen sekme

İlgili ID ve tarihli dönüşe basıldığında danışmanın hasta ile paylaştığı bilgiler açılmaktadır. Bu bilgiler; ölçüm ID’si, tarih, danışman tarafından istenirse önerilen model sonucu ve danışman tarafından yazılan yönergeler görülebilmektedir.



**Şekil 2.8.** Danışmanın hasta ile paylaştığı bilgilerin görüntülediği sekme

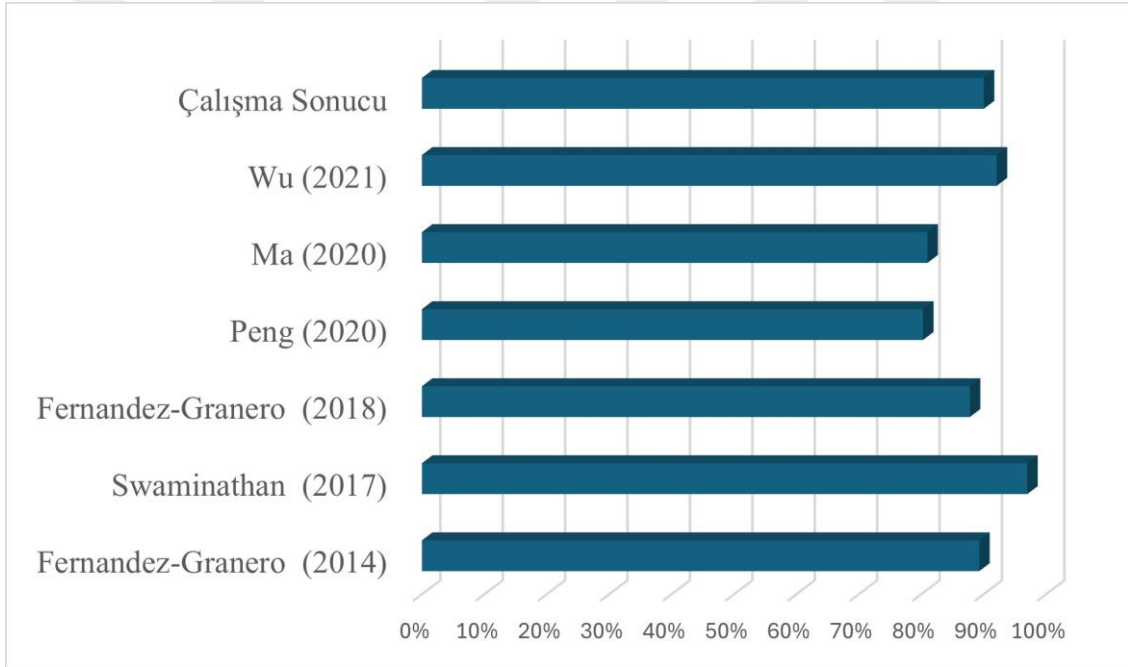
Şekil 2.9. 'da hastanın programın hatalarını bildirebilmesi, geliştirilmesine yardımcı olabileceği geri bildirim sekmesi gösterilmiştir. Geri bildirim sekmesine uygulamanın sol üst tarafındaki yatay üç çizgiye basılarak ulaşılabilir.



**Şekil 2.9.** Hastanın program hakkında geri bildirim yapmasını sağlayan sekme

### 3. BULGULAR VE TARTIŞMA

Ramón-Fernández vd. (2022) KOAH hakkında yapılan yapay zeka çalışmalarını değerlendirmek için karar ağaçları, destek vektör makineleri ve sinir ağlarını kullanarak teşhis, alevlenme tahmini, şiddet sınıflandırması ve önlenmesine yönelik farklı nitelikte 67 çalışmayı değerlendirmiştir, değerlendirilen çalışmaların tüm performans ölçütlerinin ortalamalarının 80%-90% arasında değişiklik gösterdiği belirtilmiştir. Bu çalışmalar arasında alevlenme tahmini üzerine olan Fernández-Granero vd. (2014), Swaminathan vd. (2017), Fernández-Granero vd. (2018), Peng vd. (2020), Wu vd. (2021) ve Ma vd. (2020) çalışmalarının sonuçları ile tez çalışmasının sonucunun doğruluğu Şekil 3.1. 'de birlikte gösterilmiştir.



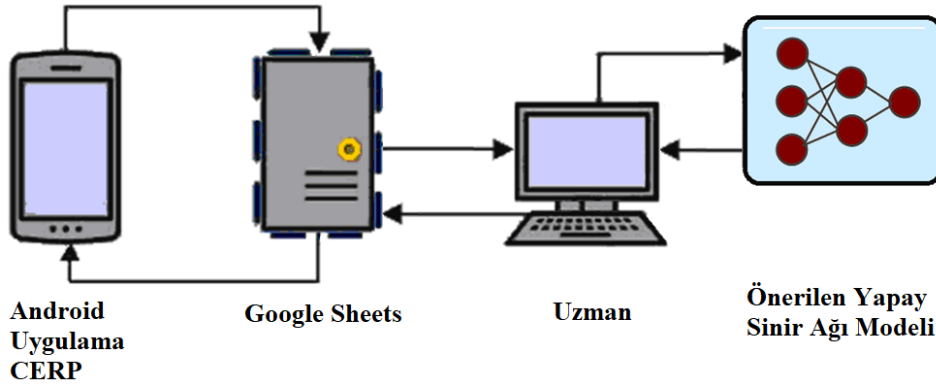
**Şekil 3.1.** Altı farklı çalışma ve tez çalışmasının sonuçlarının doğrulukları

Şekil 3.1. 'de ele alınan alevlenme tahmini üzerine çalışmalar farklı veri setleri, metotlar ve yaklaşımlarla yapılmıştır. Fernández-Granero vd. (2014) çalışmasında daha önce değinildiği üzere olasılıksal sinir ağı modeli kullanmıştır, Swaminathan vd. (2017) Gradyan Artırılmış Karar Ağaçları ve Lineer Regresyon kullanmıştır. Fernández-Granero vd. (2018) çalışmasında rastgele karar ağacı temelli bir yaklaşım kullanmıştır. Peng vd. (2020) çalışmasında C5.0 karar ağacı algoritması kullanmıştır. Wu vd. (2021) çalışmasında derin sinir ağlarını kullanmıştır ve Ma vd. (2020) çalışmasında K-en yakın komşu ve lineer regresyon kullanmışlardır. Doğruluk yüzdelerine bakıldığında tez

çalışmasının sonuçlarının başarılı olduğu görülmektedir.

XGBoost, lojistik regresyon ve rastgele orman makina öğrenmesi algoritmaları ile birçok çalışma yapıldığı ve genel olarak 75%-90% oranında başarı gösteren çalışmalar olduğu görülmektedir. Yapılan çalışmada KOAH alevlenme tahmininde %90.04 başarı oranı gözlenmiştir. Önerilen YSA modelinin başarısı, daha zengin bir veri seti ve bu veri setinin daha anlamlı etki sabitleri ile işlenmesi sonucunda artırabilir niteliktedir.

Yapılan tez çalışmasında geliştirilen android uygulaması dünyada yaygın olarak kullanılan uzaktan sağlık izleme açısından önem kazanmaktadır. Android uygulama ve tüm sistemin işleyişi Şekil 3.2.'de görselleştirilmiştir.



Şekil 3.2. Oluşturulan sistemin genel yapısı

Sistemin android uygulama tarafı, veri depolama alanı olarak kullanılan Google Sheets'e veri gönderip veri alabilmektedir. Veri depolama alanının daha hızlı ve daha geniş depolama hacmine sahip bir alternatif ile değiştirilmesi ilerleyen süreçlerde artan kullanıcı sayısı sebebiyle aksaklıklar yaşanmasının önüne geçebilir. Danışmanın veri girebilmesi için gerekli arayüz daha şık ve hızlı bir tasarım ile sunulabilir. Fernández-Granero vd. (2014) çalışmasında kullanıldığı gibi KOAH hastaları için özelleştirilmiş, dokunmatik ve ses ile çalışma desteği sunan kullanımı kolay, hasta tarafından kolayca veri toplamayı sağlayan cihazlar sisteme entegre edilerek kullanılabilir.

#### 4. SONUÇLAR

Bu çalışmadaki temel amaç, yapay zeka ve uzaktan sağlık izleme konseptlerini birleştirecek bir yaklaşıma ait uygulama örneği oluşturmaktır. Tasarlanan sistem mobil

uygulama, veri depolama alanı, sağlık uzmanı tarafı ve önerilen yapay zeka modelinden oluşmaktadır. Hasta, tasarlanan mobil uygulama CERP aracılığıyla güncel ölçülen tüm verileri veri depolama alanı olarak seçilen Google Sheets ortamına aktarabilmektedir. Veri depolama alanından alınan veriler otomatik olarak sağlık danışmanına iletilir. Daha sonra modelden tahmin edilen alevlenme riski durumu, sağlık danışmanı tarafından risk durumu ve tavsiyeler mobil CERP uygulaması ile hastaya iletilir. Deneysel sonuçlar mobil uygulamanın, veri depolama alanının ve modelin başarılı bir şekilde çalıştığını göstermektedir.

Modelin öngörüdeki arttırılabilir başarısı, yapay zekanın bu süreçte oynayabileceği potansiyel rolü göstermektedir. Önerilen model, kişiselleştirilmiş alevlenme riski tahmininin yanı sıra akıllı hastane ve evde sağlık konseptiyle bu süreci hem hastalar hem de sağlık personeli için kolaylaştıracak bir sistemdir. Söz konusu kişiselleştirilmiş ve doğruluğu yüksek tahminlerin, bu alanda yapılan diğer çalışmalar ve sağlık hizmetleri sektörünün talepleri dikkate alındığında modern sağlık hizmetlerine katkı sağladığı görünmektedir. CERP, evde sağlık ve akıllı hastane konseptleri doğrultusunda tasarlanan Android uygulama prototipi, yapay zeka sistemleri ve IoT teknolojilerinin birleştirilmesinin, sağlık hizmetlerinin verimini önemli oranda yükseltebileceğini ortaya koymaktadır. KNHANES veri setleri kullanılarak, KOAH alevlenme tahmini için oluşturulan veri setinin deneyler ve sonuçlar doğrultusunda başarılı olduğu görülmektedir. Sonraki ay alevlenme risk tahmini için kullanılan performans değerlendirme ölçütleri R, MSE, RMSE, MAE, R-kare modelin başarısını ortaya çıkarmaktadır. Ayrıca önerilen yaklaşım, sağlık kuruluşlarındaki iş yükü ve mali yüklerin azaltılmasına doğrudan katkısı sağlayacaktır.

## 5. KAYNAKLAR

Agusti, A., Calverley, P.M., Decramer, M., Stockley, R.A., Wedzicha J.A. (2014). Prevention of exacerbations in chronic obstructive pulmonary disease: knowns and unknowns. *Chronic Obstructive Pulmonary Disease*, 1(2), 166-184. doi: <http://doi.org/10.15326/jcopdf.1.2.2014.0134>.

American Lung Association. (2024, January 24). Learn About COPD. <https://www.lung.org/lung-health-diseases/lung-disease-lookup/copd/learn-about-copd>

Bingöl, Z., & Çağatay, T. (2016). Kronik Obstrüktif Akciğer Hastalığı (KOAH) Olgularında Alevlenme Nedenleri Tanı, Tedavi Ve Risk Grubu Olgularında Farkındalık.

Klinik Tıp Aile Hekimliği, 8(5), 21-23.

Bollmeier, S. G., & Hartmann, A. P. (2020, February 7). Management of chronic obstructive pulmonary disease: A review focusing on exacerbations. *American Journal of Health-System Pharmacy*, 77(4), 259-268. <https://doi.org/10.1093/ajhp/zxz306>.

Christensen, T., Mikkelsen, S., Geisler, L., & Holst, M. (2022, April 16). Chronic obstructive pulmonary disease outpatients bear risks of both unplanned weight loss and obesity. *Clinical Nutrition ESPEN*, 49(8), 246-251. <https://doi.org/10.1016/j.clnesp.2022.04.010>.

Çolak, Y., Afzal, S., Marott, J. L., Nordestgaard, B. G., Vestbo, J., Ingebrigtsen, T. S., & Lange, P. (2019). Prognosis of COPD depends on severity of exacerbation history: A population-based analysis. *Respiratory medicine*, 155, 141–147. <https://doi.org/10.1016/j.rmed.2019.07.021>.

Donaldson, G.C., Law, M., Kowlessar, B., Singh, R., Brill, S.E., Allinson, J.P., & Wedzicha, J.A. (2015). Impact of Prolonged Exacerbation Recovery in Chronic Obstructive Pulmonary Disease. *American Journal of Respiratory and Critical Care Medicine*, 192(8), 943–950. <https://doi.org/10.1164/rccm.201412-2269OC>.

Fernández-Granero, M. A., Sanchez-Morillo, D., & Leon-Jimenez, A. (2018, February 10). An artificial intelligence approach to early predict symptom-based exacerbations of COPD. *Biotechnology & Biotechnological Equipment*, 32(3), 778-784. <https://doi.org/10.1080/13102818.2018.1437568>.

Fernández-Granero, M. A., Sánchez-Morillo, D., León-Jiménez, A., & Crespo, L. F. (2014). Automatic prediction of chronic obstructive pulmonary disease exacerbations through home telemonitoring of symptoms. *Bio-medical materials and engineering*, 24(6), 3825–3832. <https://doi.org/10.3233/BME-141212>

Global Initiative for Chronic Obstructive Lung Disease. (2024, January 11). GLOBAL STRATEGY FOR PREVENTION, DIAGNOSIS AND MANAGEMENT OF COPD: 2024 Report. [https://goldcopd.org/wp-content/uploads/2024/01/GOLD-2024\\_v1.2-11Jan24\\_WMV-1.pdf](https://goldcopd.org/wp-content/uploads/2024/01/GOLD-2024_v1.2-11Jan24_WMV-1.pdf).

Global Initiative for Chronic Obstructive Lung Disease. (2023, February 17). GLOBAL STRATEGY FOR PREVENTION, DIAGNOSIS AND MANAGEMENT OF COPD: 2023 Report. [https://goldcopd.org/wp-content/uploads/2023/03/GOLD-2023-ver-1.3-17Feb2023\\_WMV.pdf](https://goldcopd.org/wp-content/uploads/2023/03/GOLD-2023-ver-1.3-17Feb2023_WMV.pdf).

Korea Disease Control and Prevention Agency. (2010-2015). Korean National Health and Nutrition Examination Survey. Retrieved from [https://knhanes.kdca.go.kr/knhanes/eng/sub03/sub03\\_02\\_02.do](https://knhanes.kdca.go.kr/knhanes/eng/sub03/sub03_02_02.do).

Kabbay, H. (2022). Artificial Neural Network Concepts and Examples. University of Missouri, St. Louis, USA. Theses, 402. <https://irl.umsl.edu/thesis/402>

Kukrety, S. P., Parekh, J. D., & Bailey, K. L. (2018, July-August). Chronic obstructive pulmonary disease and the hallmarks of aging. *Lung India*, 35(4), 321–327.

[https://doi.org/10.4103/lungindia.lungindia\\_266\\_17](https://doi.org/10.4103/lungindia.lungindia_266_17)

Ma, X., Wu, Y., Zhang, L., Yuan, W., Yan, L., Fan, S., Lian, Y., Zhu, X., Gao, J., Zhao, J., Zhang, P., Tang, H., & Jia, W. (2020). Comparison and development of machine learning tools for the prediction of chronic obstructive pulmonary disease in the Chinese population. *Journal of Translational Medicine*, 18(1), 146. <https://doi.org/10.1186/s12967-020-02312-0>

Mannino, D. M., Roberts, M. H., Mapel, D. W., Zhang, Q., Lunacsek, O., Grabich, S., van Stiphout, J., Meadors, B. L., Feigler, N., & Pollack, M. F. (2023, November 29). National and Local Direct Medical Cost Burden of COPD in the United States From 2016 to 2019 and Projections Through 2029. *CHEST Journal*, (In Press). <https://doi.org/10.1016/j.chest.2023.11.040>.

Peng, J., Chen, C., Zhou, M., Xie, X., Zhou, Y., & Luo, C. H. (2020). A Machine-learning Approach to Forecast Aggravation Risk in Patients with Acute Exacerbation of Chronic Obstructive Pulmonary Disease with Clinical Indicators. *Scientific reports*, 10(1), 3118. <https://doi.org/10.1038/s41598-020-60042-1>.

Putcha, N., Anzueto, A. R., Calverley, P. M. A., Celli, B. R., Tashkin, D. P., Metzdorf, N., Mueller, A., & Wise, R. A. (2022, February 19). Mortality and exacerbation risk by body mass index in patients with COPD in TIOSPIR and UPLIFT. *Annals of the American Thoracic Society*, 19(2), 204-213. <https://doi.org/10.1513/AnnalsATS.202006-722OC>.

Rahi, M. S., Thilagar, B., Balaji, S., Prabhakaran, S. Y., Mudgal, M., Rajoo, S., Yella, P. R., Satija, P., Zagorulko, A., & Gunasekaran, K. (2023, March 10). The impact of anxiety and depression in chronic obstructive pulmonary disease. *Advances in Respiratory Medicine*, 91(2), 123-134. <https://doi.org/10.3390/arm91020011>.

Ramón-Fernández, A.D., Fernández, D.R., Gilart-Iglesias, V., & Marcos-Jorquera, D. (2022). Analyzing the use of artificial intelligence for the management of chronic obstructive pulmonary disease (COPD). *International journal of medical informatics*, 158, 104640. <https://doi.org/10.1016/j.ijmedinf.2021.104640>.

Rejeb, A., Rejeb, K., Treiblmaier, H., Appolloni, A., Alghamdi, S., Alhasawi, Y., & Iranmanesh, M. (2023, July). The Internet of Things (IoT) in healthcare: Taking stock and moving forward. *Internet of Things*, 22, 100721. <https://doi.org/10.1016/j.iot.2023.100721>.

Shukla, S. D., Shastri, M. D., Jha, N. K., Gupta, G., Chellappan, D. K., Bagade, T., & Dua, K. (2021). Female gender as a risk factor for developing COPD. *EXCLI Journal*, 20, 1290–1293. <https://doi.org/10.17179/excli2021-4118>.

Singh, D., Hurst, J. R., Martinez, F. J., Rabe, K. F., Bafadhel, M., Jenkins, M., Salazar, D., Dorinsky, P., & Darken, P. (2022, July 9). Predictive modeling of COPD exacerbation rates using baseline risk factors. *Therapeutic Advances in Respiratory Disease*, 16. <https://doi.org/10.1177/17534666221107314>.

Soner, S., Karakurt, S. (t.y.). KOAH ALEVLENMELERİ. <https://toraks.org.tr/site/sf/wgmf/rfic/c114129c3e6841a9c4f6545d5133c729db91e31f46fa2ddcd1454203132f72b4.pdf>.

Swaminathan, S., Qirko, K., Smith, T., Corcoran, E., Wysham, N. G., Bazaz, G., Kappel, G., & Gerber, A. N. (2017). A machine learning approach to triaging patients with chronic obstructive pulmonary disease. *PLoS ONE*, 12(11), e0188532. <https://doi.org/10.1371/journal.pone.0188532>.

Tomasic, I., Tomasic, N., Trobec, R., Krpan, M., & Kelava, T. (2018). Continuous remote monitoring of COPD patients-justification and explanation of the requirements and a survey of the available technologies. *Medical & biological engineering & computing*, 56(4), 547–569. <https://doi.org/10.1007/s11517-018-1798-z>.

Vogelmeier, C. F., Diesing, J., Kossack, N., Pignot, M., & Friedrich, F. W. (2021, August 24). COPD Exacerbation History and Impact on Future Exacerbations - 8-Year Retrospective Observational Database Cohort Study from Germany. *International Journal of Chronic Obstructive Pulmonary Disease*, 16, 2407-2417. <https://doi.org/10.2147/COPD.S322036>.

Wang, G., Ma, A., Zhang, L., Guo, J., Liu, Q., Petersen, F., Wang, Z., & Yu, X. (2022). Acute exacerbations of chronic obstructive pulmonary disease in a cohort of Chinese never smokers goes along with decreased risks of recurrent acute exacerbation, emphysema and comorbidity of lung cancer as well as decreased levels of circulating eosinophils and basophils. *Frontiers in medicine*, 9, 907893. <https://doi.org/10.3389/fmed.2022.907893>.

Wang, X., Ren, H., Ren, J., Song, W., Qiao, Y., Ren, Z., Zhao, Y., Linghu, L., Cui, Y., Zhao, Z., Chen, L., & Qiu, L. (2023). Machine learning-enabled risk prediction of chronic obstructive pulmonary disease with unbalanced data. *Computer Methods and Programs in Biomedicine*, 230, 107340. <https://doi.org/10.1016/j.cmpb.2023.107340>.

Westerik, J. A., Metting, E. I., van Boven, J. F., Tiersma, W., Kocks, J. W., & Schermer, T. R. (2017). Associations between chronic comorbidity and exacerbation risk in primary care patients with COPD. *Respiratory Research*, 18(1), 31. <https://doi.org/10.1186/s12931-017-0512-2>.

World Health Organization. (2023, March 16). Chronic obstructive pulmonary disease (COPD). [https://www.who.int/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-\(copd\)](https://www.who.int/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-(copd)).

Wu, C. T., Li, G. H., Huang, C. T., Cheng, Y. C., Chen, C. H., Chien, J. Y., Kuo, P. H., Kuo, L. C., & Lai, F. (2021). Acute exacerbation of a chronic obstructive pulmonary disease prediction system using wearable device data, machine learning, and deep learning: Development and cohort study. *JMIR mHealth and uHealth*, 9(5), e22591. <https://doi.org/10.2196/22591>.

Zarrin, P. S., Roeckendorf, N., & Wenger, C. (2020, September 14). In-Vitro Classification of Saliva Samples of COPD Patients and Healthy Controls Using

Machine Learning Tools. *IEEE Access*, 8, 168053-168060. <https://doi.org/10.1109/ACCESS.2020.3023971>.

Zeng, S., Arjomandi, M., Tong, Y., Liao, Z. C., & Luo, G. (2022). Developing a machine learning model to predict severe chronic obstructive pulmonary disease exacerbations: Retrospective cohort study. *Journal of Medical Internet Research*, 24(1), e28953. <https://doi.org/10.2196/28953>



