

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME İLE AKCİĞER SESLERİNİN YÜKSEK DOĞRULUKLA
SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Ayşenur BAKAY

HAZİRAN 2024
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME İLE AKCİĞER SESLERİNİN YÜKSEK DOĞRULUKLA
SINIFLANDIRILMASI**

Ayşenur BAKAY

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
“ELEKTRONİK YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 15 / 02 / 2024
Tezin Savunma Tarihi : 28 / 06 / 2024

Tez Danışmanı : Dr. Öğr. Üyesi Mehmet ÖZTÜRK

Trabzon 2024

ÖNSÖZ

“Derin Öğrenme İle Akciğer Seslerinin Yüksek Doğrulukla Sınıflandırılması” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilimsel akademi yolunda ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Dr. Öğr. Üyesi Mehmet ÖZTÜRK’e teşekkürü bir borç bilirim. Ayrıca öğrenim hayatım boyunca desteğini esirgemeyen ve üzerimde büyük emekleri olan annem Fatma BAKAY, babam Adnan BAKAY ve abim Mustafa Anıl BAKAY’ a teşekkür eder, minnettarlığımı sunarım.

Bu araştırmanın, bilim dünyasına, ilgilenenlere ve ülkemize faydalı olmasını dilerim.

Ayşenur BAKAY
Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme İle Akciğer Seslerinin Yüksek Doğrulukla Sınıflandırılması ” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr. Öğr. Üyesi Mehmet ÖZTÜRK’ün sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 28/06/2024

Ayşenur BAKAY

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VI
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ.....	IX
SEMBOLLER VE KISALTMALAR DİZİNİ	X
1. GENEL BİLGİLER.....	1
1.1. Yapay Zeka Kavramı.....	1
1.2. Yapay Zeka Teknikleri.....	3
1.2.1. Makine Öğrenmesi	3
1.2.2. Yapay Sinir Ağları.....	16
1.2.3. Derin Öğrenme	17
1.3. Derin Öğrenme Katmanları	20
1.4. Derin Öğrenme Modelleri.....	23
1.5. Görüntü İşleme ve Bilgisayar Görmesi	27
1.6. Derin Öğrenme İle Akciğer Seslerinin Yüksek Doğrulukla Sınıflandırılması İle Alakalı Çalışmalar.....	28
2. YÖNTEM	32
2.1 Veri Seti	32
2.2 Veri Setinin Oluşumu	32
2.3 Veri Hazırlama Süreci	33
2.5 Özelliklerin Eşitlenmesi.....	35
2.6 Eğitim ve Test Setlerine Ayırma	36
2.7 Modelin Oluşturulması ve Eğitimi	36
2.8 Modelin Değerlendirilmesi	37
3. BULGULAR	40
4. SONUÇ TARTIŞMA VE ÖNERİLER.....	42
5. KAYNAKLAR.....	46
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

DERİN ÖĞRENME İLE AKCİĞER SESLERİNİN YÜKSEK DOĞRULUKLA SINIFLANDIRILMASI

Ayşenur BAKAY

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik ve Elektronik Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Mehmet ÖZTÜRK
2024, 60 Sayfa

Solunum sistemi hastalıklarının erken teşhisi ve tedavisi, hastaların yaşam kalitesini artırmak ve ölüm oranlarını azaltmak açısından büyük önem taşımaktadır. Geleneksel olarak doktorlar, stetoskop kullanarak hastaların akciğer seslerini dinler ve bu seslere dayanarak tanı koyarlar. Ancak bu yöntem subjektif olup tecrübeye bağlıdır. Bu çalışmada, akciğer seslerinin otomatik sınıflandırılması hedeflenmiştir. Farklı filtre türleriyle kaydedilmiş ve çeşitli akciğer hastalıklarına sahip hastalardan alınmış ses dosyaları kullanılmıştır. Sesler, göğüs duvarının çeşitli noktalarından kaydedilmiş ve uzmanlar tarafından tanı konulmuştur. Veri artırma teknikleri kullanılarak (pitch shift ve zaman uzatma), modelin performansı artırılmıştır. Makine öğrenmesi teknikleri ile bu ses dosyalarından elde edilen MFCC özellikleri çıkarılmış ve Bidirectional LSTM (BiLSTM) katmanları içeren bir derin öğrenme modeli ile sınıflandırılmıştır. Bu çalışma, solunum sistemi hastalıklarının erken teşhisinde kullanılabilecek güvenilir ve etkili bir sistem geliştirmeyi amaçlamaktadır. Bulgular, sağlık profesyonellerine tanı sürecinde yardımcı olabilecek ve hasta bakımında önemli bir ilerleme sağlayabilecek niteliktedir.

Anahtar Kelimeler: Akciğer Sesleri, Derin Öğrenme, Sınıflandırma

Master Thesis

SUMMARY

HIGH-ACCURACY CLASSIFICATION OF LUNG SOUNDS USING DEEP LEARNING

Ayşenur BAKAY

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electric-Electronic Graduate Program
Supervisor: Assistant Professor Mehmet ÖZTÜRK
2024, 60 Pages

Early diagnosis and treatment of respiratory system diseases are crucial for improving patients' quality of life and reducing mortality rates. Traditionally, doctors use stethoscopes to listen to patients' lung sounds and diagnose based on these sounds, which is a subjective and experience-dependent method. This study aims to classify lung sounds automatically. Audio files recorded with different filter types from patients with various lung diseases were used. The sounds were recorded from different points on the chest wall and diagnosed by specialists. Data augmentation techniques (pitch shift and time stretch) were employed to enhance model performance. Machine learning techniques were applied to extract MFCC features from these audio files, and a deep learning model with Bidirectional LSTM (BiLSTM) layers was used for classification. This study aims to develop a reliable and effective system for the early diagnosis of respiratory system diseases. The findings are intended to assist healthcare professionals in the diagnostic process and represent a significant advancement in patient care.

Key Words: Lung Sounds, Deep Learning, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Makine öğrenmesi ve klasik programlama arasındaki fark.....	4
Şekil 2. Makine Öğrenmesi Metotları.....	4
Şekil 3. Tez çalışmasında açıklanan algoritmalar.....	5
Şekil 4. Bağlanım ve sınıflandırma yönteminin çalışma şekilleri	6
Şekil 5. Kümeleme algoritması çalışma prensibi.....	7
Şekil 6. K-Ortalamlar algoritması çalışma prensibi	8
Şekil 7. Yukarıdaki grafikte görüldüğü üzere dirsek metoduna göre bu veri setine en uygun kümeleme.....	9
Şekil 8. Siluet Yöntemi	9
Şekil 9. Temel bileşenler analizi i boyuttaki ham veriden, en anlamlı özellikleri olan özünü.....	10
Şekil 10. Yarı denetimli öğrenmedeki veri gösteriminin farkları	12
Şekil 11. Kullanılan Markov modeli.....	15
Şekil 12. Yapay sinir ağı topolajisi	17
Şekil 13. Bir sinir hücresinin matematiksel modeli	17
Şekil 14. Yapay Sinir Ağı (üstte), Evrişimli Sinir Ağı (altta) farklı topolojileri	19
Şekil 15. Yapay zekâ kavramlarının gösterimi	19
Şekil 16. Evrişimli Sinir Ağı genel mimarisi.....	20
Şekil 17. Evrişim işlemi.....	21
Şekil 18. ReLU fonksiyon(kırmızı) ve türevinin(mavi) grafiği.....	21
Şekil 19. Havuzlama katmanı gösterimi	22
Şekil 20. Tam bağlı katman yapısı.....	22
Şekil 21. Seyrelme katmanı sonrası bağlantı şekli.....	23
Şekil 22. Sınıflandırma katmanı işlevi.....	23
Şekil 23. Derin öğrenme mimarilerinden bazıları.....	24
Şekil 24. LeNet mimarisi	24
Şekil 25. AlexNet Mimarisi	25
Şekil 26. ZF Net Mimarisi	25

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Yatay format tablosu.....	11
Tablo 2. Dikey format tablosu	11
Tablo 3. Literatürdeki diğer çalışmalar	32
Tablo 4. BİLSTM Modelde kullanılan parametre ve değerleri	43



SEMBOLLER VE KISALTMALAR DİZİNİ

YSA	: Yapay Sinir Ağları
YDZ	: Yapay Dar Zeka
YGZ	: Yapay Genel Zeka
YSZ	: Yapay Süper Zeka
MFCC	: Mel-Frekans Kepstral Katsayıları
ML	: Makine Öğrenmesi
DL	: Derin Öğrenme
CNN	: Evrişimli Sinir Ağı
RNN	: Tekrarlamalı Sinir Ağı
γ	: İndirim faktörü
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
BİLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory)

1. GENEL BİLGİLER

1.1. Yapay Zeka Kavramı

Sanayi Devrimi boş zaman anlayışı için büyük değişimlerin yaşandığı bir dönemin başlangıcını temsil etmektedir. Sanayi devrimi ile makineler insanların kas gücü ile yaptıkları işlerin yerini almaya başlamış ve tüm insanlık bu değişime uyum sağlayarak, bu değişimden kazanç elde edebilecekleri yeni durumlar oluşturmuşlardır. 21. Yüzyıla gelindiğinde ise akıl gücüyle yapılabilen işlerin makinelere nasıl yaptırılabilceği sorusunun cevabı aranmaya başlanmıştır (Tegmark, 2019).

Teknolojinin kişisel yaratıcılıkların ortaya çıkışında insanların hayatını kolaylaştıran önemli bir araç konumunda olduğu bir gerçektir. Teknolojik gelişmelerin mihenk taşı olarak görülen bilgisayar teknolojisinin gelişmesine paralel olarak farklı teknolojik kavramların ortaya çıktığı görülmektedir. II. Dünya Savaşı sırasında Alan Mathison Turing tarafından, Nazilerin savaş sırasında haberleşme için kullandıkları Enigma makinesinin şifelerini çözmek amacıyla (Turing, 1954), mekanik sistemlerin elektronik sistemlerle kontrolünün sağlandığı cihazlar kullanılarak hem bilgisayar biliminin hem de yapay zekanın temelleri atılmıştır (Tunç ve Sanduvaç, 2020).

Yapay zeka teknolojisi Yapay Dar Zeka (YDZ), Yapay Genel Zeka (YGZ) ve Yapay Süper Zeka (YSZ) olmak üzere üç kategoride incelenmektedir. YDZ günlük olarak birçok alanda etkileşim içerisinde gerçekleşen yapay zeka türüdür. Sosyal medya platformlarında bulunan fotoğraf etiketleme, yüz tanıma, içerik akışları, Google asistan gibi farklı işletim sistemlerinin akıllı kişisel asistanları, mesajlaşma uygulamaları, satın alma önerileri ve satış tahminleri gibi görevler YDZ tarafından gerçekleştirilmektedir (Meskó, Hetény ve Győ, 2018). YGZ, muhakeme (Kaplan ve Haenlein, 2019) ve insan zekasının yapabildiği genellemeleri yapabilen (Husain, 2019), çeşitli bağlamlarda karmaşık sorunları çözme ve yeni sorunları çözmeyi öğrenme yeteneğine sahip olan yapay zeka sistemleridir (Pennachin ve Goertzel, 2007). YGZ'yi YDZ'den ayıran en önemli nokta, genelleme yaparak karşılaştığı sorunlara kendi kendine çözüm üretebilmesidir. (Kaplan ve Haenlein, 2019). YSZ ise kendisinin gerçekten farkında olan, insana gerek duymadan yapılacaklar hakkında bilinçli karar verebilme yeteneğine sahip ve yapay zeka teknolojisinin geleceği olarak adlandırılan sistemlerdir (Meskó, Hetény ve Győ, 2018; Kaplan ve Haenlein, 2019).

Günlük görevlere yardımcı olan pek çok uygulama ve hizmet, yapay zeka sistemleri tarafından desteklenmektedir. Bu teknoloji sayesinde insan yetenekleri köreltilerek dışarda bırakılmak isteniyor şeklinde (Ernst, Merola ve Samaan, 2019) bir algı olsa da günümüzde kullanılan YGZ düzeyindeki yapay zeka sistemleri hala insana ihtiyaç duymaktadır. Yapay zeka sistemleri ile hem şirketler hem de bireyler mevcut yeteneklerini en etkin şekilde kullanabilmektedirler (Sivasubramanian, 2021). Öğrenme, problem çözme, yaratıcılık, örüntü tanıma, tümevarım ve tümdengelim, sınıflandırma ve çok daha fazlasını ifade eden yapay zeka kavramı (Hutter, 2005) sahip olduğu bu özellikler sayesinde hayatın hemen hemen her alanında vazgeçilmez konumlara yerleştirilen sistemlerin ortaya çıkışına neden olmuştur (Öztemel, 2006). Yapay zekayı sistemleri içerisine dahil eden alanlar günümüzde artık sadece bilişim teknolojileriyle sınırlı değildir. İnsan aklının ve kas gücünün süreci yönettiği birçok noktada yapay zeka teknolojilerinden bahsetmek mümkün hale gelmiştir.

Tunç ve Sanduvaç (2020)'e göre insan sadece sahip olduğu 5 duyu organıyla bilgiye erişebiliyorken, yapay zeka internet bağlantısı sayesinde çok kısa süreler içerisinde daha fazla bilgiye daha hızlı ulaşabilmektedir. Sahip olduğu bu önemli avantajın hem zaman bakımından hem de maddi gelir elde etme noktasında birçok endüstriye olan katkıları yapılmış bilimsel çalışmalarla da ortaya konmuştur. Bu alanlardan bazıları sağlık (Rigby, 2019), bankacılık (Donepudi, 2017), iletişim (Gunkel, 2012), alışveriş (Stanciu ve Rindaşu, 2021), video oyunları (Safadi, Fonteneau ve Ernst, 2015), askeriye (Svenmarck vd., 2018), otomotiv (Tubaro ve Casilli, 2019) ve robotik (Bogue, 2014) alanlar şeklinde ortaya çıkmaktadır.

Yapay zekanın büyük ölçekte ses getiren uygulamalarından biri de sanal organizasyonlardır. Hizmet üretimi ve sunulması aşamasında zamandan ve mekandan bağımsız olarak, bilgisayarın sunduğu imkanlar doğrultusunda sürekli iletişim halinde olan bu organizasyonel yapılar, bilgi tabanlı yöntemlerden ve robotik yapılardan daha büyük bir endüstriyel yapının temelini oluşturmaktadır (O'Leary, Kuokka ve Plant, 1997). Bu endüstriyel gelişimin kapısını aralayan temel nokta, Atalay ve Çelik (2017)'e göre bilgisayarların da dışında internet bağlantısına sahip olan her teknolojik ürünün veri üretmesi ve yine aynı teknolojinin üretilen bu verileri toplamasıdır. Sayısız ve karmaşık şekilde üretilen verilerin tanınması veya tanımlanması için temelde yine insan bilgisine ihtiyaç duyulmaktadır. İnternet siteleri, elektronik gazeteler, sosyal medya platformları, vlog ve bloglar, otomatik algılayıcılar ve pek çok akıllı cihazda insanlar tarafından üretilen içerikler birer veri olarak depolanmaktadır. Depolanan bu verilerin hepsi pek çok farklı endüstride

kabul görmek isteyen kurum ve kuruluşlar için oldukça önemlidir (Doğan ve Arslantekin, 2016). Verilerle gelişerek büyüyen geleceğin yapay akıllı teknolojileri, insan hayatını pek çok farklı noktada kolaylaştırmasının yanı sıra önemli bir rekabet avantajı da sağlayacağı ifade edilmektedir (Joe, 2021).


İletişim teknolojileri, sağlık, medya, otomotiv, finans endüstrileri gibi pek çok alanda ortaya çıkan verilerin depolanması, işlenmesi ve analiz edilmesi noktasında “Büyük Veri” olarak adlandırılan bir kavram ortaya çıkmaktadır (Buhl vd., 2013). Büyük verinin ortaya çıkışı, internet bağlantısına sahip olan her teknolojik ürünün veri üretmesiyle ve verilerin saklanmasıyla başlamıştır. Bu veriler, günümüzde gündelik yaşamın akışı içerisinde hatta çoğu zaman farkında olmadan üretilmekte (Oussous, 2018) ve önemsiz olarak görülse de kişisel olarak yapılan paylaşımlar, okunan haberler ya da beğenilen fotoğraflar hakkımızda veri olarak saklanmaktadır. Depolanan verilerle kullanıcı alışkanlıkları, davranış türleri, hobileri, kişilikleri ve hatta ruh halleri hakkında bile tahminlerde bulunabilmek mümkün hale gelmektedir (Chen, Mao ve Liu, 2014).

1.2. Yapay Zeka Teknikleri

1.2.1. Makine Öğrenmesi


Klasik programlamada, yazılımcı bilgisayara talimatlar vererek istenen davranışı açıkça tanımlar. Bu yöntem, belirli görevler için oldukça etkili olsa da, karmaşık ve değişken ortamlarda yetersiz kalabilir. Klasik yapay zeka uygulamaları ise, önceden tanımlanmış kurallara ve verilere dayalı olarak karar verme mekanizmaları sunar. Bu yaklaşımlar, belirli bir problem alanında uzmanlaşmak için faydalı olsa da, yeni durumlara uyum sağlama ve öğrenme becerilerinden yoksundur. Makine öğrenmesi (ML), bu paradigma sınırlamalarını aşarak yeni bir bakış açısı sunar. ML algoritmaları, veri kümelerinden ve beklenen çıktı örneklerinden faydalanarak, karmaşık ilişkileri ve örüntüleri otomatik olarak keşfeder. Bu sayede, önceden programlanmamış yeni durumlara özgün ve doğru yanıtlar üretebilen modeller oluşturmak mümkün hale gelir (Chollet, 2017). Bu bağlamda, ML, bilgisayarların veriye dayalı olarak öğrenme ve gelişme yeteneğini geliştirmeyi amaçlar. Bu sayede, karmaşık ve dinamik ortamlarda daha sağlam ve esnek çözümler üretmek mümkün hale gelir. Algoritma ve veri setinden oluşan bu yapıda algoritmalar klasik programlamadakine benzemez. Klasik programlamada algoritmalar, sıralı talimatlar şeklinde olmasına karşılık

makine öğrenmesinde veri setlerinden genelleştirmeler yapacak şekilde tasarlanmıştırlar. Bu genelleştirmeler yeni durumlara uyarlanarak öğrenme sağlanır. (Chollet, 2017). Şekil 1’ de klasik programlama ile makine öğrenmesi programlama süreçleri arasındaki fark görülmektedir.



Şekil 1. Makine öğrenmesi ve klasik programlama arasındaki fark

Makine öğrenimi, veri işleme ve model oluşturma süreçlerinde farklı yaklaşımlar benimseyen üç temel kategoriye ayrılır: gözetimli, gözetimsiz ve pekiştirmeli öğrenme. Gözetimli öğrenme yönteminde, modelin tahminleri, gerçek değerlerle karşılaştırılarak hata miktarı minimize edilmeye çalışılır. Bu süreçte, modelin ağırlık parametreleri iteratif olarak güncellenir. Gözetimsiz öğrenmede ise, model giriş verilerinden bağımsız olarak kendi iç yapısını keşfetmeye yönlendirilir ve veri setinin altında yatan yapıyı veya desenleri ortaya çıkarması beklenir. Pekiştirmeli öğrenmede model, verilen girdilere dayanarak, belirlenen sınıflandırma veya karar verme görevlerini yerine getirirken, en iyi sonucu elde etmek için hangi stratejileri izleyeceğini öğrenir (Chollet, 2017).




Şekil 2. Makine Öğrenmesi Metotları

Makine öğrenimi, istatistiksel analizlerle derin bir ilişki içinde olmasına rağmen, metodoloji ve uygulama alanlarında önemli farklılıklar gösterir. Özellikle büyük veri setleri ile çalışma kapasitesi, makine öğreniminin istatistiksel yöntemlerden ayrıştığı temel noktalardan biridir. İstatistiksel modeller, genellikle büyük veri setlerinin karmaşıklığı ve hacmi karşısında sınırlamalar yaşarken, makine öğrenimi algoritmaları bu tür verilerden öğrenme ve adaptasyon yeteneğine sahiptir. Makine öğreniminin temel amacı, deneyimlerden öğrenerek performansı artırmaktır; deneyim miktarının artmasıyla birlikte öğrenme kapasitesi de doğru orantılı olarak gelişir. Bu bağlamda, veri miktarındaki artış, makine öğreniminin etkinliğini ve önemini daha da artırmaktadır. Makine öğrenimi süreçlerinde, öğrenilecek konseptlerin temsilleri, sisteme giriş verisi olarak sunulur ve her bir temsilin model çıkışına olan etkisi, ağı kendisi tarafından belirlenir. Bu noktada, doğru temsilcilerin seçilmesi kritik bir öneme sahiptir. Geleneksel makine öğrenimi yaklaşımlarında, bu temsilciler genellikle manuel olarak tasarlanır ve seçilir (Chollet, 2017).

* Makine Öğrenmesinin Türleri


Derin Öğrenmeye geçmeden önce makine öğrenmesini detaylıca anlatmakta fayda vardır. Çok sayıda makine öğrenmesi sistemi bulunmaktadır. Girdi olarak verilen bilginin etiketli veya etiketsiz olup olmadığına göre ya da ne kadarının etiketli olduğu tespit edilebilir. Giren verinin tamamının mı yoksa aşamalı olarak mı sisteme tanıtılmasına göre ya da örnek tabanlı ve model tabanlı olarak iki şekilde ayrılabilir. Bu kriterler birbirinden tamamen ayrı olarak değil hibrit bir şekilde de kullanılabilir.



Şekil 3. Tez çalışmasında açıklanan algoritmalar

Denetimli Öğrenme


Modeli besleyen verilerin etiketli olmasına yani beklenen sonuçları içermesi durumuna denetimli öğrenme denir. En basit denetimli öğrenme görevleri sınıflandırma ve bağlantıdır. Sınıflandırma görevi eğitilen modele yeni verilen girildiğinde hangi sınıfa ait olduğunu belirtmektedir. En basit örneği mail kutusunun postaları gerekli ve gereksiz olarak ayırabilmesidir. Diğer görev bağlantı ise sayısal bir çıktı vermektedir. Verilen girdilere ve etiketlere bakarak, modelden istenilen veri için sayısal bir tahminde bulunmaktadır. Örneğin evlerin özniteliklerinin çeşitli olduğu (vergi miktarı, bulunduğu konumun suç oranı, konutun yaşı vb.) ve etiket değerinin kirayı belirlediği bir veri setiyle eğitilen bir modelin, belirli özniteliklerdeki bir evin kirasını tahmin edebilmesi bir bağlantı görevidir. Bağlantı problemi sınıflandırma için de kullanılabilmektedir. İstenilen verinin hangi sınıfa ait olduğunun yüzde değerini verebilmesine lojistik bağlantı denir.



Şekil 4. Bağlantı ve sınıflandırma yönteminin çalışma şekilleri

Denetimsiz Öğrenme

Denetimsiz öğrenmede modelse eğitilen veriler etiketsizdir. Model kendi kendine öğrenmeye, veriler arası benzerlikler bulmaya çalışır. Örneklerle açıklamak gerekirse, LinkedIn profilinize bakan ziyaretçilerden oluşan bir veri seti olduğu varsayalım. Model, benzer ziyaretçileri gruplayarak varsayımlar üretebilir. Bu varsayımlar, ziyaretçilerin %50'sinin 5-10 yıl arası çalışmış kadın yazarların olduğu ve sabahları profilinize baktığı ya da %30'unun çalışan ihtiyacı olan şirketler olduğu ve çalışma saatleri içinde profilinize baktığı olabilir. Buna denetimsiz öğrenmede kümeleme denir. Elde edilen kümeler kendi içlerinde daha küçük kümelere ayrılmasına da hiyerarşik kümeleme algoritması denir.



Şekil 5. Kümeleme algoritması çalışma prensibi

Bir diğer denetimsiz öğrenme görevi ise boyut azaltmadır. Boyut azaltmanın görevi veri kaybı yaşamadan, eldeki bilgiyi en basit şekilde gösterebilmektir. Bu birbiriyle ilişkisi olan birkaç niteliği bir araya getirerek yapılabilir. Örnek olarak, bir çalışan memurun yaşı ile memurluk kıdemi arasındaki benzerlik yüksek olabilir. Boyut azaltma algoritması bu iki özelliği tek bir özellikmiş gibi kabul edip öyle davranabilmektedir. Buna makine öğrenmesinde öznitelik çıkarımı denir.


Denetimsiz öğrenme algoritmalarının temel çalışma prensibi veriyi kullanışlı bir halde temsil etmeye dayalıdır. Bu yüzden görselleştirme çok önemlidir. Çok sayıda heterojen verinin oluşturduğu veri setleri ile beslenen modellerde görselleştirme algoritmaları her bir alt kümeyi belirtebilmek için çok boyutlu gösterimler çizerler. Örneğin iki boyutta üst üste gelen iki farklı kümenin gösteriminde üçüncü boyut kümelerin birbirlerinden ayrı gösterimini sağlamaktadır.

Bir diğer denetimsiz öğrenme algoritması anomali tespittir. Normal durumlarca eğitilmiş modelin başka bir örnek gördüğünde bunun normal durumlara benzeyip benzememesine göre anomali tespiti yapabilmektedir. Örnek olarak kredi kartından her zamankinden fazla yapılan alışverişte sistemin bunu algılayıp olağandışı olarak kabul edip kart sahibini uarması gösterilebilir.

Literatürlerde en çok kullanılan denetimsiz öğrenme algoritmalarında K-Ortalamlar (K-Means), PCA ve diğerleri aşağıda gösterilmiştir

K-Ortalamlar yöntemi bir kümeleme algoritması olan denetimsiz bir makine öğrenmesi türüdür. Etiketsiz yani çıktısını bilmediği verileri, kendi aralarında benzetimler yaparak çıktı verebilen bir kümeleme algoritmasıdır. K belirlenen küme sayısını temsil

etmektedir. Veri kümesi içerisinde rastgele K kadar merkez noktası belirlenerek verilerin bu K merkez noktalarına uzaklıkları ölçülür. En kısa mesafe hangi kümeyle ise veri o kümeyle ait olmaktadır. Merkez noktaları rastgele seçildiği için bu işlem birkaç kez tekrarlanmalıdır ki optimal bir değere ulaşılabilsin. Optimal kümeleri bulmaktaki amaç her kümenin elemanlarının birbirine maksimum oranda benzerlik göstermesi ve kümelerin kendi aralarında maksimum uzaklık göstermesidir. Bu uzaklık, verilerin etiketleri bilinmediği için çıktı verirken başarıyı arttırmayı ve sınıflar arası benzerliği azaltmayı temsil etmektedir. K-ortalamlar yönteminde belirlenen K sayıdaki kümelerin elemanları kendi için minimum varyansa sahip olmalıdırlar.




Şekil 6. K-Ortalamlar algoritması çalışma prensibi

K- ortalamlar yönteminde uygun K küme değerini bulmak için iki farklı yöntem bulunmaktadır. Bunlar Dirsek Metodu (Elbow Method) ve Siluet Analizidir (Silhouette Analysis).


Dirsek metodunda etiketsiz verilerin her K küme sayısı için küme merkezine uzaklıklarının karesi toplamı hesaplanmaktadır. Hesaplanan uzaklıklara ve K küme sayısına göre grafik çizilir ve grafikte ani bir azalmanın görüldüğü değer optimal K değerini vermektedir

Siluet analiz yönteminde her K küme sayısına göre farklı bir formül uygulanmaktadır. Buna göre kümelerdeki her elaman için oluşan Siluet katsayısı -1 ile 1 arasında bir değer

almaktadır. 1 değeri o verinin hesaplandığı kümeye ait olduğunu göstermektedir. -1 değeri ise verinin yanlış bir küme ile gruplandığını göstermektedir.



Şekil 7. Yukarıdaki grafikte görüldüğü üzere dirsek metoduna göre bu veri setine en uygun kümeleme




Şekil 8. Silüet Yöntemi

Yukarıdaki grafikte görüldüğü üzere Silüet metoduna göre bu veri setine en uygun kümeleme yöntemi için K değeri Silüet skorunun maksimum olduğu 5 seçilmelidir. Böylelikle optimal K değeri bu veri kümesi için bulunmuş olur

Temel bileşenler analizi (Principal Component Analysis, PCA) yöntemi genelde çok boyuta sahip olan veri kümelerinde gürültüyü azaltma, boyut küçültme gibi nedenlerden dolayı kullanılan bir denetimsiz öğrenme algoritmasıdır. Temel bileşenler analizinde amaç çok boyutlu olan veri kümesini daha sade bir hale getirmektir. Başka bir şekilde ifade etmek istenirse amaç verinin boyutu daraltıldığında ana veriden bilgi kaçağı olmamasını

sağlamaktır. Boyutu yani niteliği azaltılan veriden kayıp olmaması imkânsız olacağı için, bunu veride yer alan daha az önemli niteliklere uygulayabilmek esastır. Bir grafik üzerinden düşünüldüğünde ise çoklu özelliklere sahip karmaşık bir veriye farklı bir açıdan bakabilmek ve veriler arası daha anlamlandırılabilir ayrımlar çıkarabilmek PCA olarak adlandırılmaktadır. Şekil 9’da görüldüğü gibi çok sayıdaki karmaşık bir veri kümesine farklı noktalardan bakmak boyut azaltılmasına neden olmaktadır



Şekil 9. Temel bileşenler analizi i boyuttaki ham veriden, en anlamlı özellikleri olan özünü

Eclat, birliktelik kural çıkarımı tabanlı bir denetimsiz makine öğrenmesi algoritmasıdır. Birliktelik kural çıkarımı, veriler arasındaki benzerlikleri çözerek beraber gerçekleşme olasılıklarını bulan bir yöntemdir. Bu yönetime verilecek en popüler örnek internet üzerinden alışveriş yapılmasını sağlayan online alışveriş sitelerinde, kullanıcıların daha önce aldıkları ya da inceledikleri ürünlere göre önerilerde bulunan sistemler verilebilmektedir. Diğer bir ifadeyle birliktelik kural çıkarımı yöntemi kullanıcıların davranışlarını inceleyip öğrenerek, bir sonraki davranışları hakkında kullanıcılara ya da yukarıdaki örnekte gösterildiği üzere satıcılara hangi ürünlerin beraber satıldığı hakkında önerilerde bulunmaktadır. Birliktelik kural çıkarımı yönteminde iki önemli nokta bulunmaktadır. Bunlar kullanıcılar tarafından başlangıçta belirlene Destek ve Güven faktörleridir.

Eclat algoritması hangi ürünlerin beraber kullanıldığı ya da hangi verilerin birbirine yakın olduğu hakkında kullanıcılara bilgi veren, diğer birliktelik kural çıkarımı algoritması olan Apriori ‘in aksine yatay formatta değil dikey formattaki verilen çalışan bir yöntemdir. Eclat’taki ana veri setindeki sık kullanılan öğeleri bulmaktadır. Buna derin öncelikli arama denilmektedir.

Tablo 1. Yatay Format Tablosu

Sepet ID	Ürünler
1	Elma, muz, portakal
2	Elma, portakal,
3	Muz, karpuz
4	Elma, muz, portakal, karpuz

Tablo 2. Dikey Format Tablosu (TID-list Table)

Ürün	Sepet ID'leri
Elma	1,2,4
Muz	1,3,4
Portakal	1,2,4
Karpuz	3,4

Üstteki tabloda verilen örneği Eclat ile çözmek istediğimizde şu adımların yapılması gerekmektedir: Öncelikle yatay formatta verilen verileri dikey formata çevrilmelidir. Sıklıklarına göre (örneğin ürünlerin sepette bulunma miktarı) numaralandırılan öğelerden, kullanıcının seçtiği minimum destek değerine (minsup) göre elemanlar atılmalıdır. Yukarıdaki Tablo 1 ve Tablo 2 de görüldüğü üzere minsup = 2 ise "karpuz" ürünü dahil edilir. Tek sayıda bir işlem numarası listesi olmadığı için atılan bir öğe olmayacaktır. Saha sonra ikinci adım olarak sepetteki öğelerin ikili kombinasyonları şeklinde sıklıkları bulunacaktır. Bu listeden de tek kalan işlem sıklığının olduğu satır yok edilecektir. Daha sonra öğelerin üçlü kombinasyonları yapılacak ve bu işlem TID sütunundaki tüm sayı değerleri minimum destek değerinden küçük oluncaya kadar devam edecektir. Örneğin minimum destek değeri 2 olarak seçildiğinde, işlem numarası listesindeki değerlerin hepsi 1 olduğunda durmak ve bir önceki adımda elde edilen tablodaki önerilen kombinasyonlar kullanılmaya başlanmaktadır.

Yarı Denetimli Öğrenme

Etiketli ve etiketsiz verilerin bir arada olduğu öğrenim şeklidir. Bu öğrenme şeklinde hem denetimli hem de denetimsiz öğrenme algoritmaları hibrit şekilde çalışır. Genellikle çok sayıda etiketsiz ve az sayıda etiketli verinin bulunduğu karışık verilerle çalışırlar. Etiketli verilerden öğrendikleri hedefleri yani muhtemel sonuçları, etiketsiz verilerdeki kümelerle eşleştirebilirler. Google Photos ve Pinterest gibi uygulamalar yarı denetimli öğrenmeye birer örnektir. Yarı denetimli öğrenmedeki veri gösteriminin farkları Şekil 10'da gösterilmiştir.



Şekil 10. Yarı denetimli öğrenmedeki veri gösteriminin farkları

Pekiştirmeli Öğrenme

Pekiştirmeli Öğrenme (Reinforcement Learning), makine öğrenmesinin bir türü olup çalışma prensibi bakımından denetimli öğrenme ve denetimsiz öğrenmeden farklı olmaktadır. Diğer öğrenme türlerinde olduğu gibi konu giriş verisinin etiketli ya da etiketsiz olmasına göre bunların sınıflandırılması veya benzerlik gösteren verilen en uygun şekilde kümelenmesi değil, çalışma sürecinin ödül ve ceza sistemine göre ardışık şekilde davranış göstermesi üzerine kuruludur. Pekiştirmeli Öğrenmede, ajan adı verilen sistem biriminin sürekli bir öğrenme eylemi içerisinde, doğru bildiği eylemlerden ödül yani pozitif, yanlış yaptığı eylemlerden de ceza yani negatif geribildirim uygulaması sayesinde modelin öğrenmesi pekiştirilmektedir. Bu yüzden Pekiştirmeli Öğrenme adını almaktadır. Bu teknikte ajanın yani sistemin belirlediği eylemler bütününe, yani seçtiği algoritmaya politika denmektedir. Politika, ajanın içinde bulunduğu görevi gerçekleştireceği çevrede karşılaştığı durumlara karşı verdiği cevaplardır. Ajan adı verilen birim nesnel bir varlık olarak değil, eylemleri gerçekleştirip öğrenmeyi sağlayan bir araç olarak kabul edilmektedir. Başlangıçta rastgele olarak belirlenen eylemler, model ödül ve cezalarla eğitildikçe, eğitimin gerçekleştiği çevreye uyum sağlayacak ve mantıklı kararlar vermeye başlayacaktır. Pekiştirmeli Öğrenmede amaç öğrenme işlemi sonrasında sistemin maksimum seviyede ödüle ya da sürekli negatif geribildirim alabileceği durumlar karşısında minimum ceza puanına ulaşmasını sağlamaktır. Ödül ifadesi pekiştirmeli öğrenme sistemlerinde haz, acı kavramları ile ilişkilendirilip olup geri bildirim sinyali olarak görev yapmaktadır. Ajan bu geri bildirimlere göre deneyimlerinden yararlanarak aksiyonlar arasından hangisinin daha olumlu yanıtlar alacağına göre seçim yapabilmektedir. Bazı durumlarda, ajanın karşılaştığı sorunlardan anlık olarak yüksek puan ya da düşük ceza puanına sahip eylemi seçmek yerine tam tersi bir eylem seçilebilmektedir. Bunun sebebi anlık olarak dezavantajlı görünen

eyleme bağılı olan diğer eylemlerin daha yüksek pozitif veya düşük ödül cezalarına sahip olmasından kaynaklanmasındır. Bu pekiştirmeli öğrenmede durum değeri olarak adlandırılmaktadır. Anlık değil olası toplam ödül ya da ceza puanı olarak kabul edilmektedir. Amacı ödülleri eniyilemek olan pekiştirmeli öğrenme sistemlerinde politika seçimi performansı arttırmada çok önemli bir yer tutmaktadır. Görev boyunca olabilecek muhtemel tüm sonuçları karşılayabilecek şekilde dinamik bir politika seçimi ajanın elde edebileceği ödülü eniyilemekte büyük önem taşımaktadır. Pekiştirmeli öğrenme sistemleri model adı verilen çevreden, bağımsız olarak modelsiz olarak da kullanılabilme ve modelin aksine önceden eğitilmeden de performans gösterebilmektedirler Pekiştirmeli öğrenme deneyimin önem arz ettiği deneme yanılma yöntemiyle öğrenmesi açısından masa üstü ve bilgisayar oyunlarında, akıllı ev araç gereçlerinde sıklıkla kullanılmaktadır.

Denetimli ve denetimsiz öğrenmelerin aksine eğitim setinin kullanılmadığı durumlarda görev alan pekiştirmeli öğrenme, ajanların görevi birden çok kez yerine getirip öğrenmesi ile gerçekleştirilmektedir. Bunun sebebi çok sayıda bulunan belirsiz koşul ve alt koşullar sebebi ile ajanın görevi tanıyabilmesidir. Pekiştirmeli öğrenme eğitim veri setinin olmaması yani herhangi bir ön veriye ihtiyaç duymadan karar alması açısından canlıların özellikle hayvanların karar alma ve öğrenme sistemine benzetilmektedir. Karar verme sürecini ve aldığı kararların doğruluğunu arttırabilmek için geliştirilmiş olan bazı pekiştirmeli öğrenme yöntemleri bulunmaktadır. Bunlardan en çok kullanılanı Markov karar süreçleri ve Q-Öğrenme yöntemidir

Richard Bellman tarafından tanımlanan Markov karar süreçleri, pekiştirmeli öğrenme sistemlerinde aksiyomları gerçekleştiren ajanların, bulundukları durumdan bir sonraki duruma geçmeleri için vermeleri gereken kararları matematiksel olarak formüle etmeye yaramaktadır. Markov karar süreçlerine göre t anında S_t durumunda bulunan bir ajanın, S_{t+1} durumuna geçmesi sadece S_t durumuna bağlıdır. Bu kural Markov karar süreçlerinin belleksizliği olarak adlandırılmaktadır çünkü karar verme süreci geçmişteki durumlara değil sadece o andaki (t) duruma bağlıdır. Yaptığı aksiyomlara göre ödül veya ceza alan ve bunu eniyilemeye çalışan ajan için bir sonraki duruma geçmesi, karar vermesi gereken bir veya birden fazla aksiyomun olasılıklarına bağlıdır. (Bellman,1957)

Önceden bilinmeyen stokastik yani rastgele süreçlerde karar alma mekanizması olarak çalışan Markov süreçleri (Markov zincirleri) gelecekteki olası durumları hesaplayabilmek için güncel durumdaki olasılıkları kullanmaktadır. Bu özelliği taşıyan sistemleri diğer bir adı ise Markovyen sistemlerdir. Markovyen sistemleri matematiksel olarak göstermek istersek,

$$P[X_{tn} = x_{tn} | X_{tn-1} = x_{tn-1}, \dots, X_{t1} = x_1] = P[X_{tn-1} = x_{tn-1} | X_{tn-1} = x_{tn-1}]$$

$$(t_1 < t_2 < t_3 \dots) \quad (1.1)$$

Bu teoremi ajanın ve ödülün olduğu bir pekiştirmeli öğrenme sistemine uygulamak istersek aşağıdaki formülü elde edilmiş olur

$$P[S_{t+1} | S_t] = P[S_{t+1} | S_1, S_2, S_3, \dots, S_t] \quad (1.2)$$

Ödül değerinin R ile gösterildiği bir Markov karar süresinde (MKR) toplam ödül değeri sürekli şekilde artmaktadır. Toplam ödül değerini gösteren formül aşağıda gösterildiği gibidir. G toplam ödül değerini temsil etmektedir.

$$G = R_1 + R_2 + R_3 + \dots + R_n \quad (1.3)$$

Bir pekiştirmeli öğrenme modelinde, öğrenen ajan her zaman periyodik sürelerle farklı durumlarla karşılaşmayabilir ya da karşılaşp gerçekleştirdiği aksiyonların ödülleri hemen almayabilir. Bu sistemde, G toplamını sonsuza doğru götürmektedir. Bu durumda görevleri gerçekleştiren ajanların, sistemi yavaşlatacak ödüllere sahip aksiyonları gerçekleştirmemeleri için indirim faktörü denilen (discount factor) bir çarpan belirlenmiştir. Sıfır ile bir arasında bir değer alan “ γ ” ile gösterilen indirim faktöründe, $\gamma = 0$ değeri için ajan uzun vadeye yayılan ödüllendirmelere sahip hareketlerden kaçınacak, $\gamma = 1$ olduğu durumda ise ajanın gelecekte alacağı ödüller daha önemli hale gelecek ve buna göre seçimlerini yapacaktır. İndirim faktörü değeri ödüllerin değerinden bağımsız olan tamamen ajanın gelecekte alacağı ödüller ile ne kadar ilgilenip ilgilenmediğini belirleyen bir değişkendir. İndirim faktörünün eklenmiş olduğu indirim faktörlü toplam ödül değeri aşağıda gösterildiği gibidir.

$$G_t = R_t + \gamma R_{t+1} + \gamma^2 R_{t+2} + \dots = \sum_{k=0}^{\infty} \gamma^k R_{t+k} \quad (1.4)$$

Kısacası bir Markov karar süreci ödül değerine, alınan aksiyona, durum değerine, bu durumları gerçekleştirecek olan aksiyonların gerçekleşme olasılığına ve indirim faktörü değişkenlerine bağlı bir karar alma sürecidir.

Richard Bellman’a göre, alabileceği ödül değerini eniyilemek isteyen bir ajanın aşağıda gösterilen Bellman Optimal Eşitlik Değeri denkleminde uyması gerekmektedir. Bu denklem gelecekte yapacağı aksiyonların hangilerinin kendi için daha yüksek ödül ya da düşük ceza toplam puanına sahip olduğu kararını verirken kullanılmaktadır.

$$Q(s, a) = \sum_{s'} T(s, a, s') (r(s, a, s') + \gamma \sum_{a'} \pi(s', a') Q(s', a')) \quad (1.5)$$

$s_t = t$ anındaki durumu

$s_{t'} = s$ durumundan sonraki durum ($s_{t'} = s_{t+1}$)

$a_t = s_t$ durumundan $s_{t'}$ durumuna geçilmesi için yapılması gerek aksiyon


$$rt = r(st, at, st')$$

$= st$ durumundan st' durumuna geçileince kazanılan ödül ya da ceza

$T(s, a, s') = st$ durumundan st' durumuna geçme olasılığı

$\pi(s, a) =$ ajanın uyguladığı karar verme politikası

Şekil 11’de yer alan Necdet SÜT ve arkadaşlarının gerçekleştirdiği “Sağlık Alanında Karar Vermede Döngüsel Süreçlerin Kullanımı: Bir Markov Model Uygulaması” adlı çalışmada yer alan akut lenfoblastik lösemi (ALL) hastalığında tedavi aşamalarına ilişkin oluşturulan bir Markov karar alma sürecine ait olan zincir gösterilmiştir. Belirtilen sayısal değerler ödül değerleri değil, zincirde yer alan durumlara geçiş olasılıklarıdır. Modelde yer alan geçiş olasılıklarının oluşturduğu geçiş matrisi ve izin verilen geçiş durumları aynı adlı çalışmada detaylı olarak yer almaktadır. (Süt, 2020) (Doğan ve Türkoğlu, 2019).



Şekil 11. Kullanılan Markov modeli

Diğer bir pekiştirmeli öğrenme algoritması Q-Öğrenme algoritmasıdır. Q-Öğrenme algoritması, model oluşturulmadan kullanılan bir algoritmadır. Q-Öğrenme algoritması yapı itibarıyla Richard Sutton’un geliştirdiği Zamansal Fark Öğrenimi (Temporary Difference Learning, TDL) yöntemi ile benzerlik göstermektedir. (Sutton, 1998)

Zamansal fark öğrenimi yönteminde amaç, gelecekte yer alacak olan toplam ödül değerini tahmin etmektir. Zamansal fark öğrenimi yöntemi modele ihtiyaç duymadan geçmiş durumlardan öğrendiği eksik tecrübelerle ajanın son duruma varmasını beklemeden her durumda kendini güncelleyerek sonuç vermesidir. Belirtilen sonuçtan kasıt optimal indirimli durum değeridir. Bütün işlemler başlangıçta rastgele belirlenen bir politika altında gerçekleşmektedir (Nabiyev, 2021)

Q-Öğrenme algoritması, politika dışı zamansal fark öğrenimi olarak kabul edilebilmektedir. Amacı $Q(s, a)$ değerini hesaplamak olan algoritma, bu her t anı için kendini güncellediği için bu değer ortalama hesaplanmaktadır. Bu değer $Q^N(s, a)$ olarak kabul edilmektedir.

$$Q^N(s, a) = \frac{1}{N} \sum_{n=1}^N Q_n(s, a) \quad (1.6)$$

$n = N - 1$ durumu için:

$$Q^N(s, a) = \frac{1}{N} (QN(s, a) + \sum_{n=1}^{N-1} Q_n(s, a)) \quad (1.7)$$

$$Q^N(s, a) = \frac{1}{N} (QN(s, a) + NQN-1(s, a) - QN-1(s, a)) \quad (1.8)$$

$$Q^N(s, a) = QN-1(s, a) + lr(QN(s, a) - QN-1(s, a)) \quad (1.9)$$

Formülde gösterilen lr değeri öğrenme oranı olarak kabul edilmekte ve ortalama değerin hesaplanacağı adım aralığı olmaktadır. N değeri ise öğrenme sürecindeki adım sayısını temsil eder Rastgele olmayan sistemler için Bellman Optimal Eşitlik Değeri denklemi uyarlanmak istenirse aşağıdaki denklem elde edilmektedir.

$$Q(s, a) = r(s, a, s') + \gamma \max_{a'} Q(s', a') \quad (1.10)$$


(1.10) numaralı denklemde yerine koyulursa Q-öğrenme algoritmasında optimal olarak indirimli durum değeri fonksiyonu şu hale gelmektedir.

$$Q^N(s, a) = QN-1(s, a) + lr(r(s, a, s') + \gamma \max_{a'} Q(s', a') - QN-1(s, a)) \quad (1.11)$$

Bu denklem N sayıdaki her karar alma sürecinde tekrarlanacak ve güncellenecektir.


1.2.2. Yapay Sinir Ağları

Yapay sinir ağları, insan beyin yapısını taklit eden interaktif nöron kümeleri ile inşa edilmiştir. Bu sistemler, insanların temel özelliklerinden biri olan öğrenme kabiliyetine sahip olarak tasarlanmıştır. Her bir işlem birimi, diğerleriyle ağırlık değerleri üzerinden ilişkilendirilmiştir. Öğrenme süreci, bu ağırlık değerlerinin, veri setine bağlı olarak sistemin kendini ayarlamasıyla gerçekleşir. Nihayetinde, bu ağırlıkların düzenlenmesi yoluyla, ağın yeni veri durumlarını tanıyıp öğrenmesi mümkün hale gelir (Elmas, 2018).



Şekil 12. Yapay sinir ağı topolajisi

Şekil 3’ de görüldüğü gibi bir yapay sinir ağı, giriş katmanı, gizli katmanlar ve çıkış katmanlarından oluşur. Giriş katmanında girdiler alınır. Bu girdiler, işlenecek nesnenin öz nitelikleri veya başka bir ağın çıktıları olabilir. Gizli katman girdiden alınan değerleri belirli ağırlıklarda çarparak karşılar. Ağırlıklandırılmış girdiler bir aktivasyon fonksiyonundan geçirilerek çıkışa aktarılır. Aktivasyon fonksiyonunun sonucunda anlamlı sonuçlar çıktı katmanına aktarılır. Çıktı katmanı nihai sonuç veya bir başka ağın girdisi olabilir. Şekil 13’de verilen model incelendiğinde X girişleri W ağırlıklarıyla çarpılarak toplam fonksiyonundan geçirilmektedir. Elde edilen toplam $F(Net)$ transfer fonksiyonuyla çıkışa aktarılmaktadır (Murat, 2021).



Şekil 13. Bir sinir hücresinin matematiksel modeli

1.2.3. Derin Öğrenme


Derin öğrenme (DL); onlarca hatta yüzlerce katmandan oluşan hesaplama modelidir. Bu katmanlar arasında hesaplamalar ve soyutlamalarla veri temsilleri öğrenilir. Bu temsiller aracılığıyla yeni durumlara uygun sonuçlar tahmin edilebilir. Derin öğrenme, görüntü işleme, nesne tanıma, hastalık tespiti, dil işleme, karar verme gibi alanlardaki gelişmeleri ivmelendirmiştir. Derin öğrenme, büyük veri kümeleriyle çalışır. Verilerin temsillerini

oluşturmak ve sonucu tahmin etmek için karmaşık hesaplamalarla ve geri yayılım algoritmalarıyla ağırlıkları biçimlendirir (LeCun, vd., 2015).

Klasik makine öğrenmesi algoritmalarında, modelin başarısı için veri kümesinin önceden belirlenmiş ve el ile tasarlanmış özelliklere dönüştürülmesine olan ihtiyacı, önemli bir sınırlama oluşturmaktadır. Bu durum, hem veri hazırlama sürecini zorlaştırmakta hem de modelin karmaşık ilişkileri ve soyut kavramları öğrenme yeteneğini kısıtlamaktadır. Derin öğrenme ise bu zorluğun üstesinden gelerek, veri temsili öğrenimini otomatikleştirmeye ve modelin doğrudan ham verilerden öğrenmesine imkan tanımaktadır (LeCun, vd., 2015).

Derin öğrenme, ardışık katman dizilimlerinin oluşturduğu derin yapıları ifade eder. Bu terim, çok katmanlı yapay sinir ağlarını ve derin sinir ağlarını tanımlamak için kullanılır. Yapay sinir ağları, ileri beslemeli, geri beslemeli ve çok katmanlı sinir ağları gibi çeşitli dönüşümlerden geçerek evrimleşmiştir. Evrişimli Sinir Ağları (CNN), geniş çapta tanınan ve kullanılan sinir ağlarından biridir ve bu ismini, matrisler arasında gerçekleşen ‘evrişim’ isimli matematiksel operasyondan alır. CNN’ler, birbiriyle bağlantılı çok sayıda katmandan meydana gelir; bu katmanlar arasında doğrusal olmayan katmanlar, evrişim katmanları ve havuzlama katmanları bulunur. Bu katmanlar, öğrenme sürecinde farklı işlevler üstlenerek verinin karmaşık özelliklerini çıkarır (LeCun ve ark., 2015).

Sınıflandırma problemlerinde, Evrişimli Sinir Ağları (CNN) tarafından üretilen çıktılar, girdinin ait olduğu kategorileri temsil eder. CNN’lerin eğitim süreci, genellikle yoğun zaman ve kaynak gerektiren bir faaliyettir. Ancak, eğitim sonrasında gerçekleştirilen tahmin işlemi, görece daha hızlıdır ve daha az kaynak kullanımı ile mümkündür. CNN’ler ile Yapay Sinir Ağları (YSA) arasındaki temel farklılıklar, Şekil 14’te görselleştirilmiştir. Görselde açıkça görüldüğü üzere, YSA’lar giriş, çıkış ve bu iki katman arasında yer alan gizli katmanlardan meydana gelirken; CNN’ler, ardışık sıralanan çok sayıda katmandan oluşur ve bu katmanlar arasında evrişim ve havuzlama gibi işlemler yer alır.



Şekil 14. Yapay Sinir Ağı (üstte), Evrişimli Sinir Ağı (altta) farklı topolojileri


Yapay zekâ ile ilgili kavramlar arasındaki ilişki Şekil 15’de gösterildiği gibi ifade edilebilir; yani makine öğrenmesi yapay zekânın bir alt dalıdır. Yapay sinir ağları ise makine öğrenmesinin bir sınıfı olarak kabul edilebilir. YSA, CNN’nin daha basit halidir. YSA, zamanla geliştirilerek CNN oluşturulmuştur. Derin öğrenme, yapay zekâ kavramı altında ele alınabilir. Derin öğrenme YSA ve CNN yapılarından oluşturulmuştur. Makine öğrenmesi Derin öğrenmeye göre daha temel bir kavramdır (LeCun, vd., 2015).



Şekil 15. Yapay zekâ kavramlarının gösterimi

1.3. Derin Öğrenme Katmanları

Geleneksel makine öğrenimi metodolojileri genellikle lineer bir yapıya sahiptir; buna karşın, derin öğrenme metodları, incelenen problemin özelliklerine uygun olarak farklılaşabilen çok katmanlı ve dinamik süreçlerden oluşur. Bu ileri düzey öğrenme teknikleri Şekil 16'da gösterildiği gibi veri ön işleme, boyut indirgeme, nitelik tespiti ve sınıflandırma gibi evreleri kapsamlı bir şekilde entegre ederler ve bu sayede karmaşık veri yapılarını modelleyebilirler.




Şekil 16. Evrişimli Sinir Ağı genel mimarisi

Evrişimli Sinir Ağları temel yapısı itibarıyla derin öğrenme mimarileri arasında yer alır ve ses işleme gibi çeşitli disiplinlerde uygulanabilir olmasına karşın, esas olarak görüntü işleme, görüntü tabanlı sınıflandırma ve desen tanıma gibi alanlarda ün kazanmıştır.


Giriş Katmanı: CNN mimarisinin başlangıç noktasını oluşturur ve ham verilerin yer aldığı katmandır. Bu katmana sağlanan giriş verilerinin, ağın genel yapısına uygun olarak seçilmesi büyük önem taşır. Eğer giriş veri boyutları fazla büyük belirlenirse, bu durum eğitim ve test süreçlerinde gereken kaynak miktarını artırabilir. Öte yandan, veri boyutlarının çok küçük tutulması, ağın performansını olumsuz yönde etkileyebilir. Dolayısıyla, giriş verilerinin optimizasyonu, ağın genel çıktı kalitesi için kritik bir öneme sahiptir.

Evrişim Katmanı: Evrişim, karmaşıklığı azaltmak amacıyla başvurulmuş matematiksel bir operasyondur. Bu katman, giriş katmanından alınan verilere, özellikleri belirginleştirmek için küçük filtreler uygular ve sonuç olarak özellik haritaları oluşturur. Bu prosedür, Şekil 17'de gösterildiği üzere, orijinal giriş verisine kıyasla daha az boyutlu matrislerin üretilmesini sağlar.




Şekil 17. Evrişim işlemi

Aktivasyon Katmanı: Yapay sinir ağlarına paralel olarak, CNN'ler de aktivasyon fonksiyonlarından yararlanır. Aktivasyon süreci, giriş sinyalleri üzerinde uygulanan doğrusal olmayan bir dönüşümü temsil eder. Genelde YSA'larda sigmoid fonksiyonu aktivasyon için tercih edilirken, CNN mimarilerinde daha çok düzeltilmiş doğrusal birimler olan ReLU (Rectified Linear Units) kullanılır. ReLU fonksiyonu, $h(y)=\max(0,y)$ şeklinde matematiksel olarak ifade edilir. ReLU'nun aktivasyon fonksiyonu ve onun türevinin grafiği, genellikle literatürde Şekil 18'deki gibi gösterilir.




Şekil 18. ReLU fonksiyonu(kırmızı) ve türevinin(mavi) grafiği

Havuzlama Katmanı: Havuzlama katmanının temel amacı, giriş verisinin boyutlarını azaltmaktır. Bu işlem, çeşitli filtre aracılığıyla (örneğin maksimum, minimum, ortalama gibi) gerçekleştirilir. Havuzlama işlemi sırasında, bazı veri kayıpları kaçınılmazdır. Bu kayıplar, modelin sonuç performansını olumsuz yönde etkileyebilir. Ancak, havuzlama katmanı aynı zamanda modelin aşırı uyum (overfitting) sorununu minimize ederek genelleme yeteneğini artırır. Havuzlama katmanında kullanılan filtre adım büyüklüğü, modelin ihtiyaçlarına göre ayarlanabilir (LeCun et al., 2015). Şekil 19'da gösterilen maksimum havuzlama örneğinde, 4x4'lük bir matris, 2x2'lik bir filtre kullanılarak havuzlanmakta ve her bir 4x4'lük bölgeden en yüksek değerler seçilerek daha küçük bir matris elde edilmektedir. Ortalama havuzlama yönteminde ise, 2x2'lik bölgelerin ortalamaları alınarak yeni ve daha küçük boyutlu bir matris oluşturulur.



Şekil 19. Havuzlama katmanı gösterimi


Tam Bağlantılı Katman: Evrişimli sinir ağlarının mimarisinde, konvolüsyonel, ReLU ve havuzlama katmanlarını takiben tam bağlantılı (fully connected) katmanlar bulunur. Bu katmanda yer alan nöronlar, lineer bir dizilim gösterir ve önceki katmanlardaki tüm nöronlarla bağlantılıdır. Bu yapı, ağın sınıflandırma performansını iyileştirmek için önceki katmanlardan elde edilen özelliklerin ağırlıklarını optimize etme işlevi görür. Ağırlıkların bu optimizasyonu sayesinde, öne çıkan özellikler temel alınarak sınıf tahminleri gerçekleştirilebilir.



Şekil 20. Tam bağlı katman yapısı


Seyreltme Katmanı: Çok katmanlı yapay sinir ağlarında, modelin aşırı uyum sorununu hafifletmek amacıyla seyreltme katmanı kullanılır. Bu katman, belirlenen bir eşik değeri aracılığıyla, önemsiz veya düşük etkili bilgilerin ihmal edilmesini sağlar. Sonuç olarak, modelin aşırı uyum yapmasının önüne geçilir. Seyreltme işlemi, nöronların veya

bağlantıların seçici bir şekilde devre dışı bırakılması yoluyla, ya da her iki yöntemin bir kombinasyonu olarak uygulanabilir.



Şekil 21. Seyrelme katmanı sonrası bağlantı şekli

Sınıflandırma Katmanı: Derin öğrenme mimarilerinde, sınıflandırma sürecinin gerçekleştiği katman, sınıflandırma katmanıdır. Bu katmanın çıktısı, sınıfların sayısına karşılık gelen bir vektör biçimindedir ve her bir eleman, ilgili sınıfın tahmini olasılığını temsil eder. Her bir nesne için, sınıfların sayısı kadar 0 ile 1 arasında bir değer dizisi elde edilir. Bu değerlerden en yüksek olanı, nesnenin ait olduğu sınıfı gösterir. Sınıflandırma katmanında, genellikle yüksek başarı oranları nedeniyle softmax aktivasyon fonksiyonu kullanılır. Şekil 13'te, katmana verilen girdi değerlerine softmax fonksiyonu uygulanmakta ve çıktı olarak her bir sınıf için olasılık değerleri sunulmaktadır. Bu değerler 0 ile 1 arasında olup, 1'e yaklaşan değer, ilgili nesnenin ait olduğu sınıfı belirtir.




Şekil 22. Sınıflandırma katmanı işlevi

1.4. Derin Öğrenme Modelleri


Derin öğrenme, nesne tanıma gibi görevlerdeki üstün performansı ile bilim dünyasında adından söz ettirmeye başlamıştır. Bu alanda, LeCun'un öncülük ettiği LeNet modeli ile

başlayarak, birçok yenilikçi derin öğrenme mimarisi geliştirilmiştir. Özellikle 2012 ImageNet yarışmasında gösterdiği başarı ile AlexNet, derin öğrenme alanının tekrar ilgi odağı olmasını sağlamıştır. İlerleyen zamanlarda, çeşitli mimariler tasarlanmış ve bu mimariler, bilgisayarlı görme alanında artan başarılar elde etmiştir. Şekil 14, bu önemli derin öğrenme mimarilerinin gelişim sürecini kronolojik olarak sunmaktadır. AlexNet'in 2012'deki başarısı, bu alandaki bir dönüm noktası olarak kabul edilmektedir.




Şekil 23. Derin öğrenme mimarilerinden bazıları

Derin öğrenme modelleri, zamanla daha fazla katman eklenerek geliştirilmiştir. Algılama mekanizmaları gelişmiş ve bu sayede performansları artırılmıştır. Son yıllarda, çapasız algılayıcılar ve otomatik makine öğrenimi (AutoML) mimarilerine olan ilgi belirgin bir şekilde artmıştır. Yann LeCun ve ekibi tarafından 1998 yılında geliştirilen LeNet, ilk başarılı Evrişimli Sinir Ağı (CNN) olarak tanınmaktadır. Bu ağ, 0'dan 9'a kadar olan rakamların görüntülerini sınıflandırmak için kullanılmıştır ve çıkış katmanı on sınıf içermektedir. Ağ, giriş olarak 32x32 piksel boyutunda, toplam 1024 parametre almakta ve yedi katmandan oluşmaktadır. Bu gelişmeler, derin öğrenme alanındaki yeniliklerin sürekli bir evrim içinde olduğunu göstermektedir. (Lecun ,Bottou, Bengio, ve Haffner, 1998)




Şekil 24. LeNet mimarisi

AlexNet, Krizhevsky ve ekibinin geliştirdiği bir derin öğrenme mimarisidir ve 2012 yılında ImageNet görsel tanıma yarışmasında birincilik elde etmiştir. Bu model, örüntü tanıma alanındaki hata oranını %15 seviyelerine indirerek, derin öğrenme tabanlı görüntü tanıma uygulamalarının yaygınlaşmasına öncülük etmiştir. AlexNet mimarisi, beş evrişimli katman, havuzlama katmanları ve üç tam bağlı katman içermekte olup, bu yapısal özellikleriyle dikkat çekmektedir. Bu başarı, derin öğrenme mimarilerinin potansiyelini ve görüntü tanıma görevlerindeki etkinliğini kanıtlamıştır.



Şekil 25. AlexNet Mimarisi

AlexNet'in ImageNet yarışmasında elde ettiği çığır açan başarı sonrasında, derin öğrenme algoritmaları benzer yarışmalarda giderek daha fazla tercih edilmiş ve her seferinde öncekilerden daha ileri düzeyde sonuçlar ortaya konmuştur. Zeiler ve Fergus tarafından geliştirilen ZF Net modeli, 2013 yılında gerçekleştirilen yarışmada %11,2'lik hata oranı ile zirveye yerleşmiştir. Bu modelde, AlexNet modelinin ilk katmanlarında kullanılan 11x11 boyutundaki filtreler, 7x7 boyutuna indirgenmiştir. Bunun yanı sıra, havuzlama katmanında iki adımlık bir kaydırma işlemi uygulanarak modelin performansı artırılmıştır.



Şekil 26. ZF Net Mimarisi


2014 yılında ImageNet yarışmasında VggNet, %7,3 gibi dikkate değer bir hata oranı ile liderliği elde etmiştir. Oxford Üniversitesi'ndeki bilim insanları tarafından geliştirilen bu ağ, 11'den 19'a kadar değişen konvolüsyon katman sayılarına sahip altı farklı yapıyı

içermektedir. Bu yapılar arasında, özellikle vgg-16 ve vgg-19 mimarileri literatürde geniş yer bulmuştur. VggNet'in yanı sıra, GoogleNet, ResNet, DenseNet ve Yolo gibi birçok farklı derin öğrenme mimarisi de geliştirilmiştir. Bu mimariler, nesne algılama gibi uygulamalarda halen en tercih edilen yöntemler arasında yer almaktadır ve sürekli olarak geliştirilmeye devam etmektedirler.

RNN (Recurrent Neural Network), geri beslemeli sinir ağı anlamına gelir ve zaman serisi verilerini veya dizisel verileri modellemek için kullanılan bir tür yapay sinir ağıdır. Bidirectional Long Short-Term Memory (BiLSTM) ağları, özellikle sıralı veri tahmin görevleri için uygun olan bir tür tekrarlayan sinir ağı (RNN) mimarisidir. Geleneksel RNN'ler, uzun vadeli bağımlılıkları öğrenme konusunda zorluk yaşar ve bu nedenle kaybolan gradyan sorunuyla karşılaşır. LSTM ağları, bu sorunu çözmek için bellek hücrelerini kullanır ve bu hücreler uzun sekanslar boyunca bilgiyi koruyabilir.

LSTM ağları, hücre durumu ve üç tür kapı içerir: giriş kapısı, unutma kapısı ve çıkış kapısı. Bu kapılar, hücre durumuna bilgi akışını düzenler ve ağı önemli bilgileri korumasına ve gereksiz ayrıntıları unutmasına olanak tanır. Hücre durumu, LSTM'lerin uzun vadeli bağımlılıkları hatırlama yeteneğinin anahtarıdır. Kapılar tarafından düzenlenir ve dizinin tamamı boyunca bilgi taşır. Giriş kapısı, yeni bilginin hücre durumuna ne kadarının eklenmesi gerektiğini kontrol eder. Unutma kapısı, önceki hücre durumunun ne kadarının unutulması gerektiğine karar verir. Çıkış kapısı, hücre durumundan ne kadar bilginin çıkış olarak verilmesi gerektiğine karar verir.

BiLSTM ağları, her zaman diliminde hem ileri hem de geri yönde çalışır, bu sayede model, her iki yönden de bağlam bilgisi alabilir. Bu, özellikle bağlamın her iki yönde de önemli olduğu doğal dil işleme gibi görevler için faydalıdır. BiLSTM'ler, LSTM katmanlarını hem ileri hem de geri yönde çalışacak şekilde düzenleyerek daha zengin ve daha kapsamlı bir bilgi temsili sağlar. Bu çift yönlü bilgi akışı, metin sınıflandırma, konuşma tanıma ve biyoinformatik gibi çeşitli alanlarda önemli performans iyileştirmeleri sunar.



Şekil 27. BiLSTM Mimarisi

BiLSTM'ler, ileri ve geri yönde çalışan iki LSTM katmanının birleşiminden oluşur. Bu yapı, hem geçmiş hem de gelecek bağlam bilgisini kullanarak daha kapsamlı bir bilgi temsili sağlar. İlk katman, giriş kelimeleri veya özellikleri daha düşük boyutlu vektörlere dönüştüren gömme katmanıdır. Bu katman, her kelimenin anlamını temsil eden vektörleri öğrenir ve bu vektörler, BiLSTM katmanlarına giriş olarak kullanılır. İleri LSTM katmanı, diziyi soldan sağa doğru işler ve her zaman adımında, önceki adımların bilgisini kullanarak bir çıktı üretir. Geri LSTM katmanı ise diziyi sağdan sola doğru işler

ve gelecekteki adımların bilgisini kullanarak bir çıktı üretir. İleri ve geri yönlü LSTM katmanlarının çıktıları birleştirilir, bu birleştirme işlemi, her zaman adımı için iki yönlü bağlam bilgisini bir araya getirir. Bu yapı, her zaman adımı için hem geçmiş hem de gelecek bilgileri hesaba kattığı için, özellikle dil modeli görevleri, konuşma tanıma ve zaman serisi analizi gibi bağlamın her iki yönden de önemli olduğu durumlarda etkili sonuçlar verir. BiLSTM'ler, standart LSTM'lerin sağladığı avantajları iki yönlü bilgi akışı ile birleştirerek daha güçlü ve esnek modeller oluşturur.

1.5. Görüntü İşleme ve Bilgisayar Görmesi

Bilgisayarlı görü insan görme sisteminin makineler tarafından otonom hale getirilmesi olarak tanımlanabilir İnsanlar görme eylemini rahatlıkla yapabilirler. Örneğin bir tabloya baktığımızda orada var olan nesneleri rahatlıkla ayırt edebiliriz ve sayabiliriz. Ancak görme eylemini gerçekleştirmek makineler için bu kadar basit değildir Bilgisayar görmesi, dijital görüntülerden üst düzey anlamlar çıkarmayı amaçlayan disiplinler arası bilimsel alandır. Bilgisayarlı görü günümüzde; hastalık tespiti, uzay çalışmaları, ergonomi, biyoloji, savunma

sanayi, malzeme, otomasyon, elektronik tüketici ürünleri, siber güvenlik, güvenlik, trafik denetimi ve benzeri birçok alanda yaygın olarak kullanılmaktadır (Kurtulmuş, 2012).

Bir görüntü iki boyutlu bir $f(x, y)$ fonksiyonu olarak tanımlanabilir. f fonksiyonunun herhangi bir (x, y) koordinatındaki genliği görüntünün o noktadaki yeğinliği olarak ifade dileyebilir. Yeğnlik değerinin sonlu ve ayrık olduğu durumda görüntüyü sayısal görüntü olarak isimlendirebiliriz. Dolayısıyla sayısal görüntü sonlu sayıda bileşenden oluşur. Her bileşene piksel adı verilir (Kurtulmuş, 2012).

Görüntü işleme ve bilgisayarlı görü kavramlarının sınırları tam olarak ayrılmamıştır. Tanım olarak görüntü işleme; ölçülmüş veya kaydedilmiş sayısal görüntü verilerinin, elektronik ortamda bilgisayar veya yazılımlar aracılığıyla amaca uygun hale getirilmesi [67], şeklinde ifade edilebilir. Görüntü işleme görüntünün niteliğini artırmayı amaçlar. Görüntü üzerinde daha üst düzey işlemler yapabilmek için ön düzenlemeleri kapsar.

Nesne tespiti görüntü içindeki nesnenin belirginleştirilerek zeminden ayırt edilmesidir. Bu aşamada nesnenin konumu da belirlenmiş olur. Görüntüde aranacak nesne hakkında ön bilgi varsa kayan pencere kullanarak eşleştirme yapılır. Eğer yoksa nesneye ait renk, yoğunluk, eğilim, doku, hareket vb. nitelikler aranır

Bilgisayarlı görü çalışmaları için birçok yazılım mevcuttur. Bunlar içinde hem ticari hem de araştırma geliştirme için kullanılan OpenCV göze çarpmaktadır. OpenCV birden çok programlama dilinde uygulama geliştirmeye imkân verir. VLFeat yerel özellik çıkarma, görüntü anlama ve eşleştirme konusunda uzaman bir çerçeve olarak tanıtılmıştır. MATLAB ile çalışabilir ve c ile yazılmıştır MATLAB platformu görüntü işleme için araçlar sunmaktadır. Performansın önemsenmediği özellikle bilimsel çalışmalarda tercih edilmektedir. MATLAB içinde OpenCV araçlarını kullanmak mümkündür.

1.6. Derin Öğrenme İle Akciğer Seslerinin Yüksek Doğrulukla Sınıflandırılması İle Alakalı Çalışmalar

Modern tıbbi uygulamalarda, teşhis süreci esas olarak görsel ve işitsel verilerin analizine dayanmaktadır. Tıp profesyonelleri, çeşitli teknikler kullanarak bu verilere ulaşabilirler ve bu veriler sıklıkla görüntü veya ses formatında temsil edilir. Solunum esnasında akciğerler tarafından üretilen hava akımının ses sinyalleri, solunum yollarının durumu hakkında kritik bilgiler sağlar. Oskültasyon, hekimlerin stetoskop aracılığıyla hastaların akciğerlerini dinleyerek hastalıkları teşhis etmelerini sağlayan klasik bir yöntemdir.

Bu prosedür, herhangi bir advers reaksiyon veya yan etki teşkil etmez. Prosedürün etkinliği ve doğruluğu, doktorun insan vücudu tarafından üretilen normal ve patolojik sesleri tanıma kapasitesine bağlıdır. Ne var ki, akciğer sesleri değişken sinyaller olduğundan, oskültasyon ile bu seslerin analiz edilmesi zorluklar içerir. Bu nedenle, oskültasyon metodunun desen tanıma sistemleri ile entegrasyonu, daha belirgin ve doğru klinik teşhisler elde etmek için yararlı olabilir.

Akciğer auskültasyonu sırasında, solunum sesleri iki ana kategori altında incelenebilir: normal vesiküler sesler ve patolojik adventisyöz sesler. Eğer bir solunum patolojisi mevcut değilse, vesiküler sesler net bir şekilde algılanır; ancak patolojik bir durum söz konusu olduğunda, bu normal seslere ek olarak adventisyöz sesler duyulabilir. Vesiküler seslerin değerlendirilmesinde, trakeal, bronşial ve bronkoveziküler seslerin karakteristik özellikleri dikkate alınmalıdır. Bu seslerin inspirasyon fazları, ekspirasyon fazlarına kıyasla daha uzun sürelidir. Normal vesiküler sesler, genellikle 100 ila 1000 Hz frekans aralığında yer alır ve bu ses spektrumunda belirgin pikler gözlemlenmez. Patolojik solunum sesleri ise, sürekli ve kesikli olmak üzere iki farklı türde ortaya çıkabilir ve bu sesler, normal solunum seslerine ek olarak tespit edilir.

Solunum sesleri, ek olarak tespit edilen seslerle birlikte, sürekli ve kesikli olmak üzere iki ana kategoriye ayrılır. Sürekli sesler, hırıltıya benzer niteliktedir ve genellikle 100 Hz üzerinde bir frekans spektrumuna sahiptirler. Bu sesler, 100 ms üzerindeki periyodlarla tekrar eden dalga formasyonlarına yol açar. Örneğin, Rhonchi olarak bilinen sürekli sesler, yaklaşık 200 Hz veya daha düşük bir frekansla tanımlanır. Hırıltı sesleri, obstrüktif akciğer rahatsızlıklarının yaygın bir göstergesi olup, astım, pnömoni ve bronşit gibi hastalıklarla ilişkilendirilir. Diğer yandan, tıkrıtı sesleri kesikli solunum sesleri kategorisine girer ve kardiyovasküler bozukluklarda daha sık rastlanır. Bunların süresi 20 ms'den kısa olup, frekans içeriği genellikle daha geniştir. Akademik literatür, çeşitli akciğer sesi kategorilerini tanımlar.

Demir ve arkadaşları (2019), akciğer ses sinyallerini analiz etmek için öncelikle zaman-frekans dönüşümü kullanarak spektrogram görüntüleri elde etmişlerdir. Sınıflandırma sürecinde, iki farklı derin öğrenme modeli test edilmiştir. İlk modelde, özellik çıkarma işlemi için önceden eğitilmiş bir CNN derin öğrenme modeli ve sınıflandırma için DVM algoritması tercih edilmiştir. İkinci model ise, aynı CNN modelini kullanarak transfer öğrenme tekniğini uygulamıştır. Her iki yöntemin performansı, on katlı çapraz doğrulama

metodu ile değerlendirilmiş ve elde edilen doğruluk oranları sırasıyla %65,5 ve %63,09 olarak kaydedilmiştir.

Kochetov ve arkadaşları (2018) tarafından yayımlanan çalışmada, solunum seslerini analiz ederek sınıflandırmak amacıyla geliştirilen yenilikçi bir modelin detayları sunulmuştur. Bu model, gelişmiş gürültü azaltma teknikleri ve tekrarlayan sinir ağları kullanarak, solunum seslerini temiz bir biçimde izole etme yeteneğine sahiptir. Elde edilen özellikler, dört farklı kategoriye ayrılmış veri setindeki örnekleri doğru bir şekilde sınıflandırmak için kullanılmıştır. Model, geniş kapsamlı bir açık erişim veri setinde değerlendirilmiş ve %65,7 oranında bir başarı oranı göstermiştir. İlgili literatürdeki diğer çalışmalar Tablo 3'te özetlenmiştir.

Tablo 3. Literatürdeki Diğer Çalışmalar

Yazar	Amaç/Yöntem	Sonuç
İçer ve Gengeç (2014)	Normal ve anormal akciğer seslerini sınıflandırmak için güç spektral yoğunluk değerlerinin frekans oranını ve Hilbert-Huang Dönüşümü (HHD) özelliklerini kullandılar	Sınıflandırıcı olarak Destek Vektör Makineleri (DVM) kullanılmıştır ve %90'ın üzerinde doğruluk elde edilmiştir
Naves ve ark. (2016)	Akciğer seslerinin sınıflandırılması için K-NN ve Bayes sınıflandırıcıları tercih etmişlerdir	Kullanılan veri setinde beş tip akciğer sesi bulunmaktadır. Genetik algoritmalar ve Fisher doğrusal ayırıcı özellik azaltmak için kullanılmıştır. Sınıflandırıcı doğruluğu ortalama olarak %98,1'dir
Serbes ve ark. (2013)	Zaman frekansı ve zaman ölçeği (TS) analizini önermektedir. Özellik çıkarma adımı, zaman frekansı ve zaman ölçeği analizi kullanılmıştır	Ön işleme için, çitirtı bilgisi içermeyen frekans bantlarını çıkarmak amacıyla Çift ağaçlı karmaşık dalgacık dönüşümü (Dual-tree complex wavelet transform - DTCWT) uygulanmıştır. Sınıflandırma adımı, çitirtı ve çitirtı olmayan sesleri sınıflandırmak için K-En Yakın Komşular (K-NN), DVM ve Yapay Sinir Ağları (YSA) kullanılmıştır. En iyi sınıflandırma sonucu %97,5 olarak DVM'den elde edilmiştir

Tablo 3'ün devamı

Jin ve Sattar (2014), [□]	Solunum seslerini sınıflandırmak için DVM kullanmışlardır. [□]	Sinyallerden anlık basıklık (kurtosis), ayırma fonksiyonu (diskriminant fonksiyon) ve entropi gibi özellikler çıkarılarak optimal olarak %97,7 ile %98,8 arasında sınıflandırma doğruluğu elde edilmiştir [10]. Bahoura (2009), iki sınıftan oluşan akciğer solunum [□]
Bahoura (2009), [□]	iki sınıftan oluşan akciğer solunum seslerinin sınıflandırılması için farklı bir yaklaşım önermiştir. [□]	Sinyallerden Mel-frekanslı cepstral katsayıları (MFCC) çıkarılmıştır ve özellik kümesi olarak kullanılmıştır. Sınıflandırmak için ise Gauss Karışım Modeli kullanılmıştır ve %94,2 sınıflandırma başarımı elde edilmiştir [□]
Orjuela ve ark. (2014), [□]	Normal, üfürüm ve çırtı solunum seslerini sınıflandırmak için YSA ile birlikte MFCC özelliklerini kullanmışlardır [□]	Sınıflandırma başarımı çırtı solunum seslerinde %75, üfürüm solunumlarında %100 ve normal solunum seslerinde ise %80 olarak hesaplanmıştır [□]
Maruf ve ark. (2015) [□]	Gauss Karışım Modeli'ni kullanarak çırtı solunum seslerinin normal solunum seslerinden ayrılması ve sınıflandırılması için bir yöntem önermişlerdir [□]	Bu çalışma dört adımdan oluşmaktadır. Bu adımlar ön işleme, özellik çıkarma, özellik seçme ve sınıflandırma şeklindedir. Ön işleme adımı, arka plan gürültüsü azaltımı için bir bant geçiren filtre kullanılmıştır ve daha sonra enerji ve spektrogram gibi özellikler çıkarılmıştır. Özellik seçme adımından sonra, nihai özellikler Gauss Karışım Modeli kullanılarak eğitilmiştir. Çalışmadan elde edilen genel doğruluk %97,56'dır [□]

2. YÖNTEM


2.1 Veri Seti

Solunum sistemi hastalıklarının erken teşhisi, hastaların yaşam kalitesini artırmak ve ölüm oranlarını azaltmak açısından kritik bir rol oynar. Geleneksel yöntemlerde, doktorlar stetoskop kullanarak hastaların akciğer seslerini dinler ve bu seslere dayanarak tanı koyarlar. Ancak bu yöntem subjektif olup, tecrübeye dayalıdır ve doğruluk oranı kişiden kişiye değişebilir. Yapay zeka ve makine öğrenmesi tekniklerinin sağlık alanında kullanımıyla birlikte, akciğer seslerinin objektif bir şekilde analiz edilmesi ve sınıflandırılması mümkün hale gelmiştir.

Bu çalışma, farklı filtre türleriyle kaydedilmiş ve çeşitli akciğer hastalıklarına sahip hastalardan alınmış ses dosyalarını kullanarak, akciğer seslerinin otomatik sınıflandırılmasını hedeflemektedir.

2.2 Veri Setinin Oluşumu

Bu çalışma için kullanılan veri seti, farklı filtre türleriyle kaydedilmiş ve çeşitli akciğer hastalıklarına sahip hastalardan alınmış ses dosyalarından oluşmaktadır. Her bir ses dosyası, belirli filtre tiplerine, hasta numaralarına ve uzman tarafından konulan tanılara göre kodlanmıştır. Ses dosyaları, göğüs duvarının farklı noktalarından kaydedilmiştir. Bu ses dosyaları, .wav formatında olup, veri seti bu dosyaların bir kombinasyonundan oluşmaktadır. Her ses dosyası, belirli bilgileri içerecek şekilde adlandırılmıştır. Filtre türü, kullanılan filtre tipi olup, Bell 20-200Hz, Diyafram 100-500Hz ve Genişletilmiş aralık 50-500Hz frekans aralıklarında seslerin kaydedilmesini sağlar ve farklı ses özelliklerinin yakalanmasına olanak tanır. Hasta numarası, P1'den P112'ye kadar numaralandırılmış hasta numarası olup, her bir hasta için tekil bir numara atanmış ve bu numara hastaların ayırt edilmesini sağlar. Ses tipi, solunum seslerinin tipi olup; crackles, wheezes, normal ve crepitations ses tiplerini kapsar. Tanı, uzman tarafından konulan tanı olup, astım, KOAH, bronşit, kalp yetmezliği ve akciğer fibrozisi gibi hastalıkları belirtir. Kaydedildiği konum, göğüs duvarının hangi noktasından kaydedildiği olup, posterior, alt, sağ, üst, ön ve orta konumları içerir. Bu bilgiler, dosya adlarında kodlanarak saklanmış ve analiz için kullanılmıştır.




Şekil 28. Üç filtre ve spektrogram kullanılarak kaydedilmiş 19 saniyelik solunum sesleri

Örneğin, "B_P1_C_Asthma_P.wav" dosya adı, Bell filtre tipiyle kaydedilmiş, P1 numaralı hastadan alınmış crackles ses tipini, astım tanısını ve posterior konumdan kaydedildiğini belirtir. Bu sistematik adlandırma, ses dosyalarının kolayca tanımlanmasını ve doğru analiz edilmesini sağlar.

2.3 Veri Hazırlama Süreci

Veri hazırlama süreci, ses dosyalarının okunması, özelliklerin çıkarılması ve veri artırma işlemlerini içerir. İlk olarak, tüm ses dosyaları belirtilen dizinden okunur. Her bir ses dosyası için, dosya adlarından tanı bilgileri çıkarılır ve ses özellikleri elde edilir. Bu özellik çıkarma işlemi için librosa kütüphanesi kullanılmıştır. Elde edilen MFCC özellikleri, modelin girdi vektörlerini oluşturur. MFCC (Mel-Frekans Kepstral Katsayıları), ses sinyallerinin en yaygın kullanılan özelliklerinden biridir. İnsan kulağının algılama şekline benzer bir şekilde ses frekanslarını analiz eder. Bu çalışmada, her ses dosyasından 40 MFCC özelliği çıkarılmıştır. librosa kütüphanesi kullanılarak gerçekleştirilen bu işlemde, her ses dosyası için belirli adımlar izlenmiştir.




Şekil 29. MFCC Yapısı

İlk adım, ses dosyasının yüklenmesi ve örnekleme oranının belirlenmesidir. Bu adımda, ses sinyali dijital olarak işlenir ve analiz için hazır hale getirilir. İkinci adım, mel-frekans spektrumunun hesaplanmasıdır. Bu spektrum, ses sinyalinin frekans bileşenlerini ortaya çıkarır ve insan kulağının algıladığı frekans aralıklarına daha uygun bir şekilde temsil edilir. Üçüncü adım, mel-frekans spektrumundan kepsral katsayılarının elde edilmesidir. Bu katsayılar, sesin frekans içeriğini ve zamanla nasıl değiştiğini temsil eder. Çıkarılan özellikler, her bir ses dosyası için özellik vektörlerini oluşturur. Bu vektörler, modelin girdi verisi olarak kullanılır. Bu aşama, ses verisinin analitik model tarafından işlenebilir hale getirilmesi için kritiktir.


2.4 Veri Artırma

Veri artırma, modelin genel performansını artırmak ve aşırı öğrenme riskini azaltmak için kullanılan bir tekniktir. Bu çalışmada, veri setini zenginleştirmek amacıyla iki temel veri artırma yöntemi uygulanmıştır. İlk yöntem, pitch shift olarak bilinen ton kaydırma işlemidir. Bu yöntem, ses dosyasının tonunu belirli bir adım sayısı ile değiştirir. Ses sinyalinin frekansını artırarak veya azaltarak, farklı tonlarda aynı ses sinyalini üretir. Örneğin, bir ses sinyali iki yarım ton yukarı kaydırılarak farklı bir ton elde edilir. Bu teknik, modelin farklı tonlarda aynı hastalık sesini tanıma yeteneğini artırır.



Şekil 30. Pitch Shift

İkinci yöntem, time stretch olarak bilinen zaman uzatma işlemidir. Bu yöntem, ses dosyasının hızını belirli bir oranla değiştirir. Ses sinyalinin hızını artırarak veya azaltarak, farklı hızlarda aynı ses sinyalini üretir. Örneğin, bir ses sinyali %20 oranında yavaşlatılarak daha uzun bir süreye yayılır. Bu teknik, modelin farklı hızlarda aynı hastalık sesini tanıma yeteneğini artırır. Bu işlemler, her bir ses dosyası için ayrı ayrı uygulanmış ve elde edilen yeni özellikler orijinal veri setine eklenmiştir.



Şekil 31. Time Stretch

Bu sayede, modelin eğitim verisi çeşitlendirilmiş ve daha geniş bir veri seti elde edilmiştir. Veri artırma teknikleri, modelin genelleme yeteneğini artırarak, gerçek dünya verileri üzerinde daha iyi performans göstermesini sağlar.

2.5 Özelliklerin Eşitlenmesi

Ses dosyalarının uzunlukları farklı olabileceğinden, özellik vektörlerinin boyutları eşitlenmiştir. En uzun özellik dizisinin uzunluğu belirlenmiş ve diğer tüm özellik vektörleri bu uzunluğa göre doldurulmuştur. Bu işlem, tüm özellik vektörlerinin aynı boyutta olmasını sağlar ve modelin bu veriler üzerinde tutarlı bir şekilde çalışmasını sağlar. Özellik vektörlerinin boyutlarını eşitlemek için genellikle sıfır dolgu (zero padding) kullanılır. Bu,

daha kısa özellik vektörlerinin sonuna sıfır ekleyerek uzunluklarını artırır ve tüm vektörlerin aynı boyutta olmasını sağlar.

2.6 Eğitim ve Test Setlerine Ayırma

Hazırlanan özellik vektörleri ve etiketler, eğitim ve test setlerine ayrılmıştır. Eğitim ve test setleri, %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Eğitim ve test setleri için etiketler LabelEncoder kullanılarak kodlanmış ve kategorik formata dönüştürülmüştür. Bu adımlar, modelin eğitim sürecinde ve performans değerlendirmesinde kullanılacak veri setlerinin hazırlanmasını sağlar. Eğitim seti, modelin öğrenmesi için kullanılırken, test seti modelin genelleme yeteneğini değerlendirmek için kullanılır.

2.7 Modelin Oluşturulması ve Eğitimi

Bu çalışmada, çift yönlü LSTM (BiLSTM) katmanları içeren bir derin öğrenme modeli kullanılmıştır. Model, ileri ve geri yönde çalışan LSTM katmanlarından oluşmakta ve her iki yönden de bağlam bilgisi alınmaktadır. BiLSTM'ler, standart LSTM'lerin sağladığı avantajları iki yönlü bilgi akışı ile birleştirerek daha güçlü ve esnek modeller oluşturur. Modelin yapısı, diziyi hem ileri hem de geri yönde işleyerek bağlam bilgisini yakalar ve giriş dizisinin tamamı hakkında daha zengin bilgi sağlar.

Dropout katmanları, aşırı öğrenmeyi önlemek için kullanılır ve her eğitim adımında belirli bir oranda nöron rastgele kapatılarak modelin daha genel özellikler öğrenmesi sağlanır. İlk dropout katmanı, ilk BiLSTM katmanının ardından eklenmiştir. BatchNormalization katmanları, her mini-batch'in ortalamasını sıfır ve standart sapmasını bir olacak şekilde normalleştirir. Bu işlem, modelin daha hızlı ve stabil öğrenmesini sağlar. İlk BatchNormalization katmanı, ilk dropout katmanının ardından gelir. İkinci BiLSTM katmanı, ilk katmanın çıktısını işleyerek daha derin özellikler çıkarır ve hem ileri hem de geri yönde çalışarak bağlam bilgisini daha da zenginleştirir. İkinci dropout katmanı, aşırı öğrenmeyi önlemek için ikinci BiLSTM katmanının ardından eklenmiştir.

İkinci BatchNormalization katmanı, modelin daha derin katmanlarda da stabil ve hızlı öğrenmesini sağlamak için kullanılır. Son katman, sınıf sayısı kadar birim içerir ve softmax aktivasyon fonksiyonunu kullanarak her sınıf için olasılık dağılımı üretir. Bu katman, modelin çıktısını belirler ve hangi sınıfa ait olduğunu tahmin eder. Model, kategorik çapraz entropi kaybı ve Adam optimizasyon algoritması kullanılarak eğitilmiştir. Kategorik çapraz entropi kaybı, sınıflandırma problemlerinde yaygın olarak kullanılır ve her sınıfın doğru

tahmin edilip edilmediğini ölçer. Adam optimizasyon algoritması ise öğrenme oranını dinamik olarak ayarlayarak, modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlar.

En iyi modelin saklanması için ModelCheckpoint geri çağırımı kullanılmıştır. Bu geri çağırım, her epoch sonunda doğrulama seti üzerinde modelin performansını değerlendirir ve en düşük doğrulama kaybına sahip modeli saklar. Modelin hiperparametreleri arasında, LSTM katmanlarının birim sayısı (32 ve 64 birim), dropout oranları (%50), BatchNormalization kullanımı, eğitim epoch sayısı (225 epoch), batch boyutu (32) ve kernel düzenleyicisi (L2 düzenleyici ile 0.01) yer almaktadır. Bu hiperparametreler, modelin performansını optimize etmek ve aşırı öğrenmeyi önlemek için dikkatlice seçilmiştir. Bu yapılandırma, modelin solunum sesi verilerini etkili bir şekilde işlemesini ve hastalık sınıflandırma görevini başarıyla yerine getirmesini sağlar.

2.8 Modelin Değerlendirilmesi

Modelin performansı, eğitim ve test setleri kullanılarak değerlendirilmiştir. Eğitim süreci boyunca, eğitim ve doğrulama doğruluğunu izlemek için eğitim ve doğrulama veri setleri üzerinde model eğitilmiştir. Eğitim tamamlandıktan sonra modelin performansı, test veri seti üzerinde doğruluk ve doğrulama doğruluğu metrikleri kullanılarak değerlendirilmiştir. Elde edilen doğruluk değerleri ve eğitim süreci boyunca elde edilen doğrulama doğruluğu grafikleri analiz edilmiştir. Modelin başarısı, sağlık profesyonellerine tanı sürecinde yardımcı olabilecek ve hasta bakımında önemli bir ilerleme sağlayabilecek niteliktedir.

Eğitim sürecinde modelin doğruluğu, modelin eğitim veri setindeki performansını yansıtırken, doğrulama doğruluğu modelin doğrulama veri setindeki performansını yansıtır. Bu iki metrik, modelin öğrenme sürecini ve eğitim sırasında karşılaştığı zorlukları görsel olarak temsil eder. Doğruluk, modelin doğru tahmin ettiği örneklerin toplam örneklere oranını gösterir ve genel performansı ölçmek için kullanılır. Eğitim ve doğrulama doğruluğu grafikleri, modelin aşırı öğrenme (overfitting) veya az öğrenme (underfitting) problemlerini tanımlamaya yardımcı olabilir.

Bu çalışmada, doğruluk ve doğrulama doğruluğu değerleri, modelin akciğer hastalıklarını doğru bir şekilde sınıflandırma yeteneğini göstermektedir. Modelin yüksek doğruluk değerleri, sağlık profesyonellerinin hastalıkları daha hızlı ve doğru bir şekilde teşhis etmesine yardımcı olabilir. Bu da, hastaların daha hızlı tedavi almasını ve yaşam

kalitelerinin artmasını sağlar. Ayrıca, bu tür bir sistemin kullanımı, sağlık hizmetlerinde verimliliği artırabilir ve kaynakların daha etkili kullanılmasını sağlayabilir.


Bu çalışma, solunum sistemi hastalıklarının erken teşhisinde kullanılabilecek güvenilir ve etkili bir sistem geliştirmeyi amaçlamaktadır. Farklı filtre türleriyle kaydedilmiş ve çeşitli akciğer hastalıklarına sahip hastalardan alınmış ses dosyalarını kullanarak, akciğer seslerinin otomatik sınıflandırılmasını sağlamıştır. Veri artırma teknikleri ve BiLSTM katmanları kullanılarak elde edilen model, solunum sistemi hastalıklarının tanısında önemli bir araç olarak kullanılabilir. Bu çalışmanın bulguları, sağlık profesyonellerine tanı sürecinde yardımcı olabilir ve hasta bakımında önemli bir ilerleme sağlayabilir. Bu sistem, solunum sistemi hastalıklarının erken teşhisinde büyük bir potansiyele sahiptir. Modelin doğruluğu ve genelleme yeteneği, sağlık profesyonellerinin hastalıkları daha hızlı ve doğru bir şekilde teşhis etmesine yardımcı olabilir. Bu da, hastaların daha hızlı tedavi almasını ve yaşam kalitelerinin artmasını sağlar. Ayrıca, bu tür bir sistemin kullanımı, sağlık hizmetlerinde verimliliği artırabilir ve kaynakların daha etkili kullanılmasını sağlayabilir. Gelecekte, bu çalışmanın bulguları, daha geniş ve çeşitli veri setleri üzerinde test edilerek ve optimize edilerek geliştirilebilir. Ayrıca, farklı makine öğrenmesi ve derin öğrenme algoritmaları kullanılarak modelin performansı daha da artırılabilir. Bu tür gelişmeler, sağlık hizmetlerinde yapay zeka kullanımının daha yaygın hale gelmesine ve hastalık teşhisinde daha yüksek doğruluk oranlarına ulaşılmasına katkı sağlayabilir. Bu çalışmanın sonuçları, solunum sistemi hastalıklarının teşhisinde yapay zeka ve makine öğrenmesinin potansiyelini göstermektedir. Bu alandaki ilerlemeler, hastaların yaşam kalitesini artırabilir ve sağlık hizmetlerinin genel etkinliğini artırabilir. Bu nedenle, bu tür çalışmaların devam ettirilmesi ve genişletilmesi büyük önem taşımaktadır. Bu çalışmanın amacı, solunum sistemi hastalıklarının erken teşhisinde kullanılabilecek güvenilir ve etkili bir sistem geliştirmektir. Farklı filtre türleriyle kaydedilmiş ve çeşitli akciğer hastalıklarına sahip hastalardan alınmış ses dosyalarını kullanarak, akciğer seslerinin otomatik sınıflandırılmasını sağlamıştır. Veri artırma teknikleri ve BiLSTM katmanları kullanılarak elde edilen model, solunum sistemi hastalıklarının tanısında önemli bir araç olarak kullanılabilir. Bu çalışmanın bulguları, sağlık profesyonellerine tanı sürecinde yardımcı olabilir ve hasta bakımında önemli bir ilerleme sağlayabilir. Bu sistem, solunum sistemi hastalıklarının erken teşhisinde büyük bir potansiyele sahiptir. Modelin doğruluğu ve genelleme yeteneği, sağlık profesyonellerinin hastalıkları daha hızlı ve doğru bir şekilde teşhis etmesine yardımcı olabilir. Bu da, hastaların daha hızlı tedavi almasını ve yaşam kalitelerinin artmasını sağlar. Ayrıca, bu tür bir sistemin

kullanımı, sađlık hizmetlerinde verimliliđi artırabilir ve kaynakların daha etkili kullanılmasını sađlayabilir. Gelecekte, bu alıřmanın bulguları, daha geniř ve eřitli veri setleri üzerinde test edilerek ve optimize edilerek geliřtirilebilir. Ayrıca, farklı makine ğrenmesi ve derin ğrenme algoritmaları kullanılarak modelin performansı daha da artırılabilir. Bu tür geliřmeler, sađlık hizmetlerinde yapay zeka kullanımının daha yaygın hale gelmesine ve hastalık teřhisinde daha yüksek dođruluk oranlarına ulařılmasına katkı sađlayabilir. Bu alıřmanın sonuçları, solunum sistemi hastalıklarının teřhisinde yapay zeka ve makine ğrenmesinin potansiyelini göstermektedir. Bu alandaki ilerlemeler, hastaların yařam kalitesini artırabilir ve sađlık hizmetlerinin genel etkinliđini artırabilir. Bu nedenle, bu tür alıřmaların devam ettirilmesi ve geniřletilmesi büyük önem tařımaktadır. Bu alıřmanın amacı, solunum sistemi hastalıklarının erken teřhisinde kullanılacak güvenilir ve etkili bir sistem geliřtirmektir. Farklı filtre türleriyle kaydedilmiř ve eřitli akciđer hastalıklarına sahip hastalardan alınmiř ses dosyalarını kullanarak, akciđer seslerinin otomatik sınıflandırılmasını sađlamıřtır.


3. BULGULAR

Bu çalışmada geliştirilen model, akciğer hastalıklarının tanısında kullanılmak üzere çeşitli solunum seslerini otomatik olarak sınıflandırmak amacıyla eğitilmiştir. Modelin performansı, eğitim ve doğrulama doğruluğu metrikleri kullanılarak değerlendirilmiştir. Eğitim süreci boyunca, modelin hem eğitim hem de doğrulama veri setleri üzerindeki doğruluk değerleri sürekli olarak izlenmiştir. Eğitim tamamlandıktan sonra, modelin test veri seti üzerindeki performansı, genel doğruluk ve doğrulama doğruluğu değerleri kullanılarak analiz edilmiştir.

Elde edilen sonuçlar, modelin yüksek doğruluk oranlarına ulaştığını göstermektedir. Eğitim doğruluğu, modelin eğitim veri seti üzerindeki performansını yansıtırken, doğrulama doğruluğu modelin doğrulama veri seti üzerindeki performansını yansıtmaktadır. Bu metrikler, modelin öğrenme sürecinin etkinliğini ve genel performansını değerlendirmek için kullanılmıştır. Eğitim süreci boyunca elde edilen doğruluk ve doğrulama doğruluğu grafikleri, modelin aşırı öğrenme veya az öğrenme gibi problemler yaşamadığını ve istikrarlı bir şekilde öğrenmeye devam ettiğini göstermiştir.



Şekil 32. Training ve Validation Accuracy (Eğitim ve Doğrulama Doğruluğu) Grafiği



Şekil 33. Karmaşıklık Matrisi

Şekil 32’de görüldüğü üzere, eğitim doğruluğu ve doğrulama doğruluğu zamanla artmış ve yaklaşık %99.25 oranında doğruluğa ulaşmıştır. Bu yüksek doğruluk oranı, modelin solunum seslerini doğru bir şekilde sınıflandırma yeteneğini açıkça ortaya koymaktadır. Eğitim sürecinin başlarında doğruluk hızla artmış, ardından daha dengeli bir şekilde artış göstermiş ve son aşamada yüksek bir doğruluk seviyesine ulaşmıştır. Doğrulama doğruluğu da benzer bir trend izlemiş ve modelin genelleme yeteneğinin yüksek olduğunu göstermiştir.

Şekil 33’deki karmaşıklık matrisinde modelin genel olarak oldukça yüksek doğruluk oranına sahip görünüyor. Ancak, bir yanlış sınıflandırma durumu mevcut: Bir adet Wheezes (Hırıltı) örneği yanlış bir şekilde Normal olarak tahmin edilmiştir.

Bu çalışmanın bulguları, sağlık profesyonellerine solunum sistemi hastalıklarının tanısında yardımcı olabilecek güvenilir bir araç sunmaktadır. Modelin yüksek doğruluk oranları, hastalıkların daha hızlı ve doğru bir şekilde teşhis edilmesini sağlayarak, hastaların daha erken tedavi almasına ve yaşam kalitelerinin artmasına katkıda bulunabilir. Ayrıca, bu tür bir sistemin sağlık hizmetlerinde kullanımı, verimliliği artırabilir ve sağlık kaynaklarının daha etkili kullanılmasını sağlayabilir.


4. SONUÇ TARTIŞMA VE ÖNERİLER

Bu çalışma, akciğer seslerinin otomatik olarak sınıflandırılmasında derin öğrenme modellerinin etkinliğini göstermektedir. Kullanılan BiLSTM tabanlı model, yüksek doğruluk oranlarıyla solunum sesi verilerini başarılı bir şekilde sınıflandırmıştır. Bu başarının ardında yatan temel faktörlerden biri, modelin ileri ve geri yönde çalışan LSTM katmanlarıyla donatılmasıdır. Bu yapı, modelin her iki yönden de bağlam bilgisini kullanarak daha kapsamlı ve zengin bilgi temsilleri oluşturmasını sağlamıştır. Modelde kullanılan parametreler Tablo 4 'te görüldüğü üzere yüksek doğruluk oranı elde etmek amacıyla parametre değerleriyle birlikte gösterilmiştir. Yapılan çalışmada bu değerlerle birlikte %99.25 doğruluk oranı elde edilmiştir.


Tablo 4. BiLSTM modelde kullanılan parametre ve değerleri

Modelde Kullanılan Parametre	Parametre Değeri
LSTM katman birim sayısı	32 ve 64 bit
Dropout oranı	%50
Eğitim epoch sayısı	225
Batch Boyutu	32
Kernel düzenleyici	L2 düzenleyici ile 0.01

Modelin performansını artıran bir diğer önemli faktör ise veri artırma tekniklerinin kullanılmasıdır. Pitch shift ve zaman uzatma gibi teknikler, orijinal veri setini çeşitlendirerek modelin daha fazla veriyle eğitilmesini sağlamış ve genelleme yeteneğini artırmıştır. Bu sayede, model yeni ve görülmemiş veriler üzerinde de yüksek doğruluk oranlarına ulaşabilmiştir. Modelin performansını ve doğruluğunu artırmak için ayrıca zero padding sıkça kullanılan bir tekniktir. Bir diğer yöntem olan reflect padding ise verinin başındaki veya sonundaki değerlerin ters çevirerek ekler ve bu yöntem, verinin uç noktalarındaki özellikleri korur, ancak işlem süresi açısından daha maliyetlidir. Modelde ayrı ayrı kullanılara elde edilen zero padding ve reflect paddinge ait sonuçlar Şekil 33 ve Şekil 34'te gösterilmiştir.



Şekil 34. Reflect padding



Şekil 35. Zero Padding

Reflect Padding Ve Zero Padding'in karşılaştırılmasına ilişkin elde edilen sonuçlar;
Reflect Padding (Şekil 34)

Avantajlar:

- Daha Düzgün ve Dengeli Performans: Yansıma doldurma ile elde edilen doğruluk değerleri daha dengeli ve düzgün bir seyir izliyor. Eğitim ve doğrulama doğrulukları arasında büyük farklar yok.
- Genel Eğilim: Grafikte genel bir yükselme eğilimi gözleniyor. Bu, modelin daha kararlı bir şekilde öğrenme sağladığını gösterir.

- Daha Yüksek Doğruluk: Reflect padding kullanılarak modelin doğruluğu daha yüksek olabilir, çünkü veri orijinal dağılımına daha yakın hale gelir.

Dezavantajlar:

- Dalgalanmalar: Yine de bazı dalgalanmalar ve ani düşüşler gözlemlenebilir. Bu, eğitim sürecinde bazı epoch'larda overfitting veya underfitting yaşandığını gösterebilir.

Zero Padding (Şekil 35)

Avantajlar:

- Daha Az Dalgalanma: Zero padding ile elde edilen doğruluk grafiği daha az dalgalanma gösteriyor. Eğitim ve doğrulama doğrulukları daha stabil bir şekilde artıyor.
- Konsolide Öğrenme: Eğitim doğruluğu ve doğrulama doğruluğu arasındaki farklar daha az, bu da modelin daha iyi genelleme yaptığını gösterebilir.

Dezavantajlar:

- Sınırlı Performans: Zero padding, özelliklerin belirli bir uzunluğa kadar doldurulması anlamına gelir ve bu da veri setinin orijinal yapısını bozabilir. Bu nedenle, modelin performansı yansıma doldurmaya göre biraz daha düşük olabilir.
- Daha Az Gerçekçi Veri: Zero padding, orijinal veri dağılımını korumaz, bu nedenle model gerçek dünya verilerine karşı daha az uyum sağlayabilir.

Karşılaştırma Sonucu:

- Performans ve Kararlılık: Reflect padding, genel olarak daha yüksek doğruluk ve dengeli bir öğrenme süreci sağlar. Ancak, bu yöntemde daha fazla dalgalanma olabilir.
- Veri Dağılımının Korunması: Reflect padding, verinin orijinal dağılımını koruduğu için daha gerçekçi sonuçlar verebilir.
- Stabil Öğrenme: Zero padding, daha stabil bir öğrenme süreci sağlar ancak modelin genelleme yeteneği ve doğruluğu reflect padding'e göre daha düşük olabilir.

Sonuç olarak, bu çalışmada geliştirilen model, solunum sistemi hastalıklarının erken teşhisinde kullanılabilecek güvenilir ve etkili bir sistem olarak önemli bir potansiyele sahiptir. Modelin doğruluk ve doğrulama doğruluğu değerleri, sağlık profesyonellerine tanı sürecinde yardımcı olabilir ve hasta bakımında önemli bir ilerleme sağlayabilir. Bu bulgular,

sağlık hizmetlerinde yapay zeka ve derin öğrenme tekniklerinin daha yaygın bir şekilde kullanılması gerektiğini ve bu alanda yapılacak çalışmaların devam etmesi gerektiğini vurgulamaktadır.



5. KAYNAKLAR

- Adachi, W., N. Tsujiuchi, T. Koizumi, K. Shiojima, Y. Tsuchiya, ve Y. Inoue. (2012). Calculation of joint reaction force and joint moments using by wearable walking analysis system, içinde 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, ss. 507–510. doi:
- Albawi, S., T. A. Mohammed, ve S. Al-Zawi. (2017). Understanding of a convolutional neural network, içinde 2017 International Conference on Engineering and Technology (ICET), c. 2018-Janua, ss. 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- Bahoura, M. “Pattern recognition methods applied to respiratory sounds classification into normal and wheeze classes.,” Comput. Biol. Med., vol. 39, no. 9, pp. 824–843, Sep. 2009, doi: 10.1016/j.combiomed.2009.06.011.
- Bahoura, Mohammed. "Pattern recognition methods applied to respiratory sounds classification into normal and wheeze classes." Computers in biology and medicine 39.9 (2009): 824-843.
- Chambres, G. Hanna, P. and Desainte-Catherine, M. “Automatic Detection of Patient with Respiratory Diseases Using Lung Sound Analysis,” 2018 International Conference on ContentBased Multimedia Indexing (CBMI). IEEE, 2018, doi: 10.1109/cbmi.2018.8516489
- Chang G.-C. and Y.-P. Cheng, “Investigation of noise effect on lung sound recognition,” 2008 International Conference on Machine Learning and Cybernetics. IEEE, 2008, doi: 10.1109/icmlc.2008.4620605.
- Chollet, F. (2017). Deep Learning with Phyton, 1st ed. Shelter Island, NY: Manning.
- Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
- Demir, F. Sengur, A. and Bajaj, V. “Convolutional neural networks based efficient approach for classification of lung diseases,” Heal. Inf. Sci. Syst., vol. 8, no. 1, p. 4, Dec. 2019, doi: 10.1007/s13755-019-0091-3.
- Doğan, F. ve İ. Türkoğlu. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, DÜMF Mühendislik Derg., c. 10, sayı 2, ss. 409 445, doi: 10.24012/dumf.411130.
- Dramsch, J. S. (2020). 70 years of machine learning in geoscience in review, içinde Advances in Geophysics, c. 61, Moseley,B. ve L. Krischer, Ed. Elsevier, ss. 1–55. doi: 10.1016/bs.agph.2020.08.002.
- Elmas, Ç. (2018). Yapay Zeka Uygulamaları, 4. baskı. Ankara: Seçkin Yayıncılık.

- Elshaw, R., A. Wahab, A. Barnawi, ve S. Sakr. (2021). DLBench: a comprehensive experimental evaluation of deep learning frameworks, *Cluster Comput.*, c. 24, sayı 3, ss. 2017–2038, doi: 10.1007/s10586-021-03240-4.
- Er M. B. and Çiğ, H. “Türk Müziği Uyarınları Kullanılarak İnsan Duygularının Makine Öğrenmesi Yöntemi İle Tanınması,” *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 8, no. 2, pp. 458–474, 2020, doi: 10.29109/gujsc.687199.
- Er M.B. and Aydılek, I. B. “Music emotion recognition by using chroma spectrogram and deep visual features,” *Int. J. Comput. Intell. Syst.*, vol. 12, no. 2, 2019, doi: 10.2991/ijcis.d.191216.001.
- Er, M.B. "Akciğer Seslerinin Derin Öğrenme ile Sınıflandırılması." *Gazi University Journal of Science Part C: Design and Technology* 8.4 (2020): 830-844.
- Fu Y. and Aldrich, C. “Flotation froth image recognition with convolutional neural networks,” *Miner. Eng.*, vol. 132, pp. 183–190, 2019, doi: 10.1016/j.mineng.2018.12.011.
- Gogul, I. ve V. S. Kumar. (2017). Flower species recognition system using convolution neural networks and transfer learning, içinde 2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN), ss. 1–6. doi: 10.1109/ICSCN.2017.8085675.
- Islam, Mohammad Safiqul, et al. "Lung cancer risk in relation to nicotinic acetylcholine receptor, CYP2A6 and CYP1A1 genotypes in the Bangladeshi population." *Clinica Chimica Acta* 416 (2013): 11-19.
- İçer S. and Gengeç, Ş. “Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds,” *Digit. Signal Process.*, vol. 28, pp. 18–27, 2014, doi: 10.1016/j.dsp.2014.02.001.
- İnik, Ö. ve E. Ülker. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilim. Araştırma Derg.*, c. 6, sayı 3, ss. 85–104.
- Jin, F. Sattar, F. and Goh, D. Y. T. “New approaches for spectro-temporal feature extraction with applications to respiratory sound classification,” *Neurocomputing*, vol. 123, pp. 362–371, 2014, doi: 10.1016/j.neucom.2013.07.033
- Kandaswamy, A. Kumar, C. S. Ramanathan, R. P. Jayaraman, S. and Malmurugan, N. “Neural classification of lung sounds using wavelet coefficients,” *Comput. Biol. Med.*, vol. 34, no. 6, pp. 523–537, 2004, doi: [https://doi.org/10.1016/S0010-4825\(03\)00092-1](https://doi.org/10.1016/S0010-4825(03)00092-1).
- Lecun, Y., L. Bottou, Y. Bengio, ve P. Haffner. (1998). Gradient-based learning applied to document recognition, *Proc. IEEE*, c. 86, sayı 11, ss. 2278–2324, doi: 10.1109/5.726791.

- LeCun, Y., Y. Bengio, ve G. Hinton. (2015). Deep learning, *Nature*, c. 521, sayı 7553, ss. 436–444, doi: 10.1038/nature14539.
- Lee Yun, et al. "In vitro antimicrobial susceptibility of *Mycoplasma hyorhinis* field isolates collected from swine lung specimens in Korea." *Journal of Swine Health and Production* 22.4 (2014): 193-196.
- Min, C., J. Xu, L. Xiao, D. Zhao, Y. Nie, ve B. Dai. (2021). Attentional Graph Neural Network for Parking-Slot Detection, *IEEE Robot. Autom. Lett.*, c. 6, sayı 2, ss. 3445–3450, doi: 10.1109/LRA.2021.3064270.
- Murat, S. (2021). İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma (Yüksek Lisans Tezi), Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Nabiyev, N. ve S. Malekzadeh. (2021). Anomalous Sound Localization Estimation. doi: <https://doi.org/10.13140/RG.2.2.25949.95201>.
- Nabiyev, V. V. (2021). *Yapay Zeka* (6. baskı), Ankara: Seçkin Yayıncılık.
- Naves, R. Barbosa, B. H. G. and Ferreira, D. D. "Classification of lung sounds using higher-order statistics: A divide-and-conquer approach," *Comput. Methods Programs Biomed.*, vol. 129, pp. 12–20, 2016, doi: 10.1016/j.cmpb.2016.02.013.
- Orjuela-Cañón, Alvaro D., Diego F. Gómez-Cajas, and Robinson Jiménez-Moreno. "Artificial neural networks for acoustic lung signals classification." *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 19th Iberoamerican Congress, CIARP 2014, Puerto Vallarta, Mexico, November 2-5, 2014. Proceedings 19*. Springer International Publishing, 2014.
- Öztemel, E. (2003). *Yapay sinir ağları*, 3. baskı. İstanbul: Papatya Yayıncılık.
- Reichert, S. Gass, R. Brandt, C. and Andrès, E. "Analysis of respiratory sounds: state of the art," *Clin. Med. Circ. Respirat. Pulm. Med.*, vol. 2, pp. 45–58, May 2008, doi: 10.4137/ccrpm.s530
- Rocha B. M. et al., "An open access database for the evaluation of respiratory sound classification algorithms," *Physiol. Meas.*, vol. 40, no. 3, p. 35001, 2019, doi: 10.1088/1361-6579/ab03ea.
- Serbes, G. Sakar, C. O. Kahya, Y. P. and Aydin, N. "Pulmonary crackle detection using time–frequency and time–scale analysis," *Digit. Signal Process.*, vol. 23, no. 3, pp. 1012–1021, 2013, doi: <https://doi.org/10.1016/j.dsp.2012.12.009>.
- Serbes, G. Ulukaya, S. and Kahya, Y. P. "An Automated Lung Sound Preprocessing and Classification System Based On Spectral Analysis Methods," *Precision Medicine Powered by pHealth and Connected Health*. Springer Singapore, pp. 45–49, 2017, doi: 10.1007/978-981-10-7419-6_8.

- Serbes, Gorkem, and Nizamettin Aydin. "Modified dual tree complex wavelet transform for processing quadrature signals." *Biomedical Signal Processing and Control* 6.3 (2011): 301-306.
- Serbes, Gorkem, et al. "Pulmonary crackle detection using time–frequency and time–scale analysis." *Digital Signal Processing* 23.3 (2013): 1012-1021.
- Sovijärvi A. et al., “Characteristic of breath sounds and adventitious respiratory sounds,” *Charact. Breath Sounds Adventitious Respir. Sounds*, vol. 10, pp. 591–596, Jan. 2000.
- Ulukaya, S. Serbes, G. Şen, İ. and Kahya, Y. P. “Akciğer Solunum Seslerinin Spektral Öznitelikler ile Sınıflandırılması,” *Süleyman Demirel Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 22, no. 2, p. 711, 2017, doi: 10.19113/sdufbed.84471.
- URL-1. (2024, Nisan 15). Data Augmentation Techniques for Audio Data in Python. Towards Data Science. Bu kaynağa şu adresten ulaşılmıştır: <https://towardsdatascience.com/data-augmentation-techniques-for-audio-data-in-python-15505483c63c>
- URL-2. (2024, Nisan 21). BiLSTM. Papers With Code. Bu kaynağa şu adresten ulaşılmıştır: <https://paperswithcode.com/method/bilstm>
- URL-3. (2024, Nisan 26). A Dataset for Detecting and Mitigating Moral Ethical Issues in Texts. ScienceDirect. Bu kaynağa şu adresten ulaşılmıştır: https://www.sciencedirect.com/science/article/pii/S2352340921001979?ref=pdf_download&fr=RR-2&rr=88a7b4a6cae65177
- URL-4. (2024, Mayıs 1). Bidirectional vs Unidirectional LSTM. Baeldung. Bu kaynağa şu adresten ulaşılmıştır: <https://www.baeldung.com/cs/bidirectional-vs-unidirectional-lstm>
- Wu, X., D. Sahoo, ve S. C. H. Hoi. (2020). Recent advances in deep learning for object Neurocomputing, c. 396, ss. 39–64, doi: 10.1016/j.neucom.2020.01.085.
- Yani, M., M. T. Budhi Irawan, S. Si., ve M. T. Casi Setiningsih, S.T. (2019). Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry’s Nail, *J. Phys. Conf. Ser.*, c. 1201, sayı 1, s.012052, doi: 10.1088/1742-6596/1201/1/012052.

ÖZGEÇMİŞ

Elektrik-Elektronik Mühendisi Ayşenur BAKAY, ilköğrenimini Bahçelievler İlkokulu'nda, Liseyi Balakgazi Lisesi'nde tamamladı. Ayşenur BAKAY, 2013 yılında Fırat Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümünü kazandı. 2018 yılında “Elektrik-Elektronik Mühendisi” unvanı ile lisans eğitimini tamamladı. 2020 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında yüksek lisans öğrenimine başladı. 2021 yılında kendi alanında Elektrik Dağıtım Şirketinde göreve başladı ve başladığı görevde halen devam etmekte.

