

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKÂ VE ROBOTİK ANABİLİM DALI

**DERİN ÖĞRENME MİMARİ YAPISINI ESAS ALAN HİBRİT YAKLAŞIM
KULLANILARAK RADYOLOJİK GÖRÜNTÜLERDEN COVID-19 TEŞHİSİ
VE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Seyfullah URUT
DANIŞMAN: Doç. Dr. Recep ÖZDAĞ

VAN-2022

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKÂ VE ROBOTİK ANABİLİM DALI

**TEZİN ADI DERİN ÖĞRENME MİMARİ YAPISINI ESAS ALAN HİBRİT
YAKLAŞIM KULLANILARAK RADYOLOJİK GÖRÜNTÜLERDEN COVID-
19 TEŞHİSİ VE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Seyfullah URUT

VAN-2022

KABUL VE ONAY SAYFASI

Yapay Zeka Anabilim Dalı'nda Doç. Dr. Recep ÖZDAĞ danışmanlığında, Seyfullah URUT tarafından sunulan “ Derin Öğrenme Mimari Yapısını Esas Alan Hibrit Yaklaşım Kullanılarak Radyolojik Görüntülerden Covid-19 Teşhisi Ve Tahmin Edilmesi” isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince/...../..... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve tezi olarak kabul edilmiştir.

Başkan:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Üye:.....

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 13/12/2022 tarih ve 2022/55-1 sayılı kararı ile onaylanmıştır.

İmza

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

(İmza)

Seyfullah URUT

ÖZET

DERİN ÖĞRENME MİMARİ YAPISINI ESAS ALAN HİBRİT YAKLAŞIM KULLANILARAK RADYOLOJİK GÖRÜNTÜLERDEN COVID-19 TEŞHİSİ VE TAHMİN EDİLMESİ

URUT, Seyfullah

Yüksek Lisans Tezi, Yapay Zekâ ve Robotik Anabilim Dalı

Tez Danışmanı: Doç. Dr. Recep ÖZDAĞ

Aralık 2022, 38 sayfa

SARS-CoV-2 virüsü kaynaklı yeni bir Koronavirüs hastalığı olan ve etkisini tüm dünyada göstermeye devam eden COVID-19 pandemisi resmi olarak toplamda 623 milyondan fazla vaka sayısına ulaşarak 6.5 milyondan fazla insanın ölümüne sebep olmuştur. Bu virüsün insan vücudunda yaptığı tahribatlar sonucunda, özellikle akciğerdeki deformasyon belirgin hale gelmiştir. Bu tezde, derin öğrenme mimarileri olan evrişimsel sinir ağı (Convolutional Neural Network - CNN) ile tekrarlayan sinir ağı (Recurrent Neural Network- RNN) kullanarak akciğer bilgisayarlı bomografi (computed tomography - CT) ve enerjisi yüksek frekanslı elektromanyetik radyasyon (energetic high-frequency electromagnetic radiation - X-Ray) görüntülerinden COVID-19'un teşhisi ve tahmin edilmesi amaçlanmıştır. Bu amaçla tez kapsamında öncelikle CNN mimarisi esas alınarak pozitif COVID-19, negatif COVID-19 ile akciğer iltihabı vakalarından oluşan ve toplam 9150 adet olan akciğer X-Ray ve CT radyolojik görüntülerden özellik çıkarımı gerçekleştirilmiştir. Sonrasında ise RNN mimarisi olan Uzun kısa süreli bellek (long short-term memory - LSTM) modeli esas alınarak görüntülerin sınıflandırması gerçekleştirilmiştir. Tasarlanan hibrit (CNN+LSTM) mimarisi ile test görüntülerinin sınıflandırılmasında %93'lük bir doğruluğa ulaşılmıştır. Bu tezde, radyolojik görüntülerden pozitif COVID-19'un sınıflandırılmasında RNN-LSTM modeli ile farklı bir hibrit mimari yapı tasarlanarak; hem literature katkı sağlanmış, hem de pozitif COVID-19 vakalarının teşhisi ve tahmin edilmesi sürecinde radyologların hızlı ve doğru karar vermelerine yardımcı olunmuştur.

Anahtar kelimeler: COVID-19, Derin öğrenme, Evrişimsel sinir ağı, Tekrarlayan sinir ağı, Uzun kısa süreli bellek.



ABSTRACT

DIAGNOSIS AND PREDICTION OF COVID-19 FROM RADIOLOGICAL IMAGES USING A HYBRID APPROACH BASED ON DEEP LEARNING ARCHITECTURAL STRUCTURE

URUT, Seyfullah

MSc. Thesis Artificial Intelligence and Robotics Department

Supervisor: Assoc. Prof. Dr. Recep OZDAG

December 2022, 38 pages

The COVID -19 pandemic, a new coronavirus disease caused by the SARS-CoV-2 virus that continues to show its effects throughout the world, has officially reached a total of more than 623 million cases and caused the death of more than 6.5 million people. As a result of the destruction of this virus in the human body, deformities are observed, especially in the lungs. This thesis, it is about diagnosis and prediction COVID-19 of lung computed tomography (CT) and energetic radiofrequency electromagnetic radiation (X-Ray) using deep learning architectures Convolutional Neural Network (CNN) and Recurrent Neural Network (RNN). For this purpose, within the scope of the thesis, mainly based on CNN architecture, feature extraction is performed from 9150 X-Ray lung images and CT radiological images consisting of positive COVID -19, negative COVID -19 and pneumonia cases. Afterward, the classification of the images is performed based on the Long Short-Term Memory (LSTM) model, which is the RNN architecture. With the designed hybrid (CNN+LSTM) architecture, an accuracy of 93% has been achieved in the classification of test images. In this thesis, a different hybrid architectural structure is designed with the RNN-LSTM model in the classification of positive COVID-19 from radiological images; not only contributed to the literature but also helped Radiologists to make quick and accurate decisions in the diagnosis and estimation of positive COVID-19 cases.

Key words: COVID-19, Deep learning, Convolutional neural Network, Recurrent neural network, Long short term memory.



ÖN SÖZ

Bu tez çalışmasında, her türlü ilgi ve yardımlarını esirgemeyen danışmanım Sayın Doç. Dr. Recep Özdağ'a teşekkür ederim. Ayrıca her vakit yanımda olan başta eşim Zehra URUT olmak üzere tüm aileme teşekkürlerimi sunarım.

2022

Seyfullah URUT



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
ÖN SÖZ	v
İÇİNDEKİLER	vii
ÇİZELGELER LİSTESİ	xi
ŞEKİLLER LİSTESİ	xiii
SİMGELER VE KISALTMALAR	xvi
1. GİRİŞ	1
1.1. COVID-19 Tespiti	2
1.2. Tezin amacı, pratik önemi ve planlaması	3
2. KAYNAK BİLDİRİŞLERİ	4
3. MATERYAL VE YÖNTEM	7
3.1. Materyal	7
3.1.1. Evrişimsel sinir ağları	7
3.1.1.1. Konvolüsyon katmanı	8
3.1.1.2. Havuzlama katmanı	9
3.1.1.3. Tam bağlantı katmanı	10
3.1.1.4. Toplu normalleştirme	10
3.1.2. ReLu aktivasyon fonksiyonu	11
3.1.3. Sigmoid aktivasyon fonksiyonu	12
3.1.4. Stratified k-fold fonksiyonu	12
3.1.5. Uzun-kısa süreli hafıza modeli	13
3.1.6. Karmaşıklık matrisi ve performans metrikleri	14
3.2. Yöntem	15

	Sayfa
3.2.1. Veri ön işleme.....	16
3.2.2. Örnekleme	16
3.2.3. Model geliştirme.....	17
3.2.4. Model değerlendirme.....	19
4. BULGULAR ve TARTIŞMA	21
4.1. X-Ray görüntüler için hibrit modelin performans değerlendirmesi	21
4.2. Hibrit model ile tespit edilen nınıfların X-Ray görüntüleri.....	26
4.3. CT görüntüler için hibrit modelin performans değerlendirmesi.....	27
4.4. Hibrit model ile tespit edilen sınıfların CT görüntüleri.....	31
5. SONUÇ.....	33
KAYNAKLAR.....	34
ÖZ GEÇMİŞ.....	38

ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Karmaşıklık matrisi	15
Çizelge 3.2. Akciğer X-Ray veri setindeki eğitim ve test görüntü verisi sayısı.....	17
Çizelge 3.3. Akciğer CT veri setindeki eğitim ve test görüntü verisi sayısı	17
Çizelge 3.4. Uygulamalardaki özel parametreler ve değerleri	18
Çizelge 3.5. Hibrit mimari yapısının ağ özeti.....	20
Çizelge 4.1. Hibrit modelin X-Ray görüntülerindeki performans değerlendirme ölçütleri.....	24
Çizelge 4.2. Hibrit modelin CT görüntülerindeki performans değerlendirme ölçütleri.....	29
Çizelge 4.3. Hibrit modelin literatürdeki çalışmalar ile karşılaştırılması.....	32

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 3.1. CNN mimarisi	8
Şekil 3.2. Konvolüsyon işlemi.....	9
Şekil 3.3. Havuzlama işlemi	9
Şekil 3.4 Tam bağlantı katmanı yapısı	10
Şekil 3.5. Normalizasyon işlemi.....	11
Şekil 3.6. ReLu fonksiyon grafiği	12
Şekil 3.7. Sigmoid fonksiyon grafiği.....	12
Şekil 3.8 K-katlamalı çapraz doğrulama ile ayrıştırma işlemi	13
Şekil 3.9. LSTM yapısı.....	14
Şekil 3.10. Akciğer X-Ray ve CT radyolojik görüntülerin tespiti ve sınıflandırılması sürecinin iş-akış diyagramı.....	16
Şekil 3.11. CNN+LSTM hibrit mimari yapısı.....	19
Şekil 4.1. Pozitif COVID-19 X-Ray görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği	22
Şekil 4.2. Negatif COVID-19 X-Ray görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği	22
Şekil 4.3. Akciğer İltihabı X-Ray görüntüleri için hibrit modelin doğruluk – kayıp performans grafiği	23

Şekil	Sayfa
Şekil 4.4. X-Ray görüntüleri için hibrit modelin ROC grafiği.....	24
Şekil 4.5. X-Ray görüntüleri için hibrit modelin karmaşıklık matrisi.....	25
Şekil 4.6. Pozitif COVID-19 X-Ray görüntüleri.....	26
Şekil 4.7. Negatif COVID-19 X-Ray görüntüleri	26
Şekil 4.8. Akciğer iltihabı X-Ray görüntüleri	26
Şekil 4.9. Pozitif COVID-19 CT görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği	27
Şekil 4.10. Negatif COVID-19 CT görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği	28
Şekil 4.11. Akciğer iltihabı CT görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği	28
Şekil 4.12. CT görüntüleri için hibrit modelin ROC grafiği	29
Şekil 4.13. CT görüntüleri için hibrit modelin karmaşıklık matrisi	31
Şekil 4.14. Pozitif COVID-19 CT görüntüleri	31
Şekil 4.15. Negatif COVID-19 CT görüntüleri	32
Şekil 4.16. Akciğer iltihabı CT görüntüleri	32

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
Colab	Google Colaboratory
CNN	Convolutional Neural Network
CT	Computed Tomography
FC	Fully Connected
FN	False Negatif
FP	False Pozitif
GPU	Graphics Processing Unit
LSTM	Long Short Term Memory
MAX	Maximal
MIN	Minimal
ReLU	Rectified Linear Units
RNN	Recurrent Neural Network
RT	Real Time
RT-PCR	Reverse Transcription - Polymerase Chain Reaction
ROC	Receiver Operating Characteristic
TN	True Negatif
TP	True Pozitif
WHO	World Health Organization
YZ	Yapay Zekâ
YSA	Yapay Sinir Ağları



1. GİRİŞ

Günümüzde yapay zekâ ve robotik alanındaki çalışmalar bütün dünyada ve ülkemizde çok hızlı ve kararlı bir şekilde yürütülmektedir. Sağlık, tarım, akıllı sistemler, biyomedikal çalışmalar, doğal dil işleme, veri analizleri, oyunlar, güvenlik sistemleri, destek botları ve sanal asistanlar gibi birçok alanda insan hayatını kolaylaştırmaya ve yaşam kalitesini arttırmaya yönelik yapay zekâ odaklı çalışmalar yapılmaktadır. Sağlık alanında, hastalığın tanı ve teşhisine yönelik olarak yapay zekâ kullanımı ile dağınık olan büyük verinin analiz edilmesi sonucunda uzman bir doktordan çok daha hızlı ve doğru sonuçlar çıkarılması günümüzde mümkün hale gelmiştir.

Koronavirüsler, insan ve hayvan türlerinin çoğunda salgın şeklinde yayılan ve yıllardır dünyamızı tehdit eden hastalıklar arasındadır. Çin'in Hubei eyaleti Wuhan şehrinde aralık 2019'da ortaya çıkan SARS-CoV-2 virüsü kaynaklı bir koronavirüs enfeksiyon salgını insanlar arasında ciddi sayıda vaka oluşturmuş ve bir çoğunun ölmesiyle sonuçlanmıştır. Dünya Sağlık Örgütü (World Health Organization-WHO) Ocak 2020'de dünya çapında acil durum ilan etmiş, 11 Mart 2020'de COVID-19 adını verdiği ve pandemi olarak sınıflandırılan yeni bir Koronavirüsü resmi olarak duyurmuştur. COVID-19 pandemisi tüm dünyaya hızla yayılarak 623 milyondan fazla insana bulaşmış ve 6.5 milyondan fazla insanın ölümüne sebep olmuştur. Koronavirüsün yarası kaynaklı olduğu, hem kuşları hem de memelileri ve insanları enfekte edebildiği saptanmıştır. COVID-19'un teşhisi Gerçek Zamanlı Ters Transkripsiyon Polimeraz Zincir Reaksiyonu (Real Time Reverse Transcription Polymerase Chain Reaction - RT-PCR) ile doğrulanabilmesine rağmen, PCR testlerinin son derece yanlış negatif sonuçlar vermesi bu testlerin güvenilirliğini düşürmüştür (Ozsahin ve ark. 2020). Ayrıca test sonuçlarının kısa bir süre içinde tespit edilememesi de bu süreçte COVID-19'un bulaşmasını kolaylaştırmıştır. Dolayısıyla, enfekte kişilerin tespit edilememesi ve gerekli tedaviye zamanında başlanamaması hem COVID-19 bulaşma riskini hem de insanların ölüm riskini artırmıştır.

1.1. COVID-19 tespiti

SARS-CoV-2 virüsünün kuluçka (inkübasyon) süresinin 2 ile 14 gün arasında değiştiği, ortalamasının ise 4-5 gün olduğu tespit edilmiştir (Anonim, 2022a). COVID-19 şüphesi olan kişilerin, uygun tedaviyi alabilmeleri, kendilerini izole edebilmeleri ve yakın kişileri bilgilendirebilmeleri için enfekte olup olmadıklarını hızlı bir şekilde bilmeleri gerekir.

Virüsleri veya antikorları tespit etmek için COVID-19 testleri 2 temel yaklaşıma göre yapılmaktadır. Birincisi, nükleik asit testi, antijen testleri ve seroloji testlerini içeren laboratuvar temelli yaklaşımlardır. İkinci olarak, X-Ray ve CT taramaları gibi akciğer görüntülemeye dayalı tanı yaklaşımları olarak kabul edilir. Nazofaringeal sürüntü, boğaz sürüntüsü ve balgam yoluyla alınan numuneler üzerinde laboratuvar (PCR) testleri yapılır. Kullanılan en yaygın tanı yöntemlerinden biri nazofaringeal sürüntüdür. Fakat PCR testinin sonuç vermesi en az 24 saat sürmekte ve tanıyı doğrulamak için ikinci bir PCR veya farklı bir test gerekebilmektedir. X-Ray ve CT taramaları ise, virüs bulaştığından şüphelenilen hastaların doğrulanmasında önemli bir tanısal yaklaşım olarak kullanılmaktadır (Singh ve ark. 2020).

COVID-19, pnemonia gibi birçok hastalıkta röntgen ve tomografi ile elde edilen görüntülere benzer düzeyde akciğeri etkileyebileceğinden, klinik inceleme yapılmadan sadece akciğer görüntülerinden elde edilen bulgulara dayanarak kesin pozitif COVID-19 sonucuna ulaşamayabilir. Klinik tanılarının yanı sıra göğüs CT taraması, COVID-19'un kesin tanısını ortaya çıkarmada yüksek duyarlılığa sahiptir. Dolayısıyla COVID-19 tanısı, enfekte kişinin semptomları ve laboratuvar bulgularının radyolojik görüntüleme teknikleri ile birleştirilmesiyle konulabilir. COVID-19'un radyolojik özellikleri, radyolojik görüntüleme teknikleri olan X-Ray ve CT taramaları ile tespit edilebilmektedir. Radyologlar, COVID-19 hastalığının tanısında çoğunlukla akciğer CT görüntülerini tercih etmektedirler. Bununla birlikte, X-Ray cihazları akciğer görüntülerinde yumuşak dokuları doğru bir şekilde ayırt edemediğinden dolayı, daha doğru tespit için akciğer CT taramaları kullanılmaktadır (Hare ve ark. 2020).

1.2. Tezin amacı, pratik önemi ve planlaması

Bu tezde, insanın akciğer radyolojik görüntüleri üzerinde COVID-19 hastalığının teşhisi ve tahmin edilmesi için derin öğrenme mimarileri olan CNN ve RNN esas alınarak yeni bir hibrit (CNN+LSTM) yaklaşımın tasarlanması amaçlanmıştır. Hastalığın erken teşhisi ve tedaviye bir an önce başlanması göz önünde bulundurularak COVID-19 salgının insan vücuduna yaptığı tahribatlar dikkate alındığında, bu tez çalışmasında COVID-19 hastalığının yüksek bir doğruluk oranı ile tespit edilmesi tezin ulaşılması gereken hedefini belirler.

Bu tezin pratik önemi; derin öğrenme modelleri esas alınarak önerilen yeni bir hibrit yaklaşım kullanılarak X-Ray ve CT radyolojik görüntülerden COVID-19'un teşhisi ve tahmin edilmesinin yüksek bir doğrulukla sağlanması ve böylelikle Radyologlara hızlı ve doğru karar vermelerinde yardımcı olunmasıdır.

Bu tez çalışması takip edildiği üzere planlanmıştır:

1. Bölümde, COVID-19 pandemisi ve teşhis ile ilgili literatür bilgilerine vurgu yapılmıştır.
2. Bölümde, çeşitli derin öğrenme modelleri esas alınarak ve insanın akciğer X-Ray ve CT görüntüleri kullanılarak yapılan literatür çalışmalarına vurgu yapılmıştır.
3. Bölümde, tez çalışmasındaki materyaller ve yöntemler açıklanmıştır. Temel alınan CNN modeli COVID-19 özellik çıkarımında materyal olarak sunulmuş olup, RNN tabanlı LSTM ise radyolojik görüntülerden COVID-19 tahmininde (sınıflandırmasında) yeni bir yöntem (hibrit yaklaşım) olarak tasarlanmıştır.
4. Bölümde, önerilen yaklaşımın doğruluk ölçütleri hesaplanarak deneysel bulgular olarak sunulmuş ve tartışılmıştır.
5. Bölümde ise, bu tez çalışmasında ulaşılan nihai sonuçlar açıklanarak gelecekte yapılması muhtemel akademik çalışmalara yönelik tavsiyeler vurgulanmıştır.

2. KAYNAK BİLDİRİŞLERİ

Tezin bu bölümünde, hem X-Ray hem de CT radyolojik görüntülerinden COVID-19'un tespitinde derin öğrenmeyi temel alan literatür çalışmaları sunulmuştur.

Bandyopadhyay ve ark. (2020), çalışmalarında COVID-19'un doğrulanmış, serbest bırakılmış, negatif ve ölüm vakalarını hızlı ve doğru olarak sınıflandırmak için LSTM-GRU'yu kullanan yeni bir yöntem sunmuşlardır. Yapılan çalışmada, teyit edilen vakalar için %87, olumsuz vakalar için %67,8, ölen vakalar için %62 ve belirsiz durum vakaları için %40,5 doğruluk elde etmişlerdir.

Rahimzadeh ve ark. (2020), çalışmalarında birleştirilmiş bir CNN modeli geliştirdiler. Xception ve ResNet50V2 modelleri kullanılarak akciğer X-Ray görüntüleri COVID-19 pozitif (+), COVID-19 negatif (-) ve akciğer iltihabı (Pnömoni) olarak sınıflandırıldı. COVID-19 pozitif olan 6054 birey ile akciğer iltihabı radyolojik görüntülerine ek olarak COVID-19 negatif olan 8851 bireyin X-Ray görüntülerinden veri seti oluşturuldu.

Uçar (2020), çalışmasında CNN tabanlı bir model ile X-Ray görüntülerinden COVID-19 sınıflandırmasını yaptı. Oluşturduğu veri setinde; COVID-19 pozitif (4290 adet), COVID-19 negatif (1583 adet) ve akciğer iltihabı görüntüleri olmak üzere üç sınıf kullanarak %98,3 olan doğruluk değerine ulaştı.

Ko (2020), çalışmasında CNN mimarilerini kullanarak akciğer CT görüntülerin COVID-19 tespitini gerçekleştirdi. Wonkwang Üniversite Hastanesi, Chonnam Ulusal Üniversite Hastanesi ile İtalyan Tıbbi ve Girişimsel Radyoloji Derneğinin veri tabanındaki radyolojik görüntülerden oluşan bir veri seti oluşturdu. VGG16, ResNet-50, Inception-3 ile Xception derin öğrenme modellerini kullanarak akciğer CT görüntülerin COVID-19 sınıflandırmasını yaptı. ResNet-50 modelinde %99'luk duyarlılık, %100 özgüllük ve %99 doğruluk olan performans metriklerine ulaştı.

Shi (2020), çalışmasında yüksek bir depolama yeri kaplayan COVID-19 akciğer CT görüntülerinden oluşan bir veri seti oluşturdu ve makina öğrenmesini temel alarak COVID-19 analizi yaptı.

Zhang ve ark. (2020), çalışmalarında COVID-19 hastalığını akciğer iltihabı hastalığından ayırt etmek için X-Viral ve xCOVID veri setinden alınan CT görüntülerini

kullanarak akciğer radyolojik görüntülerin sınıflandırmasını yaptılar. CNN derin öğrenme modelini kullanarak özgün bir model geliştirdiler. Bu modelde, %71 duyarlılık ile %83 doğruluk olan performans metriklerine ulaşıldı.

Horry (2020), çalışmasında akciğer X-Ray görüntülerinden COVID-19'u tespit etmek için eğitilmiş modelleri esas alarak yeni bir model geliştirdi. Önerilen modelde, Xception, VGG, ResNet ve Inception'ı kullanarak sınıflandırma yaptı. COVID-19 pozitif (115 adet), COVID-19 negatif (361 adet) ile akciğer iltihabı (322 adet)'ndan oluşan radyolojik görüntüler kullanıldı. Önerilen modelde, VGG16 ile VGG19 sınıflandırıcıları kabaca %80 geri çağırma hassasiyetine ulaştı.

Hu ve ark. (2020), çalışmalarında Çin'de hizmet veren hastanelerde beşyüz'den fazla hastaya ait akciğer CT görüntülerinden oluşan bir veri setini kullanarak CNN mimarisini temel alan bir yaklaşım önerdiler. Bu çalışmadaki temel amaç, büyük ölçekli klinik çalışmalarda COVID-19 hastalığını diğer hastalıklardan ayırmaktır. Radyolojik görüntüleri COVID pozitif, COVID-19 negatif ve akciğer iltihabı olarak sınıflandırdılar.

Wang ve ark. (2020), çalışmalarında PCR testi yapmadan COVID-19'u teşhis etmek amacıyla 1000 (bin) den fazla akciğer CT görüntülerinden oluşturdukları veri setini kullandılar. Hastanın hem sağlığını korumak hem de SARS-CoV-2 virüsünün yayılma riskini engellemek için kritik bir öneme sahip olan bu çalışmayı yaptılar. CNN mimarisini temel alan ve önerdikleri model ile COVID-19 hastalığı teşhisinde %88 özgüllük, %87 duyarlılık ve %89,5 doğruluk olan performans metriklerine ulaşıldı.

Ophir (2020), akciğer CT görüntülerinden COVID-19'u tespit etmek için derin öğrenme yöntemlerini kullandı. COVID-19 pozitif olma olasılığındaki CT görüntülerin özelliklerinin belirlenmesi ve önerilen modelin performansını analiz etmek amacıyla "Corona skoru" adıyla bir çalışma yaptı. Bu çalışmasında, 200'e yakın hasta ile gerçekleştirdiği bir dizi test ile zaman içindeki COVID-19 hastalığının değişim sürecini değerlendirmek için çoklu retrospektif deneyler yaptı. Çalışmanın sonunda %99.6'lık yüksek doğruluk performans metriğine ulaşmıştır.

Hall (2020), çalışmasında akciğer CT görüntülerinden COVID-19 hastalığının doğru tespit edilebilmesinin faydasını ispatlayabilmek amacıyla 4000'den fazla CT görüntü kullanarak CNN mimarisini temel alan yeni bir derin öğrenme modeli geliştirmiştir. Bu model kullanılarak 102 hastanın CT görüntülerinden COVID-19

hastalığı tespitinde %100'e yakın bir başarıya ulaşıldı. Ayrıca, COVID-19 haricinde diğer solunum yolu hastalıklarının teşhisinde ise %95'lik bir başarı elde edildi.

Hemdan (2020), çalışmasında 25 tane klinik onayı alınabilen pozitif COVID-19 vakalarına ait 50 adet akciğer CT görüntüsünü kullanarak CNN tabanlı yeni bir derin öğrenme modeli geliştirmiştir. COVIDX-Net, DenseNet, VGG19 ve Google Mobile Net'in derin öğrenme modellerinin de kullanıldığı performans analizinde, negatif COVID-19 vakalarında %89, pozitif COVID-19 vakalarında ise %91'lik tespit oranına ulaşıldı.

Wang ve ark. (2020), çalışmalarında COVID19 veri setindeki on üç bin (13000) den fazla vakaya ait akciğer CT görüntülerinden pozitif COVID-19'u tespit etmek amacıyla bir derin CNN yapısı olan COVID-Net'i tasarladı. Geliştirilen bu modelde, negatif COVID-19 vakalarında %90.5, pozitif COVID-19 vakalarında %98.9 ve akciğer iltihabı vakalarında ise %91.3'lük bir başarı sağlanarak tespitler yapıldı.

Fang (2020), endemik bölgelerde seyahat veya yerleşim öyküsü olan, ateşi veya nedeni bilinmeyen akut solunum semptomları olan 51 hastayı inceleyen bir çalışma yaptı. Akciğer CT görüntüleri ve PCR testleri ile yapılan metrik karşılaştırmalarda, %71'lik PCR testi duyarlılığına karşın %98'lik CT görüntü duyarlılığına ulaştı.

3. MATERYAL VE YÖNTEM

3.1 Materyal


Tezin bu bölümünde, öncelikle derin öğrenme modelleri olan ve insanın akciğer radyolojik görüntülerinden COVID-19 özellik çıkarımını sağlayan CNN ile kullanılan katman yapıları ve aktivasyon fonksiyonları sunulmuştur. Sonrasında ise bu radyolojik görüntülerin sınıflandırılarak yüksek bir doğrulukla COVID-19 hastalığının tahmin edilmesi probleminin çözümünde kullanılan RNN tabanlı LSTM yapısı açıklanmıştır. Ayrıca değerlendirme ölçütleri olarak kullanılan metriklerin karmaşıklık matrisi sunulmuştur.

3.1.1. Evrişimsel sinir ağları

Evrişimsel sinir ağları görüntü verilerinde sınıflandırmak ve özellik çıkarmak için kullanılmaktadır. Görüntü verilerini isimlendirmek, benzer özellikleri kümelemek ve nesne tanıma yapmak için kullanılan bir derin yapay sinir ağıdır.

Derin öğrenme mimarisi olan evrişimsel sinir ağı (CNN)'ları, özellikle ayrıştırma yapmak maksadıyla tercih edilmektedir. Biyolojiden ilham alınarak üretilen çok katmanlı algılayıcıların bir türevidir (Acarçipek, 2015). CNN, çok katman yapısı sayesinde eğitim ve test için gayet uygundur. Her katmanda havuzlama katmanı, filtre katmanı ve doğrusal olmayan katmandan oluşmaktadır. Filtre katmanında farklı özellik çıkarılması için birçok çekirdek bulunmaktadır. Havuzlama katmanında, elde edilen her özellik haritası, ayrı ayrı değerlendirilir. Her harita komşu değerinin ortalaması veya maksimum değerinin elde edilmesini sağlar (Özcan, 2014).


Şekil 3.1.(Cengil, 2016)'de gösterilen bir CNN mimarisine göre, iki evrişim katmanı ile evrişim katmanlarını izleyen iki alt örnekleme katmanı ve en üst katmanda tam- bağlantılı katman bulunmaktadır. Bu yapıda görüntü parçalara ayrıştırılarak her parçaya filtre uygulanır. Filtre işleminden sonra görüntüde küçülme olur. Bu işlem neticesinde elde edilen piksellerin özellikleri anlamlandırılarak LSTM katmanında sınıflandırma verisi olarak işleve sokulur.



Şekil 3.1. CNN mimarisi.

3.1.1.1. Konvolüsyon katmanı


Konvolüsyon katman (Convolutional Layer) CNN'nin temel yapı taşı niteliğindedir. Görüntü verisinin özelliklerini algılamada kullanılır. Bu katman, görüntüdeki düşük ve yüksek dereceli özellikleri çıkarmak için görüntüye bazı filtreler uygular. Şekil 3.2 (İnik, 2017)'de gösterildiği üzere; giriş görüntüsü renkli ve 5x5 bir matris olduğu varsayıldığında giriş veri boyutu 5x5x3 olacaktır. Konvolüsyon işlemi için 3x3'lük bir filtre ile giriş görüntüsü üzerinde sağa veya sola doğru belirli adım kaydırılarak gezinme işlemi yapılır.



Şekil 3.2. Konvolüsyon işlemi.

3.1.1.2. Havuzlama katmanı


CNN mimarisinde birbirini takip birden fazla evrişim katmanı arasında havuzlama katmanı (pooling layer) bulunur. Havuzlama katmanının amacı, görüntüler çok büyük olduğu durumda parametre sayısını azaltarak görüntüyü küçültmektir (Şekil 3.3).



Şekil 3.3. Havuzlama işlemi.

3.1.1.3. Tam bağlantı katmanı


Tam bağlantı (Fully Connected - FC) katmanı, CNN’de kullanılan son katmandır. Tam bağlantı katmanları, mimarinin bir katmandaki bütün düğümlerin köprü kurularak bir sonraki katmanlara bağlandığı bir yapay sinir ağı türüdür. Tam bağlantı ile elde edilen verilere, uygulanan düzleştirme (flattening) işleminden sonra ağı öğrenme işlevleri değerlendirilir. Şekil 3.4’te tam bağlantı katmanının temel çalışma yapısı gösterilmiştir. Tam bağlantı katmanında birçok kez havuzlama katmanlarından geçen matrisler halindeki veriler düz bir vektör haline getirilir.



Şekil 3.4. Tam bağlantı katmanı yapısı.

3.1.1.4. Toplu normalleştirme

Toplu normalleştirme (batch normalization) yapay sinir ağlarında sık kullanılan, ağı giriş ve çıkışlarına belirli ön işlem adımların uygulanmasıyla sunulan verilerin eğitimi daha verimli hale getirilebilmesini sağlamaktadır. Şekil 3.5’te gösterildiği üzere; görüntü verilerinin bağlantı katmanına ulaştırma işlemi yapılmıştır. Normalleştirme işleminin amacı ham verilere uygulanarak bu verilerin eğitim için uygun veri setinin hazırlanmasıdır. (Jayalakshmi ve Santhakumaran, 2011)




Şekil 3.5. Normalizasyon işlemi.

Şekil 3.5'te gösterildiği üzere; toplu normelleştirme işlevini CNN ağını daha düzenli hale getirerek eğitim esnasında stabil/optimize olmasını sağlamaktır. Amaç, ağımızın daha düzenli hale getirilmesi ve eğitim esnasında optimize olması için toplu normelleştirme yönteminden yararlanılmıştır.

3.1.2. Relu aktivasyon fonksiyonu

ReLU, günümüzde konvolüsyon katmanında kullanılan en yaygın aktivasyon fonksiyonudur. Pozitif ekseninde doğrusal fonksiyon ile aynı özelliklere sahip olarak görünür (Şekil 3.6). Bu tez çalışmasında, iyi bir tahmin edici olması sebebiyle bu fonksiyon kullanılmıştır. Çalışmada, özellik haritalarında doğrusallığı artırmak için relu katmanı kullanılmıştır.




Şekil 3.6. ReLu fonksiyon grafiği.

3.1.3. Sigmoid aktivasyon fonksiyonu

Lineer olmayan gerçek hayat problemleri ile sigmoid fonksiyonu kombinasyonları lineer olmayan bir sonuç verir.

Avantajı çıktı olarak $[0,1]$ aralığında değer üretir (Şekil 3.7).




Şekil 3.7. Sigmoid fonksiyon grafiği.

3.1.4. Stratified k-fold fonksiyonu

Literatürde k-katlamalı çapraz doğrulama (k-fold cross validation) olarak geçmektedir. Çapraz doğrulamayla performans ölçümü yapılır. Çalışmada her adımdan sonra eğitim doğruluğu ve kaybı belirlemek amacıyla çapraz doğrulama kullanılarak


çaprazlama doğrulamanın doğruluğu ve kaybı test edilmiş ve veri setinin eğitim - test için ayrıştırılmasıyla performans ölçümünü sağlamıştır (Şekil 3.8).



Şekil 3.8. K-katlamalı çapraz doğrulama ile ayrıştırma işlemi.

3.1.5. Uzun-kısa süreli hafıza modeli

LSTM, RNN'lerin geliştirilmiş bir halidir. Bir LSTM ağı, önceki bilgileri hatırlayabilir ve şimdiki zamanda elde edilen verilere bağlanabilir. LSTM, bir “giriş” kapısı, bir “unut” kapısı ve bir “çıkış” kapısı olmak üzere üç kapı ile birleştirilmiştir. Şekil 3.9’daki LSTM ağ yapısına göre; *giriş kapısı*, *unutma kapısı* ve X_t ’nin mevcut girişi, C_t ve CT_{-1} ’in sırasıyla yeni ve önceki hücre durumunu ifade ettiği çıkış kapısı gibi üç kapı ile birleştirilir. h_t ve h_{t-1} sırasıyla mevcut ve önceki çıktıyı ifade eder.



Şekil 3.9. LSTM yapısı.

3.1.6. Karmaşıklık matrisi ve performans metrikleri

Karmaşıklık matrisi, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin nasıl bir performansla sonuç verdiğini tanımlamak için kullanılmaktadır. Matristeki değerler kullanılarak performans metrikleri tanımlanmaktadır. Sınıflandırma modeli ile yapılan tahminler takip eden dört değerlendirme ile ifade edilir:

- Doğru-Pozitif (True Positive - TP) : Sınıflandırmadaki bir veriyi gerçek değerleriyle tahmin edilmesi için tanımlanır.
- Doğru-Negatif (True Negative- TN) : Sınıflandırmadaki yanlış bir değer yanlış olarak tahmin etmek için tanımlanır.
- Yanlış-Pozitif (False Positive - FP) : Sınıflandırmadaki gerçek değer yanlış olarak tahmin edilmesi için tanımlanır.
- Yanlış-Negatif (False Negative - FN) : Sınıflandırmadaki yanlış değer doğru olarak tahmin edilmesi için tanımlanır.

Yapılan sınıflandırmanın doğruluğunu değerlendirmek için Çizelge 3.1’de sunulan karmaşıklık matrisi kullanılmaktadır. Karmaşıklık matrisi değerleri ile *Kesinlik*, *Hassasiyet*, *Doğruluk* ve *F1-Skor* metrikleri hesaplanır.

Çizelge 3.1. Karmaşıklık matrisi.

Karmaşıklık Matrisi		Gerçek Değer	
		Pozitif	Negatif
Tahmin Değer	Pozitif	TP	FN
	Negatif	FP	TN

Kesinlik: pozitif olarak tahmin edilen verilerden kaç tanesinin gerçek pozitif olduğunu gösterir (Eş. 3.1).

$$Kesinlik = TP / (TP + FP) \quad (3.1)$$

Hassasiyet: pozitif olarak tahmin edilmesi gereken verilerin kaç tanesinin pozitif olarak tahmin edildiğini gösterir (Eş. 3.2).

$$Hassasiyet = TP / (TP + FN) \quad (3.2)$$

Doğruluk: Doğru tahmin edilen verilerin toplam verilere oranını gösterir (Eş. 3.3).

$$Dogruluk = (TP + TN) / (TP + FP + TF + FN) \quad (3.3)$$

F1-Skor: *Kesinlik* ve *Hassasiyet* metriklerinin harmonik ortalamasını gösterir.


$$F1 - Skor = 2 * (Kesinlik * Hassasiyet) / (Kesinlik + Hassasiyet) \quad (3.4)$$

3.2. Yöntem

Bu tez çalışmasında, yöntem olarak radyolojik görüntülerin veri ön işlemesi ve özellik çıkarımı yapılarak COVID-19 hastalığını tespit eden, bu görüntülerin sınıflandırılarak COVID-19 hastalığının tahmin edilmesini mümkün kılan yeni bir hibrit mimari yapı tasarlanmıştır.

3.2.1. Veri ön işleme

Bu tez çalışmasında, veri ön işleme süreci Şekil 3.10’da gösterildiği üzere birden fazla adımdan oluşmaktadır. X-Ray veri setindeki radyolojik görüntüler ön işleme aşamasında sırasıyla yeniden boyutlandırma, karıştırma ve normalizasyon işlemleri uygulanır. Sonrasında ise ön işleme tabii tutulan veri seti eğitim ve test olarak ayrıştırılarak bir sonraki işlem bölümüne aktarılır.



Şekil 3.10. Akciğer X-Ray ve CT radyolojik görüntülerin tespiti ve sınıflandırılması sürecinin iş-akış diyagramı.

3.2.2. Örneklemeye

Bu tez çalışmasında, akciğer X-Ray ve CT radyolojik görüntülerden oluşan veri seti ‘KAGGLE’ (Anonim, 2022b; Anonim, 2022c) isimli platformdan referans alınarak oluşturulmuştur. Oluşturulan veri setinde, her biri toplam 4575 adet olan X-Ray ve CT akciğer radyolojik görüntüler kullanılmıştır. Hem X-Ray hem de CT radyolojik görüntülerinin her birisi %80’i eğitim ve %20’si ise test verisi olarak bölünmüştür. Öncelikle, X-Ray radyolojik görüntü veri seti üç sınıfa ayrılarak etiketlenmiştir ve pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı olmak üzere her sınıfta 1220 adet X-

Ray görüntüsü eğitim verisi olarak kullanılmıştır. Ayrıca toplam 915 adet olan pozitif COVID-19, negatif COVID-19 ile akciğer iltihabı X-Ray görüntüsü test verisi olarak kullanılmıştır (Çizelge 3.2). Sonrasında ise, toplam 4575 adet CT radyolojik görüntü veri seti üç sınıfa ayrılarak etiketlenmiştir ve pozitif COVID-19, negatif COVID-19 ile akciğer iltihabı olmak üzere her sınıfta 1220 adet CT görüntüsü eğitim verisi olarak kullanılmıştır. Ayrıca her biri 305 adet olan pozitif COVID-19, negatif COVID-19 ile akciğer iltihabı CT görüntüsü test verisi olarak kullanılmıştır (Çizelge 3.3). Tasarlanan hibrit mimari yapısı kullanılarak X-Ray veri setinde eğitim verisi olarak ayrıştırılan görüntüler eğitilmiştir.

Çizelge 3.2. Akciğer X-Ray veri setindeki eğitim ve test görüntü verisi sayısı.

	(+)COVID-19	(-)COVID-19	Akciğer iltihabı	Toplam
<i>Eğitim</i>	1220	1220	1220	3660
<i>Test</i>	305	305	305	915

Çizelge 3.3. Akciğer CT veri setindeki eğitim ve test görüntü verisi sayısı.

	(+)COVID-19	(-)COVID-19	Akciğer iltihabı	Toplam
<i>Eğitim</i>	1220	1220	1220	3660
<i>Test</i>	305	305	305	915

3.2.3. Model geliştirme


Veri setindeki radyolojik görüntülerin sınıflandırılmasında uygulama ortamı olarak google colab üzerinden python ve tensorflow2 ile keras paketi kullanılarak hibrit mimari yapı (Bkz. Şekil 3.9) tasarlanmıştır. Hibrit olarak isimlendirilen mimari yapı esasen CNN mimarisi ile RNN mimarisinin LSTM modeli birleştirilerek (CNN+LSTM) tasarlanmıştır. Uygulamalar 16 GB grafik işlemci birimi (GPU)'ne sahip google colab'ta çalıştırılmıştır. Bu uygulamalarda kullanılan parametreler, öğrenme oranı efor sayısı aktivasyon parametreleridir. Öğrenme oranını, bir modelin ne kadar hızlı öğrendiği olarak hesaplanan bir parametredir. Öğrenme oranı ne kadar yüksek olursa, modelin öğrenme kapasitesi o kadar hızlı olur. Parametreler Çizelge 3.4'de sunulmuştur.

Çizelge 3.4. Uygulamalardaki özel parametreler ve değerleri.

<i>Parametreler</i>	<i>Değer</i>
Efor Sayısı	50
Çapraz Doğrulama Sayısı	5
Görüntü Karıştırma (Shuffle)	True
Öğrenme Oranı(Learning_rate)	0.0001
Aktivasyon Parametresi	Relu,sigmoid

Çizelge 3.4'te ifade edilen özel parametrelerde olan çapraz doğrulama için 5 kat çapraz doğrulama sayısı kullanılmıştır. Şekil 3.11'de gösterilen hibrit mimari yapısına göre tasarlanan ağ 20 katmandan oluşmuştur. Bu katmanlar sırasıyla; 12 adet evrişim katmanı, 5 adet havuzlama katmanı, 1 adet FC katmanı, 1 adet LSTM katmanı ile Softmax işlevine sahip olan 1 adet çıktı katmanıdır. Her evrişim bloğu, iki veya üç CNN ve bir havuzlama katmanı ile birleştirilir, ardından %25 bırakma oranı ile karakterize edilen bir bırakma katmanı kullanılır. ReLU aktivasyon fonksiyonu ile etkinleştirilen özellik çıkarımı için 3×3 çekirdek boyutuna sahip evrişim katmanı kullanılır. 2×2 çekirdek boyutuna sahip maksimum havuzlama katmanı, bir girdi görüntüsünün boyutlarını azaltmak için kullanılır. Mimarinin son bölümünde, fonksiyon haritası zaman bilgisini çıkarmak için LSTM katmanına aktarılır.

Yeniden şekillendirme yöntemi kullanılarak LSTM katmanının giriş boyutu (49, 512) olarak ayarlanmıştır. Hibrit mimarisi, zaman özelliklerini analizi sonrasında test verisi görüntülerinin üç kategoriden (pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı-zatürree) herhangi birine ait olup olmadıklarını tahmin etmek için X-Ray radyolojik görüntülerini FC katman aracılığıyla sıralar. Çizelge 3.5'de tasarlanan hibrit mimari yapısını oluşturan ağın özeti sunulmuştur.



Şekil 3.11. CNN+LSTM hibrit mimari yapısı.

3.2.4. Model değerlendirme

Bu aşamada, X-Ray ve CT radyolojik test verisi görüntüleri RNN-LSTM modeli ile sınıflandırılarak yüksek bir başarı oranı tespit edilmeye çalışılmıştır. CNN mimarisi esas alınarak eğitilen hibrit modelde, hem doğrulama hem test işlemleri uygulanarak modelin performans metriklerine (Bkz. Eş.3.1 – Eş.3.4) göre başarımı değerlendirilir.

Çizelge 3.5. Hibrit mimari yapısının ağ özeti.


<i>Katman</i>	<i>Tip</i>	<i>Çekirdek Boyutu</i>	<i>Adım</i>	<i>Çekirdek</i>	<i>Giriş Boyutu</i>
1	Evrişim2D	3×3	1	64	$224 \times 224 \times 3$
2	Evrişim2D	3×3	1	64	$224 \times 224 \times 64$
3	Havuz	2×2	2	-	$224 \times 224 \times 64$
4	Evrişim2D	3×3	1	128	$224 \times 224 \times 64$
5	Evrişim2D	3×3	1	128	$112 \times 112 \times 128$
6	Havuz	2×2	2	-	$112 \times 112 \times 128$
7	Evrişim2D	3×3	1	256	$56 \times 56 \times 128$
8	Evrişim2D	3×3	1	256	$56 \times 56 \times 256$
9	Havuz	2×2	2	-	$56 \times 56 \times 256$
10	Evrişim2D	3×3	1	512	$28 \times 28 \times 256$
11	Evrişim2D	3×3	1	512	$28 \times 28 \times 512$
12	Evrişim2D	3×3	1	512	$28 \times 28 \times 512$
13	Havuz	2×2	2	-	$28 \times 28 \times 512$
14	Evrişim2D	3×3	1	512	$14 \times 14 \times 512$
15	Evrişim2D	3×3	1	512	$14 \times 14 \times 512$
16	Evrişim2D	3×3	1	512	$14 \times 14 \times 512$
17	Havuz	2×2	2	-	$14 \times 14 \times 512$
18	LSTM	-	-	-	49×512
19	FC	-	-	64	25.088
20	Çıktı	-	-	3	64

4. BULGULAR ve TARTIŞMA


Tezin bu bölümünde, hem akciğer X-Ray hem de CT radyolojik görüntülerden oluşan veri seti esas alınarak tasarlanan hibrit CNN+LSTM derin mimari yapısının başarıml ölçütleri performans grafikleri kullanılarak sunulmuştur.

4.1. X-Ray görüntüler için hibrit modelin performans değeriendirmesi


Tasarlanan hibrit CNN+LSTM modeli kullanarak X-Ray radyolojik görüntülerin eğitim - test sürecinde başarıml ölçütlerinden olan doğruluk (accuracy) ve çapraz-entropi kaybı (cross-entropy loss)'nın performans değeriendirmesi grafiksel olarak Şekil 4.1 – Şekil 4.3'de gösterilmiştir. Bu grafiklerde, pozitif COVID-19 (Şekil 4.1), negatif COVID-19 (Şekil 4.2) ve akciğer iltihabı (Şekil 4.3) radyolojik görüntülerinin hibrit mimarisi ile sınıflandırıldığında tasarlanan modelin doğruluğu ve çapraz-entropi kaybı metrikleri ölçülmüştür. Grafiklerden görüldüğü üzere; X-Ray eğitim görüntülerinin doğruluk değeriinin yüksek olması bu görüntülerin sınıflandırılmasındaki başarıml oranının yüksek olduğunun, çapraz-entropi kaybı'nın düşük olması tasarlanan modelin başarımlının yüksek olduğunun bir kanıtıdır.



Şekil 4.1. Pozitif COVID-19 X-Ray görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği.




Şekil 4.2. Negatif COVID-19 X-Ray görüntüleri için hibrit modelin doğruluk – kayıp performans grafiği.



Şekil 4.3. Akciğer iltihabı X-Ray görüntüleri için hibrit modelin doğruluk – kayıp performans grafiği.

Tez çalışmasında, tasarlanan hibrit modelin X-Ray görüntülerini sınıflandırmadaki performansı değerlendirirken dikkate alınan metriklerden bir diğeri de AUC (Area Under the Curve) - ROC eğrisidir. ROC eğrisi altındaki alan (AUC)'nın kapsamı tasarlanan hibrit modelin pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı sınıflarını yüksek bir başarı doğruluğu ile ayırt etmede kullanılmıştır. Şekil 4.4'de sunulan hibrit modelin ROC grafiğine göre; X-Ray görüntülerdeki her üç sınıf için %97'nin üzerinde AUC kapsamı hesaplanmıştır. Dolayısıyla X-Ray radyolojik görüntüleri sınıflara ayırmada tasarlanan modelin yüksek bir başarı doğruluğuna ulaştığı ispatlanmıştır.



Şekil 4.4. X-Ray görüntüleri için hibrit modelin ROC grafiği.

Tez çalışmasında, X-Ray görüntülerindeki her bir sınıf için tasarlanan hibrit model kullanılarak hesaplanan performans metrikleri Çizelge 4.1’de sunulmuştur. *Kesinlik*, *Hassasiyet* ve *Doğruluk* metrikleri için bir denge skoru üreten *F1-Skor* dikkate alındığında, tasarlanan hibrit model kullanılarak X-Ray görüntülerindeki her üç sınıf için %92 ile %96 arasında değişen başarı oranlarında doğru tahmin yapıldığı tespit edilmiştir.

Çizelge 4.1. Hibrit modelin X-Ray görüntülerindeki performans değerlendirme ölçütleri.

Sınıf	Kesinlik	Hassasiyet	Doğruluk	F1-Skor
Pozitif COVID-19	0.88	0.96	0.93	0.92
Negatif COVID-19	0.95	0.96	0.93	0.96
Akciğer İltihabı	0.99	0.88	0.93	0.93

Tez çalışmasında, Şekil 4.5’te hibrit modelin Karmaşıklık (confusion) matrisi sunulurken X-Ray test veri setindeki görüntülere kıyasla tasarlanan modeldeki doğru ve yanlış tahminlerinin sayısı gösterilmiştir. Bu tahminler yorumlandığında;


- Negatif COVID-19 (normal) olan 305 adet gerçek görüntülerden; 294 tanesi normal, 9 tanesi pozitif COVID-19 ve 2 tanesi de akciğer iltihabı (pneumonia) olarak

sınıflandırıldı. Böylece negatif COVID-19 olan görüntülerin %96.3'ü normal olarak tahmin edildi.

- Pozitif COVID-19 (COVID-19) olan 305 adet gerçek görüntülerden; 11 tanesi normal ve 294 tanesi de COVID-19 olarak sınıflandırıldı. Böylece pozitif COVID-19 olan görüntülerin %96.3'ü COVID-19 olarak tahmin edildi.

- Akciğer iltihabı (pneumonia) olan 305 adet gerçek görüntülerden; 5 tanesi Normal, 33 tanesi COVID-19 ve 267 tanesi de pneumonia olarak sınıflandırıldı ve böylece akciğer iltihabı olan görüntülerin %87.5'i pneumonia olarak tahmin edildi.

Dolayısıyla tasarlanan hibrit mimari yapı kullanılarak test veri setindeki 915 adet X-Ray görüntüsünün 855 tanesi tahmin edilerek ortalama %93.4 doğruluk ile bir başarıya ulaşılmıştır. Ayrıca X-Ray görüntülerinin performans değerlendirme ölçütlerinde (Bkz. Çizelge 4.1) her üç sınıf için hesaplanan %93'lük *Doğruluk* metrik değerinin ispatlandığı belirlenmiştir.



Şekil 4.5. X-Ray görüntüleri için hibrit modelin karmaşıklık matrisi.

4.1. Hibrit model ile tespit edilen sınıfların X-Ray görüntüleri

Tasarlanan hibrit model ile test veri setinden tespit edilen Pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı X-Ray görüntüleri Şekil 4.6 – Şekil 4.8’de gösterilmiştir.



Şekil 4.6. Pozitif COVID-19 X-Ray görüntüleri.




Şekil 4.7. Negatif COVID-19 X-Ray görüntüleri.




Şekil 4.8. Akciğer iltihabı X-Ray görüntüleri.

4.2. CT görüntüler için hibrit modelin performans değerlendirilmesi


Hibrit CNN+LSTM derin mimari yapı kullanılarak CT radyolojik görüntülerin eğitim - test sürecinde başarımlar ölçütlerinden olan doğruluk ve çapraz-entropi kaybının performans değerlendirilmesi grafiksel olarak Şekil 4.9 – Şekil 4.11’de gösterilmiştir. Bu grafiklerde, pozitif COVID-19 (Şekil 4.9), negatif COVID-19 (Şekil 4.10) ve akciğer iltihabı (Şekil 4.11) radyolojik görüntülerinin hibrit mimarisi ile sınıflandırıldığında tasarlanan modelin doğruluğu ve çapraz-entropi kaybı metrikleri ölçülmüştür. Grafiklerden görüldüğü üzere; CT eğitim görüntülerinin doğruluk değerinin yüksek olması bu görüntülerin sınıflandırılmasındaki başarımlar oranının yüksek olduğunu, çapraz-entropi kaybı’nın düşük olması tasarlanan modelin başarımının yüksek olduğunu kanıtlar.



Şekil 4.9. Pozitif COVID-19 CT görüntüleri için hibrit modelin doğruluk – kayıp performans grafiği.



Şekil 4.10. Negatif COVID-19 CT görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği.



Şekil 4.11. Akciğer iltihabı CT görüntüleri için hibrit modelin doğruluk - kayıp performans grafiği.


Tasarlanan hibrit model ile CT görüntülerinin performans değerlendirmesinde, veri集中的 görüntülerden pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı olan sınıfların yüksek bir doğruluk ile ayırt edildiğini göstermek amacıyla AUC-ROC

eğrisi kullanılmıştır. Şekil 4.12’de sunulan hibrit modelin ROC grafiğine göre; CT görüntülerdeki her üç sınıf için %97’nin üzerinde AUC kapsamı hesaplanmıştır. Böylelikle CT radyolojik görüntüleri sınıflara ayırmada hibrit derin mimarinin yüksek bir başarı doğruluğuna ulaştığı ispatlanmıştır.

Tez çalışmasında, CT görüntülerindeki her bir sınıf için hibrit derin mimari yapı kullanılarak hesaplanan performans metrikleri Çizelge 4.2’de gösterilmiştir. *Kesinlik* ve *Hassasiyet* metriklerinin Harmonik ortalamasına göre hesaplanan *F1-Skor* dikkate alındığında, tasarlanan hibrit model kullanılarak CT görüntülerindeki her üç sınıf için %92 ile %96 arasında değişen başarı oranlarında tahmin yapıldığı tespit edilmiştir.

Çizelge 4.2. Hibrit modelin CT görüntülerindeki performans değerlendirme ölçütleri

<i>Sınıf</i>	<i>Kesinlik</i>	<i>Hassasiyet</i>	<i>Doğruluk</i>	<i>F1-Skor</i>
<i>Pozitif COVID-19</i>	0.88	0.97	0.93	0.92
<i>Negatif COVID-19</i>	0.95	0.96	0.93	0.96
<i>Akciğer İltihabı</i>	0.98	0.87	0.93	0.92




Şekil 4.12. CT görüntüler için hibrit modelin ROC grafiği.

Şekil 4.13’de hibrit modelin Karmaşıklık Matrisi sunularak CT test veri setindeki görüntülere kıyasla tasarlanan modeldeki doğru ve yanlış tahminlerinin sayısı gösterilmiştir. Bu tahminlere göre;

- Negatif COVID-19 olan 305 adet gerçek görüntülerden; 294 tanesi Normal, 7 tanesi COVID-19 ve 4 tanesi de Pheumonia olarak sınıflandırıldı. Böylece Negatif COVID-19 olan gerçek görüntülerin %96.3’ü COVID-19 olarak tahmin edildi.
- Pozitif COVID-19 olan 305 adet gerçek görüntülerden; 8 tanesi Normal, 295 tanesi COVID-19 ve 2 tanesi de Pheumonia olarak sınıflandırıldı. Böylece Pozitif COVID-19 olan gerçek görüntülerin %96.7’si COVID-19 olarak tahmin edildi.
- Akciğer iltihabı olan 305 adet gerçek görüntülerden; 8 tanesi Normal, 32 tanesi COVID-19 ve 265 tanesi de Pheumonia olarak sınıflandırıldı ve böylece akciğer iltihabı olan gerçek görüntülerin %86.8’i Pheumonia olarak tahmin edildi.

Dolayısıyla tasarlanan hibrit mimari yapı kullanılarak test veri setindeki 915 adet CT görüntüsünün 854 tanesi tahmin edilmiş ve ortalama %93.3 doğruluk ile bir başarıya ulaşılmıştır. Ayrıca CT görüntülerinin performans değerlendirmesinde (Bkz. Çizelge 4.2) her üç sınıf için hesaplanan %93’lük *Doğruluk* metrik değerinin ispatlandığı belirlenmiştir.




Şekil 4.13. CT görüntüleri için hibrit modelin karmaşıklık matrisi.

4.3. Hibrit model ile tespit edilen sınıfların CT görüntüleri

Tasarlanan hibrit mimari yapı kullanılarak test veri setinden tespit edilen pozitif COVID-19, negatif COVID-19 ve akciğer iltihabı CT görüntüleri Şekil 4.14 – Şekil 4.16’da gösterilmiştir.



Şekil 4.14. Pozitif COVID-19 CT görüntüleri.



Şekil 4.15. Negatif COVID-19 CT görüntüleri.



Şekil 4.16. Akciğer iltihabı CT görüntüleri.

X-Ray radyolojik görüntüler esas alınarak tasarlanan hibrit model ile literatürdeki çalışmaların performans ölçütleri karşılaştırılması Çizelge 4.3’de sunulmuştur.

Çizelge 4.3. Hibrit modelin literatürdeki çalışmalar ile karşılaştırılması.

<i>Yazar</i>	<i>Mimari Yapı</i>	<i>Kesinlik(%)</i>	<i>Doğruluk(%)</i>
Li ve ark.(Li, 2020)	Yoğun Ağ	88.9	79.2
Wang ve ark.(Wang, 2020)	Özel CNN	92.3	80.0
Asnaoui (Asnaoui,2020)	Incption_ResN	92.2	90.0
Tasarlanan hibrit model	CNN+LSTM	92.0	93.0

5. SONUÇ

Bu tezde, derin öğrenme mimarisi olan CNN ile RNN mimarisinin LSTM modeli hibrit bir şekilde kullanarak akciğer CT ve X-Ray veri seti görüntülerinden COVID-19 hastalığının teşhisi ve tahmin edilmesi amaçlanmıştır. Bu amaçla öncelikle CNN mimarisi kullanılarak veri setindeki eğitim görüntülerinin pozitif COVID-19, negatif COVID-19 ile Akciğer İltihabı olarak sınıflara ayrılması sağlanmıştır ve bu görüntülerden özellik çıkarımı gerçekleştirilmiştir. Sonrasında ise, hibrit mimari yapıda kullanılan LSTM modeli ile veri setindeki test görüntülerinin sınıflandırması gerçekleştirilmiştir.

Çalışmada, tasarlanan hibrit model 50 kez test edilerek *Kesinlik*, *Hassasiyet*, *Doğruluk* ve *F1-Skor* metrikleri ile performanslar ölçülmüştür. 50 testin ortalaması esas alındığında, hem X-Ray hem de CT radyolojik görüntülerden özellik çıkarılan her 3 sınıf için %93'lük bir *Doğruluk* metriği hesaplanmıştır. Bu radyolojik görüntülere uygulanan hibrit model ile %92 ile %96 arasında değişen *F1-Skor* metrik değerleri hesaplanmıştır. Ayrıca hibrit modelin hem X-Ray hem de CT görüntülerinin sınıflandırmadaki performansı için ROC grafikleri de dikkate alındığında, her 3 sınıf için %97'nin üzerinde AUC kapsamı hesaplanmıştır.

Sonuç olarak; bu tez çalışmasında tasarlanan CNN+LSTM mimari yapısı kullanılarak hem X-Ray hem de CT akciğer radyolojik görüntülerden özelliği çıkarılan pozitif COVID-19, negatif COVID-19 ile Akciğer İltihabı sınıflarının başarılı bir şekilde tahmini yapılmıştır. Dolayısıyla, literatürde çalışılmayan ve RNN mimarili LSTM modelini esas alan bir hibrit yapı kullanılarak akciğer radyolojik görüntülerin tespiti ve tahmin edilmesindeki başarısı mümkün kılınmıştır. Bu çalışma ayrıca, COVID-19 vakalarının teşhisi ve tahmin edilmesi sürecinde radyologların hızlı ve doğru karar verebilmelerini sağlayacaktır.

KAYNAKLAR

- Açarçipek, A. Haluk., 2015. *Derinlikli Öğrenme ile Konuşmacı Duygu Durumunun Sınıflandırılması Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul. May 2015, DOI:10.13140/RG.2.2.15723.08488
- Anonim, 2022a. T.C. Sağlık Bakanlığı COVID-19 Bilgilendirme Platformu. [https:// covid19.saglik.gov.tr/TR-66474/inkubasyon-sureci.html](https://covid19.saglik.gov.tr/TR-66474/inkubasyon-sureci.html). Sağlık Bakanlığı, Ankara. Erişim tarihi: 4.10.2021.
- Anonim, 2022b. SARS-COV-2 CT-Scan Dataset: A large dataset of CT scans for SARS-CoV-2 (COVID-19) identification. <https://www.kaggle.com/datasets/plameneduardo/sarscov2-CTscan-dataset>. Erişim tarihi: 4.10.2021.
- Anonim, 2022c. COVID-19_CNN29: Chest X-Ray Images (Pneumonia), COVID-19 chest xray. [https:// www.kaggle.com/code/amanullahasraf/covid-19-cnn29/data](https://www.kaggle.com/code/amanullahasraf/covid-19-cnn29/data). Erişim tarihi: 4.10.2021.
- Asnaoui, K. , Chawki Y., 2020. Using X-Ray images and deep learning for automated detection of coronavirus disease J Biomol Struct Dyn, **39** (10): 3615-3626. DOI: 10.1080/07391102.2020.1767212. Epub 2020 May 22.
- Bandyopadhyay S.K., Dutta S., 2020. *Machine learning approach for confirmation journal* COVID-19 cases: positive, negative, DOI: 10.1101/2020.03.25.20043505
- Baydar, B., 2018. *Convolutional Neural Network Based Brain MRI Segmentation*. ODTÜ, Fen Bilimleri Enstitüsü, Ankara. Ağustos 2019, DOI: 10.3389/fncom.2019.00056
- Brunese, L., Mercaldo, F., Reginelli, A., & Santone, A., 2020. *Pulmonary Disease and Coronavirus COVID-19 Detection from X-Rays*. Computer Methods, DOI: 10.1016/j.cmpb.2020.105608
- Cabria, I., Gondra I., 2016. MRI Segmentation Fusion for Brain Tumor Detection. *Information Fusion*, **36**: 1-9.
- Chen X., Udupa J.K., Bagci U., Zhuge Y., Yao J., 2012. Medical image segmentation by combining graph cuts and oriented active appearance models. *IEEE Transactions on Image Processing*, **2**: 2035-2046.
- Damadian, R., 1971. Tumor detection by nuclear magnetic resonance. *Science*, **171**: 1151-1153.
- Fang, Y., Zhang, H., Xie, J., Lin, M., Ying, L., Pang, P., Ji, W., 2020. Sensitivity of chest CT for COVID-19: Comparison to RT-PCR, *Radiology*, DOI: 10.1148/radiol.2020200432
- Fukushima, K., 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, **36**: 193–202.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y., 2014. *Generative adversarial nets*. Advances in Neural Information Processing Systems, **27**: 2672–2680.

- Hall, L. O., Paul, R., Goldgof, D. B., & Goldgof, G. M., 2020. Finding COVID-19 from Chest X-Rays using Deep Learning on a Small Dataset. April 2020, DOI:10.36227/techrxiv.12083964.v1
- Hare, S.S., Tavare, A.N., Dattani, V., Musaddaq, B., Beal, I., Cleverley, J., Cash, C., Lemoniati, E., Barnett, J., 2020. Validation of the British Society of Thoracic Imaging guidelines for COVID-19 chest radiograph reporting. *Clinical Radiology* 75 (9): 710.e9-710.e14.
- Hemdan, E. E.-D., Shouman, M. A., & Karar, M. E., 2020. COVIDx-Net: A Framework Of Deep Learning Classifiers To Diagnose COVID-19 In X-Ray Images. arXiv preprint, DOI: 10.48550/arXiv.2003.11055
- He, K., Zhang, X., Ren, S., Sun, J., 2015. **Deep Residual Learning for Image Recognition**. *Microsoft Research*, DOI: 10.1109/CVPR.2016.90
- Horry M.J., Chakraborty S., Paul M., Ulhaq A., Pradhan B. 2007. X-Ray image based COVID-19 detection using pre-trained deep learning models, DOI: 10.31224/osf.io/wx89s
- Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X., Xia, J. 2020. Weakly Supervised Deep Learning For COVID-19 Infection Detection And Classification From CT Images. *IEEE Access*, **89**: 118869-118883
- İnik, Ocak., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri . *Gaziosmanpasa Journal of Scientific Research*. Corpus ID: 192507790 December 2017
- Jayalakshmi, T. and A. Santhakumaran., 2011. Statistical Normalization and Back Propagation for Classification, *International Journal of Computer Theory and Engineering*, **31**: 1793-8201.
- Ko, H., Chung, H., Kang, W. S., Kim, K. W., Shin, Y., Kang, S. J., Jung, H., 2020. COVID-19 pneumonia Diagnosis Using A Simple 2D Deep Learning Framework With A Single Chest CT Image: **Model Development And Validation**. *Journal of Medical Internet Research*, **22** (6): e19569.
- Menze, B. H., 2015. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Trans Med Imaging*, **34**: 1993-2024.
- Michael Phi., 2018. Illustrated Guide to LSTM's and GRU's: A step by step explanation <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>.
Erişim Tarihi : 24.09.2022.
- Mujtaba H., 2020. Introduction to Resnet or Residual Network. Great Learning. <https://www.mygreatlearning.com/blog/resnet/#sh1>.
Erişim Tarihi: 01.8.2021.
- Ophir, G., Maayan, F.A., Hayit, G., Patrick D.B., Huangqi Z., Wenbin, J., Bernheim, A., Siegel, E., 2020. Rapid AI development Cycle For The Coronavirus (COVID19) Pandemic: Initial Results For Automated Detection & Patient Monitoring Using Deep Learning CT Image Analysis, Radiology, DOI: 10.48550/arXiv.2003.05037
- Orr, G. J. B., 2020. Momentum and learning rate adaptation. <https://cml.salk.edu/~schraudo/teach/NNcourse/momrate.html>.
Erişim tarihi: 4.8.2021
- Özcan, H., 2014. **Yüksek Lisans Tezi**. Çok Düşük Çözünürlüklü Yüz İmgelerinde Derin Öğrenme Uygulamaları, Deniz Harp Okulu, İstanbul, DOI: 10.29137/umagd.469929

- Özsahin I., Sekeroglu B., Musa S. M., Mustapha M. T., Ozsahin D.U., 2020. Review on Diagnosis of COVID-19 from Chest CT Images Using Artificial Intelligence. **Computational and Mathematical Methods in Medicine**, DOI: 10.1155/2020/9756518
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., Singh, V., 2020. Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals*, DOI: 10.1016/j.chaos.2020.109944
- Pereira, R. M., Bertolini, D., Teixeira, L. O., Silla, C. N., & Costa, Y. M. G., 2020. COVID-19 identification in chest X-Ray images on flat and hierarchical classification scenarios. **Computer Methods and Programs in Biomedicine**, DOI: 10.1016/j.cmpb.2020.105532
- Preston, D., 2016. *Magnetic Resonance Imaging (MRI) of the Brain and Spine*. <https://case.edu/med/neurology/NR/MRI%20Basics.htm>.
Erişim Tarihi: 01.10.2021.
- Rahimzadeh M., Attar A. A., 2020. New modified deep convolutional neural network for detecting COVID-19 from X-Ray images, DOI: 10.1016/j.imu.2020.100
- RL Galvez ., AA Bandala., EP Dadios., RRP Vicerra., 2019. JMZ Maningo Evrişimli sinir ağları kullanarak nesne algılama IEEE Reg. 10 Anne. Int. Konf. Proceedings/TENCON , **Institute of Electrical and Electronics Engineers Inc.**, DOI: 10.1016/j.cmpb.2020.105532
- Rosenblatt, F., 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, **65**: 386– 408.
- Saxena, S., Kumari, N., Pattnaik, S., 2021. Brain Tumour Segmentation in FLAIR MRI Using Sliding Window Texture Feature Extraction Followed by Fuzzy C-Means Clustering. **International Journal of Healthcare Information Systems and Informatics (IJHISI)**, **16**: 20. IIIT Bhubaneshwar, India.
- Shah, N., 2019. Left and Right Neural Networks -Inspired by Our Bicameral Brains. Monash University, Melbourne, DOI: 10.1017/337186250
- Shelhamer, E., Long, J., Darrell, T., 2017. Fully convolutional networks for semantic segmentation, **IEEE Trans. Pattern Anal. Mach. Intell.**, **39**: 640–651.
- Shi, F., Xia, L., Shan, F., Wu, D., Wei, Y., Yuan, H., Jiang, H., Gao, Y., Sui, H., Shen, D., 2020. Large-scale Screening of COVID-19 From Community Acquired Pneumonia Using Infection Size-Aware Classification, DOI: 10.1088/1361-6560/abe838
- Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., Simonyan, K., Zisserman, A., 2015. Very Deep Convolutional Networks For Large-Scale Image Recognition. University of Oxford, **Visual Geometry Group, Department of Engineering Science**, Oxford, DOI: 10.48550/arXiv.1409.1556
- Singh, D., Kumar, V., Kaur, V., Kaur, M., 2020. Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks. **European Journal of Clinical Microbiology & Infectious Diseases**, **39**: 1379–1389.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: A simple way to prevent neural networks from overfitting. *Learn. Res.*, **15**: 1929–1958.
- Ucar F., Korkmaz D., 2020. COVIDiagnosis-Net: deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-Ray images. *Med Hypotheses*, DOI: 10.1016/j.mehy.2020.109761

- Xiaoya, L., Xiaofei, S., Yuxian, M., Junjun, L., Fei, W., Jiwei, L., 2020. Dice Loss for Data-imbalanced NLP Tasks. Zhejiang University, **Department of Computer Science and Technology**, Hangzhou, China, DOI: 10.48550/arXiv.1911.02855
- Qian, N., 1999. On the momentum term in gradient descent learning algorithms. Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. University of Freiburg, **Computer Science Department and BIOS Centre for Biological Signalling Studies**, Germany. October 2015, DOI:10.1007/978-3-319-24574-4_28
- Vaishnav, K. B., Amshakala, K., 2015. An Automated MRI Brain Image Segmentation And Tumor Detection Using SOM-Clustering And Proximal Support Vector Machine Classifier, **IEEE International Conference on Engineering and Technology (ICETECH)**: March 2015, DOI:10.1109/ICETECH.2015.7275030
- Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., Meng, X., 2020. A Deep Learning Algorithm Using CT Images To Screen For Corona Virus Disease COVID-19. *Eur Respir J.* 2020 Aug 6, **56** (2): 2000775. DOI: 10.1183/13993003.00775-2020.
- Wang, S., Zha, Y., Li, W., Wu, Q., Li, X., Niu, M., Yu, H., 2020. A Fully Automatic Deep Learning System For COVID-19 Diagnostic And Prognostic Analysis. **European Respiratory Journal**. *Eur Radiol.* 2021 Aug, **31** (8): 6096-6104, DOI: 10.1007/s00330-021-07715-1. Epub 2021 Feb 24.
- Wei, J., 2019. VGG Neural Networks: The Next Step After AlexNet. <https://towardsdatascience.com/vgg-neural-networks-the-next-step-after-alexnet3f91fa9ffe2c>
Erişim Tarihi: 12.10.2021
- William, C. S. Jr., 2019. Magnetic Resonance Imaging (MRI Scan). https://www.medicinenet.com/mri_scan/article.htm.
Erişim Tarihi: 12.10.2021.
- Yangqing, J., 2014. Convolutional architecture for fast feature embedding. **Proceedings of the 22nd ACM international conference on Multimedia**. ACM. MM '14: Proceedings of the 22nd ACM international conference on Multimedia November 2014 Pages 675–678, DOI: 10.1145/2647868.2654889
- Zhang, J., Xie, Y., Liao, Z., Pang, G., Verjans, J., Li, W., Shen, C., 2020. Viral Pneumonia Screening On Chest X-Ray Images Using Confidence-Aware Anomaly Detection. ArXiv preprint, DOI: 10.48550/arXiv.2003.12338

ÖZ GEÇMİŞ

Seyfullah URUT, Bilgisayar mühendisliği lisans derecesini 2014 yılında Bilecik Şeyh Edebali Üniversitesi'nde aldı. Van Yüzüncü Yıl Üniversitesi Mühendislik Fakültesi Yapay Zekâ ve Robotik anabilim dalında yüksek lisans yapmaktadır. 2015-2022 yılları arasında sektörde yazılım geliştirme mühendisi olarak çalıştı. Araştırma alanları; Web Tabanlı Yazılımlar, Örüntü İşleme, Makine Öğrenmesi vb. konulardır.



VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 12/12/2022

Tez Başlığı / Konusu: Derin Öğrenme Mimari Yapısını Esas Alan Hibrit Yaklaşım Kullanılarak Radyolojik Görüntülerden COVID-19 Teşhisi ve Tahmin Edilmesi

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 61 sayfalık kısmına ilişkin, 05/12/2022 tarihinde tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %7 (yüzde yedi) dür.

Uygulanan filtreler aşağıda verilmiştir:

- Materyal ve yöntem hariç,
- Kaynaklar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimeden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

12/12/2022

Adı Soyadı: Seyfullah URUT

Öğrenci No: 19910001030

Anabilim Dalı: Yapay Zeka ve Robotik ABD

Programı: Yapay Zeka ve Robotik

Statüsü: ☐ Yüksek Lisans ☐ Doktora

DANIŞMAN ONAYI
UYGUNDUR
Doç.Dr. Recep Özdağ

ENSTİTÜ ONAY
UYGUNDUR