



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME YAKLAŞIMI İLE
PULMONER NODÜL KARAR DESTEK
SİSTEMİ**

Hilal TİRYAKİ

YÜKSEK LİSANS TEZİ

Dr. Öğr. Üyesi Burçin KURT

TRABZON-2020



TÜRKİYE CUMHURİYETİ
KARADENİZ TEKNİK ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**DERİN ÖĞRENME YAKLAŞIMI İLE
PULMONER NODÜL KARAR DESTEK
SİSTEMİ**

Hilal TİRYAKİ

YÜKSEK LİSANS TEZİ

Dr. Öğr. Üyesi Burçin KURT

TRABZON-2020

ONAY

Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı Tezli Yüksek Lisans Programı öğrencisi Hilal TİRYAKİ'nin hazırladığı “Derin Öğrenme Yaklaşımı ile Pulmoner Nodül Karar Destek Sistemi” başlıklı çalışma Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 28.02.2020

Dr. Öğr. Üyesi Burçin KURT
(Danışman)

Prof. Dr. Kemal TURHAN

Doç. Dr. Adil Alp KOÇAK

Sağlık Bilimleri Enstitüsü'ne/...../20..... tarihinde teslim edilen bu tez Enstitü Yönetim Kurulu'nun/...../20..... tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Ersan KALAY
Enstitü Müdürü

BEYAN

Bu tez çalışmasının Karadeniz Teknik Üniversitesi Sağlık Bilimleri Enstitüsü Tez Hazırlama ve Yazım Kılavuzu standartlarına uygun olarak hazırlanarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eserim olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen tüm bilgi ve yorumlara kaynak gösterdiğimi ve kullanılan kaynakların kaynaklar listesinde yer aldığını, tezin çalışılması ve yazımı aşamalarında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

17.03.2020

Hilal TİRYAKİ

TEŐEKKÖR

Bu tez alıřmasında yardımlarını esirgemeyen, bilgi ve tecrübelerini benimle paylaşan ve bana yol gösteren danışman hocam Dr. Öğr. Üyesi Burın KURT'a, Radyoloji Bölümünden Prof. Dr. Polat KOŐUCU ve Dr. Öğr. Üyesi Seluk AKKAYA'ya ve eğitim hayatım boyunca bana katkı sağlamış bütün hocalarıma teşekkür ederim. Bu süreçte büyük bir sabırla beni destekleyen ve her zaman yanımda olan aileme, tez alıřmamda katkıları olan sevgili eşim Arş. Gör. Buğra Kaan TİRYAKİ'ye ve arkadaşlarıma sevgi, saygı ve teşekkürlerimi sunarım.

Hilal TİRYAKİ

İÇİNDEKİLER

Sayfa

İÇ KAPAK SAYFASI

KABUL ve ONAY

BEYAN

TEŞEKKÜR

İÇİNDEKİLER

v

TABLolar DİZİNİ

vii

ŞEKİLLER DİZİNİ

viii

RESİMLER DİZİNİ

ix

SİMGELER, KISALTMALAR ve FORMÜLLER DİZİNİ

x

ÖZET

xi

ABSTRACT

xii

1. GİRİŞ ve AMAÇ

1

2. GENEL BİLGİLER

3

2.1. Pulmoner Nodül

3

2.2. Pulmoner Nodül Tanı ve Tedavi Yöntemleri

3

2.2.1. Bilgisayarlı Tomografi (BT)

3

2.3. Makine Öğrenmesi

4

2.3.1. Danışmanlı Öğrenme

4

2.3.2. Danışmansız Öğrenme

4

2.3.3. Takviyeli Öğrenme

4

2.4. Yapay Sinir Ağları

4

2.5. Yapay Sinir Ağlarının Sınıflandırılması

5

2.5.1. İleri Beslemeli Yapay Sinir Ağları

5

2.5.2. Geri Beslemeli Yapay Sinir Ağları	6
3. GEREÇ ve YÖNTEM	7
3.1. Derin Öğrenme Yaklaşımı ve Derin Sinir Ağları	7
3.2. Konvolüsyonel Sinir Ağları	8
3.2.1. Giriş Katmanı (Input Layer)	9
3.2.2. Konvolüsyon Katmanı (Convolution Layer)	9
3.2.2.1. Aktivasyon Fonksiyonları	9
3.2.3. Havuzlama Katmanı (Max-Pooling Layer)	10
3.2.4. Tam Bağlı Katman (Fully Connected Layer)	11
3.2.4.1. Düzleştirme (Flattening)	11
3.2.5. Çıkış Katmanı (Output Layer)	11
3.2.6. Aşırı Uydurma (Overfitting) ve Yetersiz Uydurma (Underfitting)	12
3.3. Toraks BT Görüntülerinin Eğitime Hazırlanması	13
3.4. Sistemin Eğitilmesi ve Test	17
4. BULGULAR	19
5. TARTIŞMA ve SONUÇ	24
6. KAYNAKLAR	27
EKLER	33
Ek 1. Etik Kurul Onay Belgesi	34
ÖZGEÇMİŞ	37

TABLÖLAR DİZİNİ

Tablo No		Sayfa
Tablo 1.	Görüntü sayılarını veri setlerine göre dağılımı	13
Tablo 2.	Sistemin eğitilmesinde farklı hiper-parametreler için kurulan modeller	19
Tablo 3.	Çapraz doğrulama için verinin bölünmesi	21
Tablo 4.	Model 23 için 5 kat çapraz doğrulama sonuçları	21
Tablo 5.	Çapraz doğrulama 1. kat için hassasiyet ve özgüllük	22
Tablo 6.	Literatürdeki benzer çalışmalara ait başarımlar	25

ŞEKİLLER DİZİNİ

Şekil No		Sayfa
Şekil 1.	Biyolojik sinir hücresinin yapısı (nöron)	5
Şekil 2.	Yapay sinir hücresinin yapısı	5
Şekil 3.	İleri beslemeli çok katmanlı sinir ağının yapısı	6
Şekil 4.	İleri yönlü bir derin sinir ağı yapısı	7
Şekil 5.	El yazısı rakamlarını sınıflandırma için bir CNN mimarisi	8
Şekil 6.	Sıklıkla kullanılan aktivasyon fonksiyonları	10
Şekil 7.	Max-Pooling işlemi uygulanmış görüntü matrisi	11
Şekil 8.	Model karmaşıklığının tahmini hata üzerine etkisi	12
Şekil 9.	600x400 piksel boyutlu pulmoner nodül görüntü veri seti için kurulan model	17
Şekil 10.	Model 23 için doğruluk ve kayıp (ilk 100 epoch)	21
Şekil 11.	Başarısı en yüksek olan model (Model 23) için CNN ağı	22

RESİMLER DİZİNİ

Resim No	Sayfa
Resim 1. Bir hastaya ait orijinal toraks BT görüntüsünde pulmoner nodül bulunan kesit	14
Resim 2. Gri ölçeklendirilmiş görüntü	14
Resim 3. Eşikleme işlemi uygulanmış görüntü	15
Resim 4. Erozyon işlemi uygulanmış görüntü	15
Resim 5. Kırpılmış görüntü	16
Resim 6. Gürültüden arındırılmış görüntü	16
Resim 7. Önişleme uygulanmış görüntüler	20

KISALTMA, SİMGE ve FORMÜLLER DİZİNİ

Kısaltmalar

AI	Artificial Intelligence (Yapay Zeka)
BT	Bilgisayarlı tomografi
CAD	Computer Aided Detection (Bilgisayar Destekli Tanı)
CNN	Convolutional Neural Network (Konvolüsyonel Sinir Ağı)
DL	Deep learning (Derin Öğrenme)
DLCST	Danish Lung Cancer Screening Trial (Danimarka Akciğer Kanseri Tarama Denemesi)
GPU	Graphics Processing Unit (Grafik İşlem Birimi)
KTÜ	Karadeniz Teknik Üniversitesi
LIDC	Lung Image Database Consortium (Akciğer Görüntü Veri Tabanı Konsorsiyumu)
MILD	Multicenter Italian Lung Detection (Çok Merkezli İtalyan Akciğer Tespiti)
ML	Machine Learning (Makine Öğrenmesi)
MLP	Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
NCI	National Cancer Institute (Ulusal Kansere Enstitüsü)
PET	Positron Emission Tomography (Positron Emisyon Tomografisi)
YSA	Yapay Sinir Ağları

ÖZET

Derin Öğrenme Yaklaşımı ile Pulmoner Nodül Karar Destek Sistemi

Günümüzde tıbbi analiz ve teşhisi kolaylaştırmak için makine öğrenmesi kullanımı yaygınlaşmaktadır. Makine öğrenmesi ile bilgisayar destekli tanı sistemleri geliştirilerek makinelerle yorum yapabilme yeteneği kazandırılmaktadır. Bu bağlamda bilgisayar destekli tanı sistemleri radyologlara ikinci bir görüş sunarak tanı ve tespit doğruluğunu artırmaktadır. Erken dönemde tanı, hastanın sağ kalım sürecini artırmaktadır. Bu amaçla, bu tez çalışmasında, akciğer kanseri tanısında pulmoner nodüllerin benign (iyi huylu) ya da malign (kötü huylu) olarak sınıflandırılması için derin öğrenme yaklaşımının bir yöntemi olan konvolüsyonel sinir ağılarını kullanan bir karar destek sistemi geliştirildi.

Makine öğrenmesinde Konvolüsyonel Sinir Ağı (Convolutional Neural Network-CNN) görüntülerin analiz edilmesinde başarıyla uygulanan derin yapay sinir ağıdır. CNN'ler minimal ön işleme gerektiren, çok katmanlı yapıyı kullanır. Veri seti olarak Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji Bölümü'nden alınan 600 hastaya ait 1070 adet toraks BT (bilgisayarlı tomografi) görüntüleri kullanıldı. Geliştirilen karar destek sistemi ile toraks BT görüntüleri üzerinden akciğer kanseri tanısı için pulmoner nodüller otomatik olarak sınıflandırıldı. Beş kat çapraz doğrulama sonucunda en yüksek doğruluk %84, ortalama doğruluk %76, ortalama hassasiyet %77 ve ortalama özgüllük %75 olarak hesaplandı. Geliştirilen sistemin temel CNN modeli kullanılarak yapılan çalışmalar arasında en yüksek doğruluğa sahip olduğu görüldü.

Anahtar Sözcükler: Akciğer kanseri, Derin öğrenme, Karar destek sistemi, Konvolüsyonel sinir ağı

ABSTRACT

Pulmonary Nodule Decision Support System with Deep Learning Approach

Today, the use of machine learning is becoming widespread to facilitate medical analysis and diagnosis. The machines are gained the ability to make comments by developing computer-aided diagnostic systems with machine learning. Thus, computer-aided diagnostic systems increase accuracy of diagnostic and detection by offering a second opinion to radiologists. Early diagnosis increases the patient's survival. In this thesis, a decision support system was developed for the classification of pulmonary nodules (benign or malignant) in the diagnosis of lung cancer using convolutional neural networks which is a method of deep learning approach.

In the machine learning, the convolutional neural network (CNN) is a deep artificial neural network that is successfully applied in image analysis. The CNNs use the multi-layering structure which requires minimal pre-processing. 1070 Thorax CT images of 600 patients from the Farabi Hospital Radiology Department of Karadeniz Technical University were used as the data set. The pulmonary nodules were automatically classified for diagnosis of lung cancer from the thorax CT images by using the developed decision support system. As a result of five-fold cross-validation, the highest accuracy was 84%, the average accuracy was 76%, the average sensitivity was 77%, and the average specificity was 75%. The improved system has the highest accuracy among the studies using the basic CNN model.

Keywords: Convolutional neural network, Decision support system, Deep learning, Lung cancer

1. GİRİŞ ve AMAÇ

Son zamanlarda Yapay Zeka (Artificial Intelligence-AI) teknikleri, sağlık hizmetlerinin gelişmesinde büyük rol oynamaktadır. Büyük veri analitik yöntemlerinin gelişimi sayesinde mevcudiyeti oldukça artan tıbbi verilere rağmen bu alanda başarılı sağlık uygulamaları mümkün hale gelmiştir. AI yaklaşımı ile geliştirilen karar destek sistemleri, hekimlerin daha iyi klinik kararlar vermesine ve hatta sağlık hizmetlerinin bazı fonksiyonel alanlarında (örneğin, radyoloji) insan kararını iyileştirmeye yardımcı olabilmektedir (1).

Son çalışmalar, CNN özelliklerinin genel olduğunu ve sinir ağların eğitildiği alanın dışındaki sınıflandırma görevlerinde de kullanılabileceğini öne sürmektedir. Ginneken vd. tarafından gerçekleştirilen çalışmada BT taramalarında nodül tespiti için, doğal görüntülerde nesne tespiti için eğitilmiş OverFeat gibi bir ağ kullanılmıştır (2). Dört torasik radyolog tarafından okunan halka açık Akciğer Görüntü Veri Tabanı Konsorsiyumu (LIDC) veri setinden 865 görüntü kullanılmıştır. Nodül adayları, bir state-of-neart nodül algılama sistemi tarafından üretilmiştir. Nodül adayları için özellikler çıkarılmış ve destek vektör makineleri ile sınıflandırılmıştır. Sonuç olarak sistemin %71 duyarlılığa sahip olduğu görülmüştür.

Bir başka çalışma Ciompi vd. tarafından yapılmıştır (3). Eğitilen sistem tüm nodül tiplerini otomatik olarak sınıflandıran çok-akışlı çok-ölçekli konvolüsyon ağlarına dayanmaktadır. Derin öğrenme sistemi, Çok merkezli İtalyan Akciğer Tespiti (MILD) tarama çalışmasının verileriyle eğitilmiş ve Danimarka Akciğer Kanseri Tarama Denemesi (DLCST) tarama denemesinden bağımsız bir veri seti üzerinde onaylanmıştır. 943 taramada sistemin sınıflandırma performansının %79.5 olduğu belirtilmiştir. Kumar vd. tarafından akciğer nodüllerini malign veya benign olarak sınıflandırmak için bir oto kodlayıcıdan elde edilen derin özellikleri kullanan bir Bilgisayar Destekli Tanı (CAD) sistemi önerilmiştir (4). Ulusal Kanser Enstitüsü (NCI), LIDC veri setinden 4323 nodülü içeren 4303 örneği kullanılmıştır. Sonuçlar sistemin %83.35'lik bir duyarlılık ve %75 başarıya sahip olduğunu göstermiştir. Riccardi ve Ark. akciğer görüntülerinde otomatik nodül tespiti için konvolüsyonel sinir ağlarına dayanan yeni bir sistem sunmuştur (5). Sistem, LIDC veri tabanı tarafından sağlanan 154 akciğer görüntüsü incelemesinde doğrulanmıştır. Yazarlar, nodüllerin %71'ini doğru bir şekilde saptandığını bildirmişlerdir.

Bu tez çalışmasında akciğer kanseri tanısında pulmoner nodüllerin benign-malign olarak sınıflandırılması için hekime yardımcı olacak klinik karar destek sistemi geliştirilmesi amaçlanmıştır.

Malign nodülü bulunan hastaların sađ kalım süresinin artırılması için olabildiğince erken dönemde tanı konulup ameliyat edilmesi gerekmektedir. Benign nodüllerde ise gereksiz cerrahi girişimden kaçınmak gerekmektedir. Bu sebeple nodülün erken dönemde sınıflandırılması oldukça önemlidir.

Bu tanı sistemi derin öğrenme algoritmalarından biri olan konvolüsyonel sinir ağıları yöntemiyle geliştirilmiştir. Bu çalışmadaki görüntü verileri Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji Bölümünden alınmıştır. 600 hastanın toraks BT (Bilgisayarlı Tomografi) çekiminde nodüllerin belirgin olarak görüldüğü kesitler kullanılarak sistem eğitilmiştir. Böylece, yeni bir hasta için toraks BT görüntüsü kullanılarak akciğer kanseri tanısında pulmoner nodüller için benign-malign sınıflandırması yapılabilecektir.



2. GENEL BİLGİLER

2.1. Pulmoner Nodül

Akciğerde bulunan lekelere pulmoner nodüller denmektedir. Pulmoner nodüller öksürük, kanlı balgam ve hırıltılı solunum gibi belirtilerle ortaya çıkabilmektedir. Hastanın akciğer enfarktüsü, verem, zatürre ve romatizma gibi hastalıklar geçirmesi de nodül oluşumuna sebep olabilmektedir (6). Pulmoner nodüllerin çapı 3 cm'den küçüktür. Şekilleri genelde yuvarlaktır ve etrafında akciğer dokusu bulunmaktadır.

Nodüller, boyut, büyüme hızı, kalsifikasyon paterni ve nodülün sınırlarına göre çeşitlilik göstermektedir. Nodül büyüklüğü ve çeşidi nodül malignitesini etkilemektedir (7). Bu özellikler bazen direkt akciğer grafisinde görülse de genellikle BT görüntülemesi gerektirmektedir. Bu çalışmada, kalsifik nodüller, solid nodüller ve buzlu cam nodüller kullanılmıştır.

2.2. Pulmoner Nodül Tanı ve Tedavi Yöntemleri

Bilgisayarlı tomografi cihazlarının hastalıkların tanısında daha sık kullanılmaya başlanmasıyla birlikte akciğerlerde nodüllere daha sık rastlanmaya başlanmıştır. Ancak nodüllerin kolayca saptanabilmesine rağmen çoğu zaman benign mi malign mi olduğuna karar vermek kolay olmamaktadır.

Pulmoner nodül teşhisinde akciğer filmi, bilgisayarlı tomografi, pozitron emisyon tomografisi (PET), iğne ile biyopsi, bronkoskopi yöntemleri kullanılmaktadır. Bazı durumlarda hekim gerekli gördüğü hastalarda kapalı ve açık akciğer ameliyatı ile biyopsi incelemesini gerekli görebilmektedir.

2.2.1. Bilgisayarlı Tomografi (BT)

Bilgisayarlı tomografi bir tıbbi görüntüleme cihazıdır. Görüntüleme x-ışınlarının dairesel olarak hastanın etrafında döndürülmesiyle gerçekleşmektedir. X-ışınları dönerek vücudu kesitler halinde taramakta ve her kesitin görüntüsünü bilgisayara iletmektedir. Cihaza bağlı olan bilgisayar görüntüleri ardışık olarak birleştirilerek 3 boyutlu bir görüntü sunmaktadır.

Tomografi görüntüleri sayesinde vücuttaki anormallikler kolayca tespit edilebilmektedir. Bilgisayarlı tomografi, pulmoner nodüllerin saptanmasında en hassas

görüntüleme yöntemidir. Tek bir toraks BT incelemesi büyük miktarda görüntü verisi üretmektedir (8).

2.3. Makine Öğrenmesi

Günümüzde, makine öğrenmesi (Machine Learning-ML) oldukça popülerlik kazanmıştır ve önümüzdeki yıllarda da katlanarak büyümesi beklenmektedir. Makine öğrenmesi, gelecek için karar vermek gerektiğinde geçmiş deneyimlerden faydalanarak karar veren bilgisayar bilimlerinin bir dalıdır. Bir modelin, yalnızca istatistiksel modellerde olduğu gibi modellenmesine gerek olmadan, verilere dayanan deneyimlerden otomatik olarak öğrenebilmesine olanak sunmaktadır. ML verilen örneklerden bilinmeyen bir kural oluşturmaktadır (9).

Nesne tanımaya yönelik çalışmalarda genellikle makine öğrenmesi yöntemleri tercih edilmektedir. Makine öğrenmesi yöntemleri büyük veri kümeleri ile çalışmaya olanak sağladığından sistemin başarı oranını artırmaktadır (10).

Makine öğrenmesi girdi ve çıktıların durumuna göre kategorilere ayrılmaktadır.

2.3.1. Danışmanlı Öğrenme

Danışmanlı öğrenmede sisteme giriş bilgisi ile çıkış bilgisi verilmektedir. Sistemden giriş verisi ile çıkış verisi arasında bir ilişki kurması istenmektedir (9).

2.3.2. Danışmansız Öğrenme


Danışmansız öğrenmede sisteme sadece giriş bilgisi verilmektedir (11). Sistemden, verilen verilerdeki gizli örüntüleri ve ilişkileri bulması istenmektedir (9).

2.3.3. Takviyeli Öğrenme


Takviyeli öğrenmede sistem, içinde bulunduğu ortamdan gelen geri bildirimlere göre (+1 ödül ya da -1 ceza kuralı) davranışını öğrenmektedir (9).

2.4. Yapay Sinir Ağları

Yapay sinir ağları (YSA), biyolojik bir beynin duyuşal girdilerinden, uyarılara cevap veren yapısını taklit eden bir modeli kullanarak bir dizi giriş sinyali ve çıkış sinyali arasındaki ilişkiyi modellemektedir. İnsan beyni, yaklaşık 90 milyar nörondan oluşmakta ve yaklaşık 1 trilyon bağlantısı bulunmaktadır (9). YSA yöntemleri, birbirine bağlı yapay nöronları (düğümleri) kullanarak problemleri modellemeye çalışmaktadır. Yapay sinir hücresi ve biyolojik sinir hücresi arasındaki benzerlik Şekil 1 ve Şekil 2’de gösterilmektedir.



Şekil 1. Biyolojik sinir hücresinin yapısı (nöron), (Bulut'dan, 12)



Şekil 2. Yapay sinir hücresinin yapısı

2.5. Yapay Sinir Ağlarının Sınıflandırılması


Yapay sinir ağları, hücrelerin birbirlerine bağlanma yapısına, öğrenme şekillerine ve aktivasyon fonksiyonlarına göre sınıflandırılmaktadır.

2.5.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda, sinyal giriş yönünden çıkış yönüne doğru iletilmektedir (Şekil 3). Bu sinir ağı modelinde katman sayıları ve hücreler arasındaki bağlantıların sayıları için

bir kısıtlama bulunmamaktadır. Çok katmanlı algılayıcılar (Multi Layer Perceptron-MLP) ileri beslemeli ağlara örnek olarak verilebilir (13).

Günümüzde en yaygın olarak çok katmanlı yapay sinir ağları kullanılmaktadır (14). Bir yapay sinir ağındaki giriş ve çıkışların arasındaki ilişki doğrusal değilse problemi tek katmanlı yapay sinir ağları ile öğrenmek mümkün olmamaktadır. Çok katmanlı yapay sinir ağları giriş katmanı, gizli katman (ara katman) ve çıkış katmanından oluşmaktadır. Giriş katmanında giriş bilgileri alınarak herhangi bir işleme tabi tutulmadan gizli katmana iletilmektedir. Gizli katmanda bir önceki katmandan gelen bilgi işlenerek bir sonraki katmana gönderilmektedir. Çok katmanlı yapıda birden fazla gizli katman olabilmektedir. Çıkış katmanında gizli katmandan gelen bilgiler işlenerek çıktı oluşturulmaktadır. Her giriş elemanı için bir çıkış elemanı verilmektedir (15).



Şekil 3. İleri beslemeli çok katmanlı sinir ağının yapısı

2.5.2. Geri Beslemeli Yapay Sinir Ağları


Geri beslemeli yapay sinir ağları modelinde her bir katmana ait bağlantılar bir önceki katmanlardan gelebileceği gibi bir sonraki katmandan da gelebilmektedir (16). Bu şekildeki yapısı sayesinde doğrusal olmayan bir davranış göstermektedir. Geri beslemeli yapay sinir ağlarının çalışma prensibinin karmaşık olmasına rağmen hafızaları sayesinde ön tahmin uygulamalarında başarılı sonuçlar verdiği görülmüştür (17).

3. GEREÇ ve YÖNTEM

3.1. Derin Öğrenme Yaklaşımı ve Derin Sinir Ağları

Grafik işlem birimlerinin (GPU) gelişmesiyle birlikte makine öğrenmesinin bir alt dalı olan Derin öğrenme [Deep Learning (DL)] yaklaşımı popülerlik kazanmıştır (18). DL yaklaşımı beynin çalışma prensibinden esinlenilerek tasarlanmıştır. Birden fazla gizli katmanlı oluşu sebebiyle “Derin” adını alır (Şekil 4). 2000’li yıllarda standart sinir ağları yerine kullanılmaya başlanan derin sinir ağlarının, GPU ve diğer donanımsal gelişmeler ile birlikte hesaplama maliyetini düşürdüğü görülmüştür (19). Bu tez çalışmasında, bütün model eğitimleri 8 GB belleğe sahip NVidia Quadro P4000 grafik işlem birimi üzerinde yapılmıştır. GPU kullanımının eğitim sürecini büyük oranda azalttığı görülmüştür.

Derin öğrenme yaklaşımında, katmanlar kullanılarak özellik çıkarımı gibi işlemler yapılmaktadır. Katmanlar arasındaki ilişki doğrusal olmamakta ve her bir katman, bir önceki katmanın çıktısını girdi olarak kabul etmektedir (20). Derin öğrenmenin çalışma prensibi veriyi en iyi temsil eden özellikler üzerinden öğrenmeyi gerçekleştirmeye dayanmaktadır. Örneğin, bir görüntü verisi için piksel başına yoğunluk değerlerinin bir vektörü veriyi temsil eden bir özelliktir. Derin öğrenme algoritmaları ile bu özelliklerden hangisinin veriyi daha iyi temsil edebildiği çıkartılabilmektedir (21).




Şekil 4. İleri yönlü bir derin sinir ağı yapısı (Song’dan, 22).

Derin öğrenme algoritmaları, hareket algılama, yüz tanıma, sağlık teknolojileri, nesne ayırt etme ve nesne algılama gibi alanlarda çalışmaktadır (23). Günümüzde Google, Facebook ve Microsoft gibi teknoloji firmaları görüntü tanıma ve nesne sınıflandırma gibi işlemlerde derin öğrenme yaklaşımını kullanmaktadır (18).

Başlıca Derin öğrenme algoritmaları, konvolüsyonel sinir ağları, tekrarlı sinir ağları, sınırlı boltzmann makineleri, derin inanç ağları ve derin oto-kodlayıcılardır. Yapılan tez çalışmasında pulmoner nodülün benign/malign sınıflandırması için CNN yöntemi kullanıldı.

3.2. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks-CNN)

Konvolüsyonel sinir ağları genellikle görüntü tanıma ve nesne algılama problemlerinde kullanılmaktadır. İleri yönlü sinir ağlarından biri olan CNN çok katmanlı bir yapıya sahiptir ve her bir katman bir görüntüye ait farklı özellikleri tanımak üzere eğitilmiştir. Bir giriş görüntüsünün bilgileri sırasıyla konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katmandan geçerek çıkış katmanına gelmektedir. Çıkış katmanından çıktılar tek bir sınıf veya görüntüyü en iyi tanımlayan sınıfların olasılığı olarak verilmektedir (23). CNN ile yapılmış bir sınıflandırma örneğine ait mimari Şekil 5'te verilmiştir.



Şekil 5. El yazısı rakamlarını sınıflandırma için bir CNN mimarisi (Marco' dan, 24).

3.2.1. Giriş Katmanı (Input Layer)

CNN mimarisindeki giriş katmanında görüntü verisi sayısal veriye dönüştürülmektedir. Bilgisayar tarafından görüntünün her pikseline 0 ile 255 aralığında değer verilerek bir matris oluşturulmaktadır. Bu matris konvolüsyon katmanına geçerek belirli işlemlere tabi tutulmaktadır.

3.2.2. Konvolüsyon Katmanı (Convolutional Layer)

Konvolüsyon katmanı CNN mimarisinin ilk katmanıdır. Bu katmanda görüntüye bir dizi filtreleme işlemi uygulanmaktadır. Filtrenin boyutu görüntü matrisinin boyutundan daha küçük olmaktadır. Oluşturulan filtre, görüntü matrisi üzerinde, genişlik ve yükseklik boyunca kaydırılarak konvolüsyon işlemi gerçekleştirilmektedir. Bu işlem sonucu görüntüyü en iyi niteleyen özellikler çıkarılmaktadır. (25). Konvolüsyon işlemi sonucu yeni bir görüntü matrisi elde edilmektedir (26). Oluşacak yeni görüntü matrisinin boyutu “Eşitlik 1” denklemi ile hesaplanmaktadır.

$$\text{Görüntü matrisinin boyutu} = \frac{N-W}{S} + 1 \quad (\text{Eşitlik 1})$$


Burada N görüntü matrisinin boyutunu, W filtre boyutunu, S ise filtrenin her bir adımında ilerleyeceği piksel sayısının ifade etmektedir. Şekil 5’teki gibi 28×28 ’lik bir görüntü matrisi için 5×5 ’lik bir filtre uygulandığında çıkış boyutu 24×24 olan bir görüntü matrisi elde edilmektedir.

3.2.2.1. Aktivasyon Fonksiyonları

Derin ağlarda, doğrusal olmayan aktivasyon fonksiyonları sayesinde ağ daha güçlü şekilde eğitilebilmektedir. Konvolüsyon katmanındaki çıkış sinyaline aktivasyon fonksiyonu uygulanarak doğrusal olmayan hale getirilmektedir. Ağın doğrusal olmayan durumları öğrenmesi sağlandığında ses, görüntü ve metin gibi karmaşık verilerden öğrenme işlemi gerçekleştirilebilmektedir (27).

ReLU fonksiyonu, Sigmoid fonksiyonu, Hiperbolik Teğet fonksiyonu ve Swish fonksiyonu sıklıkla kullanılan aktivasyon fonksiyonlarından bazılarıdır (27). ReLU fonksiyonu derin öğrenmede hızlı çalışması ve sadeliği açısından derin öğrenme alanında en

çok tercih edilen fonksiyondur (28). Sıklıkla kullanılan aktivasyon fonksiyonları Şekil 6’da gösterilmiştir.




Şekil 6. Sıklıkla kullanılan aktivasyon fonksiyonları (Çınar’dan, 29).

Bir katmandaki her nöronun aktivasyon fonksiyonu aynıdır ancak farklı katmanların aktivasyon fonksiyonları farklı olabilmektedir (30). Bu tez çalışmasındaki ağı eğitiminde, ara katmanların aktivasyon fonksiyonu olarak ReLU ve tanh fonksiyonları, son katmanda ise ikili sonuç $[0,1]$ vermesi için Sigmoid fonksiyonu kullanılmıştır (31).

3.2.3. Havuzlama katmanı (Max-Pooling Layer)

Havuzlama katmanı CNN mimarisinde konvolüsyonel katmanlar arasında bulunmaktadır. Bu katmanda görüntünün boyutu azaltılarak modelin karmaşıklığının giderilmesi amaçlanmaktadır. Standart CNN mimarisinde havuzlama katmanında filtre 2×2 ve adım sayısı 2 olarak belirlenmiştir (32).

Şekil 7’de görüntü matrisi üzerinde 2×2 boyutlu bir filtre her adımda 2 piksel gezerek ilerlemektedir. Her adımda 2×2 pencere içinde en büyük sayının olduğu piksel alınmaktadır. Çıkış verisi olarak Eşitlik 1’e göre 2×2 boyutlu görüntü matrisi elde edilmektedir. Bu katmandaki maksimum işlemi ile girdileri kolay bir şekilde sınıflandırabilecek daha sağlam bir modelin oluşturulması amaçlanmaktadır (32).



Şekil 7. Max-Pooling işlemi uygulanmış görüntü matrisi (Ergin'den, 33).

3.2.4. Tam Bağlı Katman (Fully Connected Layer)

CNN mimarisinde havuzlama katmanından sonra tam bağlı katman bulunmaktadır. Tam bağlı katmanın yapısı standart sinir ağları yapısı ile oldukça benzerlik göstermektedir (34). Katmanlardaki nöronlar bir sonraki katmanlardaki nöronlara tamamen bağlanmaktadır (30). Bu katmanda, görüntüye ait hangi özelliklerin hangi sınıfla daha iyi eşleştiği bilgisi çıkarılmaktadır. Böylece farklı sınıflar için en doğru olasılıklar elde edilebilmektedir (35).

3.2.4.1. Düzleştirme (Flattening)

Düzleştirme işlemi ile, konvolüsyon katmanının sonucunda çıkan çok boyutlu dizi, yeniden şekillendirme işlemi kullanılarak tek boyutlu diziye dönüştürülmektedir (34).

3.2.5. Çıkış Katmanı (Output Layer)

CNN mimarisindeki çıkış katmanında görüntünün sınıflandırma işlemi yapılmaktadır. Çıkış değeri sınıf sayısına eşit olmaktadır. Bu katmanda istenen sınıf sayısına göre farklı fonksiyonlar tercih edilmektedir. Sınıf sayısı ikiden fazlaysa softmax fonksiyonu tercih edilmektedir. softmax fonksiyonu ile sınıflar 0 ile 1 aralığında olasılık değerleri almaktadır.


Bu çalışmada çıkış katmanının ikili sonuç (benign-malign) vermesi istenmektedir. Bu nedenle sigmoid fonksiyonu kullanılmıştır. sigmoid fonksiyonu 0 ile 1 aralığında olasılık değerleri vermektedir (32). Bu olasılık değerleri 0.5'ten küçükse 0 etiketi, 0.5 ve üzerinde ise 1 etiketi olarak sınıflandırma yapılmıştır.

3.2.6. Aşırı uydurma (Overfitting) ve Yetersiz uydurma (Underfitting)

Bir CNN modelindeki eğitim verisinin hata oranı ile test verisinin hata oranının aralarındaki fark çok fazla ise aşırı uydurma riski söz konusu olmaktadır. Aşırı uydurma olayı modelin eğitim verisinin özelliklerini ezberlediği anlamına gelmektedir (36).

Eğitim verisi üzerinde basit olarak kurulan bir model, test verisi üzerinde başarısız tahminler yapılmasına neden olmaktadır. Eğitim verisinin hatasının yeterince küçük çıkmadığı durumlarda yetersiz uydurma söz konusu olmaktadır (36).

Şekil 8’de görüldüğü gibi modelin karmaşıklığının artması durumunda aşırı uydurma riski artmaktadır. Aşırı uydurmaktan kaçınmak için dropout işlemi ile katmanlardaki bazı nöronları ve onların bağlantılarını iptal ederek modelin eğitim verisinin özelliklerini ezberlemesi engellenmektedir. Örneğin; görüntü sınıflandırma için model, görüntüye ait en zayıf özellikleri dropout ile unutabilmektedir (37).



Şekil 8. Model karmaşıklığının tahmini hata üzerine etkisi (Şimşek’ten, 38).

3.3. Toraks BT Görüntülerinin Eğitime Hazırlanması

Derin öğrenme yaklaşımı ile pulmoner nodül karar destek sistemi Rstudio 3.6.1 sürümü ile geliştirildi. Derin öğrenme modelinin oluşturulması ve eğitimi için Keras paketi kullanıldı. Keras, Python'da yazılmış ve TensorFlow veya Theano'nun üzerinde çalışabilen, yüksek seviyeli bir sinir ağları uygulama programlama arayüzüdür (39). Keras aynı zamanda konvolüsyonel sinir ağları için önceden tanımlanmış fonksiyonlar içermektedir. Bu sayede eğitimin hızlandırılmasına imkân sağlamaktadır (31).

Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji Bölümünde “Pulmoner Nodül” tanısı koyulmuş 600 hastanın toraks BT çekiminin görüntüleri “.png” formatında kaydedildi. BT görüntülerinde nodül rastlanan kesitler alınarak toplamda 1111 görüntü elde edildi. 1111 görüntü eğitim ve test veri seti olarak bölündü (Tablo 1).

Tablo 1. Görüntü sayılarını veri setlerine göre dağılımı

Veri Seti	Veri Yüzdesi	Veri Sayısı
Eğitim	%72	800
Test	%28	311

Toraks BT görüntülerinin eğitime hazırlanması aşamasında görüntüleri bazı ön işleme yöntemleri uygulandı. Öncelikli olarak R Studio programı ile görüntüler okundu ve kaydedildi (Resim 1). Okunan görüntüler RGB uzayından Gri Ölçekli uzaya dönüştürüldü (Resim 2).




Resim 1. Bir hastaya ait orijinal toraks BT görüntüsünde pulmoner nodül bulunan kesit




Resim 2. Gri ölçeklendirilmiş görüntü

Bu işlemlerin ardından görüntülerin köşe konumlarında bulunan, hastaya ve toraks BT çekimine ait bilgilerin görüntü üzerinden silinmesi için eşikleme işlemi yapıldı (Resim 3).




Resim 3. Eşikleme işlemi uygulanmış görüntü

Eşikleme işlemi yapılan görüntüdeki gürültüyü gidermek amacıyla erozyon işlemi uygulandı (Resim 4). Bu işlem ile görüntü içindeki küçük nesneler silindi.



Resim 4. Erozyon işlemi uygulanmış görüntü

Bu işlemlerin ardından görüntüdeki akciğer görüntüsünün alınıp etrafındaki siyah bölgenin küçültülmesi amacıyla nesnenin bulunduğu konum belirlendi. Belirlenen konuma göre resim kırıldı (Resim 5).



Resim 5. Kırpılmış görüntü


Orijinal görüntüden, belirlenen piksel konumlarındaki görüntü çekildi. Böylece görüntüler gürültüden arındırılarak eğitime hazır hale getirildi (Resim 6).



Resim 6. Gürültüden arındırılmış görüntü

3.4. Sistemin Eğitilmesi ve Test Edilmesi

Sistemin eğitimi için kurulan model şekildedeki (Şekil 9) gibidir. Sistemin eğitimi için farklı modeller kurularak, filtre sayısı, çekirdek boyutu, öğrenme katsayısı, aktivasyon fonksiyonu, kaçınma değeri gibi hiper-parametrelerin CNN modelinin doğruluğu ve kaybı üzerindeki etkileri araştırıldı.



Şekil 9. 600×400 piksel boyutlu pulmoner nodül görüntü veri seti için kurulan model

Şekil 9’da görülen modelin giriş katmanında 600×400 piksel boyutlu görüntülere 3×3 piksel boyutlu 32 tur filtreleme işlemi uygulandı. Bu katmanda aktivasyon fonksiyonu olarak tanh fonksiyonu seçildi. İkinci katmanda görüntüye 2×2 piksel boyutlu havuzlama işlemi uygulandı. Üçüncü katmanda görüntüye 3×3 boyutlu 64 tur filtreleme işlemi uygulandı ve aktivasyon fonksiyonu olarak tanh fonksiyonu seçildi. Dördüncü katmanda 2×2 piksel boyutlu havuzlama işlemi yapıldı. Beşinci katmanda görüntüye 3×3 boyutlu 64 tur filtreleme işlemi uygulandı ve aktivasyon fonksiyonu olarak tanh fonksiyonu seçildi. Altıncı katmanda 2×2 piksel boyutlu havuzlama işlemi yapıldı. Yedinci katmanda 3×3

boyutlu 128 tur filtreleme işlemi uygulandı ve aktivasyon fonksiyonu olarak tanh fonksiyonu seçildi. Sekizinci katmanda 2×2 piksel boyutlu havuzlama işlemi yapıldı. Dokuzuncu katmanda düzleştirme (flatten) işlemi uygulanarak veri tek boyutlu dizi haline getirildi. Onuncu katmanda aşırı uydurmayı engellemek amacıyla dropout işlemi yapıldı ve kaçınma değeri 0.5 olarak seçildi. On birinci katmanda dizi boyutu 64 olarak belirlendi ve aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanıldı. Çıkış katmanında dizi boyutu 1 olarak belirlendi ve aktivasyon fonksiyonu olarak ikili sonuç vermesi sebebiyle sigmoid fonksiyonu kullanıldı. Konvolüsyon işleminin uygulandığı her katmanda regülerizasyon işlemi yapıldı. Bu işlem ile kayıp değerinin azaltılması amaçlandı.

Modelde optimizasyon algoritması olarak rmsprop tercih edildi ve öğrenme katsayısı (learning rate) $1e - 4$ olarak belirlendi. Öğrenme katsayısı ağırlıkların güncellenme sıklığını etkileyen bir parametredir (40).

Bir modelin eğitimi esnasında bütün veriler aynı anda değil de parçalar halinde eğitime katılmaktadır. Her adımda veri kümesi değişerek ve ağırlıklar güncellenerek model için en uygun ağırlık değerlerinin bulunması amaçlanmaktadır. Bu işlemin tekrarlandığı eğitim adımlarının her birine epoch adı verilmektedir. Epoch sayısının bir üst sınırı yoktur ancak her model için optimal bir değeri vardır. Bu model için epoch sayısı 1000 olarak belirlendi.


4. BULGULAR

Pulmoner nodül karar destek sistemi için geliştirilen modeller Tablo 2’ de verildi. Görüntü önışleme, filtre sayıları, regülarizasyon işlemleri (Reg), aktivasyon fonksiyonu (Akt), öğrenme katsayısı (lr), *epoch* sayısı gibi parametrelerin doğruluk ve kayıp üzerine etkileri değeriendirildi.

Tablo 2. Sistemin eğitilmesinde farklı hiper-parametreler için kurulan modeller

Model	Önişleme	Filtreleme	Reg	Akt	lr	Epoch	Doğruluk	Kayıp
Model 1	Yok	32-64-128-128	Yok	Relu	1e-4	30	0.43	8.67
Model 2	Yok	32-64-128-128	Yok	Tanh	1e-4	30	0.56	0.69
Model 3	Yok	32-64-64	Yok	Relu	1e-4	30	0.56	6.68
Model 4	Yok	32-64-64	Yok	Tanh	1e-4	30	0.5627	0.6930
Model 5	Yok	32-64-64-128	Yok	Relu	1e-4	30	0.5627	6.68
Model 6	Yok	32-64-64-128	Yok	Tanh	1e-4	30	0.5627	0.6902
Model 7	Yok	32-64-128-128	Var	Relu	1e-4	30	0.7202	1.8173
Model 8	Yok	32-64-128-128	Var	Tanh	1e-4	30	0.7427	0.83
Model 9	Yok	32-64-64	Var	Relu	1e-4	50	0.7202	1.9750
Model 10	Yok	32-64-64	Var	Tanh	1e-4	50	0.5627	0.7006
Model 11	Yok	32-64-64-128	Var	Relu	1e-4	50	0.7266	1.6543
Model 12	Yok	32-64-64-128	Var	Tanh	1e-4	50	0.7588	1.2205
Model 13	Yok	32-64-64-128	Var	Tanh	1e-3	50	0.5627	6.7164
Model 14	Yok	32-64-64-128	Var	Tanh	1e-5	50	0.7524	0.8539
Model 15	Ayrımlılık	32-64-64-128	Var	Relu	1e-4	50	0.7138	1.7977
Model 16	Ayrımlılık	32-64-64-128	Var	Tanh	1e-4	50	0.7459	1.1509
Model 17	Medyan (2)	32-64-64-128	Var	Relu	1e-4	50	0.7106	1.3793
Model 18	Medyan (2)	32-64-64-128	Var	Tanh	1e-4	50	0.7170	1.1873
Model 19	Medyan (3)	32-64-64-128	Var	Relu	1e-4	50	0.6784	2.4571
Model 20	Medyan (3)	32-64-64-128	Var	Tanh	1e-4	50	0.7170	1.330
Model 21	Veri Ç.	32-64-64-128	Var	Tanh	1e-4	100	0.7234	1.4842
Model 22	Veri Ç.	32-64-64-128	Var	Tanh	1e-4	100	0.7395	1.3686
Model 23	Yok	32-64-64-128	Var	Tanh	1e-4	10000	0.7813	1.6576
Model 24	Yok	32-64-64-128	Var	Tanh	1e-4	1000	0.7652	1.4362

Modellerin eğitimde görüntülere; ayrımlılık, medyan filtre ve veri çeşitlendirme gibi önışleme yöntemleri uygulandı (Resim 7). Bu önışleme yöntemlerinin başarıyı artırmadığı görüldü. Daha yüksek başarılar önışleme yöntemleri uygulanmayan modeller ile elde edildi.




Resim 7. Ön işleme uygulanmış görüntüler. **(a)** Orijinal görüntü. **(b)** Medyan filtresi uygulanmış görüntü. **(c)** Ayrımlılık uygulanmış görüntü. **(d)** Veri çeşitlendirme uygulanmış görüntü

Modelin katman sayısı ve filtre sayısı da eğitimi etkileyen bir diğer parametredir. Denemeler sonucunda 32-64-64-128 filtre sayılı, 4 katmanlı modelin sistemin eğitimi için uygun olduğu görüldü. Model 7'den itibaren katmanlara regülerizasyon işlemi eklendi. Regülerizasyon işlemi kayıp değerini azaltmaya yönelik bir işlemdir ve başarıyı artırdığı görüldü.


En önemli hiper-parametrelerden biri de aktivasyon fonksiyonudur. Modele uygun aktivasyon fonksiyonunu seçmek oldukça önemlidir. Geliştirilen modellerde, aktivasyon fonksiyonu olarak ReLU ve tanh fonksiyonları denendi. Denemeler sonucunda katmanlarda tanh fonksiyonunun kullanımının başarıyı artırdığı görüldü.

Eğitim sırasında ağırlıkların güncellenme sıklığını etkileyen öğrenme katsayısı parametresinin denemeler sonucunda optimal değerinin $1e - 4$ olduğu görüldü. Bu sayıyı artırmak veya azaltmak başarıyı düşürdü.

Modellerde epoch sayısı 30, 50, 100, 1000 olarak denendi. Doğruluğu en yüksek olan Model 12 için 10000 epoch denemesi yapıldı (Model 23) ve test sonuçlarında %78 doğruluk ve 1.65 kayıp elde edildi. Model 23 için doğruluk ve kayıp Şekil 10’da verildi.



Şekil 10. Model 23 için doğruluk ve kayıp (ilk 100 epoch)



Şekil 11. Başarısı en yüksek olan model (Model 23) için CNN ağı

Başarısı en yüksek olan Model 23 (Şekil 11) için 5 kat çapraz doğrulama yapıldı. 1070 görüntü ile yapılan 5 kat çapraz doğrulama her kat için 1000 epoch çalıştırıldı. Çapraz doğrulama sonuçları Tablo 4’te verildi.

Tablo 3. Çapraz doğrulama için verinin bölünmesi

Veri					
1.Kat	Test (214)	Eğitim (214)	Eğitim (214)	Eğitim (214)	Eğitim (214)
2. Kat	Eğitim (214)	Test (214)	Eğitim (214)	Eğitim (214)	Eğitim (214)
3. Kat	Eğitim (214)	Eğitim (214)	Test (214)	Eğitim (214)	Eğitim (214)
4.Kat	Eğitim (214)	Eğitim (214)	Eğitim (214)	Test (214)	Eğitim (214)
5.Kat	Eğitim (214)	Eğitim (214)	Eğitim (214)	Eğitim (214)	Test (214)

Çapraz doğrulama için 1070 görüntü 5 gruba bölündü (Tablo 3). Her grupta 107 benign ve 107 malign nodül görüntüsü olmak üzere toplamda 214 görüntü bulunmaktadır. Her katta gruplar sırası ile test veri seti olarak alınarak doğrulama gerçekleştirildi.

Tablo 4. Model 23. için 5 kat çapraz doğrulama sonuçları

	Doğruluk	Kayıp	Hassasiyet	Özgüllük
1. Kat	0.84	1.56	0.77	0.84
2. Kat	0.82	0.81	0.77	0.70
3. Kat	0.72	1.46	0.79	0.72
4. Kat	0.78	1.19	0.76	0.77
5. Kat	0.72	1.80	0.78	0.71
Ortalama	0.766	1.36	0.77	0.75

En yüksek doğruluk %84 iken ortalama doğruluk %76.6 olarak elde edildi. Sistemin gerçekte malign olan nodüllerin ne kadarına malign teşhisi koyabildiği ve benign nodüllerin ne kadarını benign olarak saptayabildiğini görmek amacıyla duyarlılık (sensitivity) ve özgüllük (specificity) değerleri hesaplandı.

Tablo 5. Çapraz doğrulama 1. kat için hassasiyet ve özgüllük

REFERANS			
		Malign	Benign
TAHMİN	Malign	83	17
	Benign	24	90

Çapraz doğrulama 1. kat için referans ve tahmin değerleri Tablo 5’te verildi. Toplam 107 malign görüntüsünden 83 tanesi malign olarak tahmin edildi ve 1. Kat için hassasiyet %77 olarak hesaplandı. Toplam 107 benign görüntüsünden 90 tanesi benign olarak tahmin edildi ve 1. kat için özgüllük değeri %84 olarak hesaplandı. Beş kat çapraz doğrulama sonucunda ortalama hassasiyet %77 ve ortalama özgüllük %75 olarak hesaplandı.

5. TARTIŞMA ve SONUÇ

Günümüzde teknolojik gelişmeler, yapay zekanın insan hayatında daha fazla yer edinmesini sağlamıştır. Yapay zekanın özellikle sağlık alanında kullanılmaya başlanmasıyla hekimlere ikinci bir görüş sunularak hastalıklara konulan tanı ve tespitin doğruluğunun artırılabilmesi ve erken süreçte tedaviye başlanılabilmesi mümkün hale gelmiştir.

Son yıllarda derin öğrenme algoritmalarıyla özellikle sağlık alanında tıbbi görüntüler kullanılarak birçok hastalığın tanısı için önemli çalışmalar yapılmaktadır. Makine öğrenmesi yöntemlerinden biri olan derin öğrenme algoritmaları, sağlık alanında büyük veri kümesine sahip tıbbi görüntüler üzerinden analiz yapabilme konusunda geleneksel makine öğrenmesi modellerinden daha başarılı sonuçlar vermektedir (41). Derin sinir ağlarından görüntüler üzerinde en iyi sonuçlar veren konvolüsyonel sinir ağlarıdır. CNN'ler minimum ön işleme gerektirmesi ve veriyi en iyi temsil eden özellikleri kendisi öğrenebilmesi sebebiyle sıklıkla tercih edilmektedir (20, 23). Konvolüsyonel sinir ağları ile geliştirilen karar destek sistemi ile literatürdeki benzer çalışmalar Tablo 6'da karşılaştırıldı.

Bu çalışmalar ile konvolüsyonel sinir ağları ile nodül tespiti, nodül tipi sınıflandırma ve benign-malign sınıflandırma yapılabildiği görüldü. Bu tezde yapılan çalışma için kullanılan veri sayısı literatürdeki çalışmalar baz alınarak belirlendi. Çalışmaların geneline bakıldığında LIDC veri tabanı kullanıldığı görülmektedir. Benign-malign sınıflandırma için en yüksek doğruluk Causey vd. tarafından LIDC veri tabanından 12000 görüntü kullanılarak yapılan çalışmada %94.6 olarak verilmiştir(48). Sun ve arkadaşları tarafından LIDC veri setinden 90000 toraks BT görüntüsünün kullanıldığı çalışmada doğruluk değeri %89 olarak verilmiştir. Tablonun geneline bakıldığında çalışmalarda görüntü veri sayısının yüksek oluşunun çalışmaların başarılarını artırdığı görülmektedir.

Önerilen tez çalışmasında Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji Polikliniği hasta verileri kullanılarak akciğer pulmoner nodül hastaları için hem bölgesel ve ulusal bir BT görüntü veritabanı hem de prototip bir karar destek sistemi geliştirilmiştir. Geliştirilen klinik karar destek sistemi ile derin öğrenme algoritmalarının görüntüler üzerinden akciğer kanseri tanısı koyabilmesinin başarısı test edildi. Birbirinden farklı olan 24 model kuruldu ve ağ parametrelerinin test başarımı üzerine etkileri incelendi. En yüksek başarıma sahip model ile 1070 görüntü üzerinde 5 kat çapraz doğrulama yapıldı ve en yüksek doğruluk değeri %84 ve ortalama doğruluk değeri %76.6 olarak elde edildi. Bu tez çalışması

sonucunda CNN'lerin toraks BT görüntüleri üzerinden pulmoner nodülleri sınıflandırmada başarılı olduğu görülmüştür.

Literatürdeki benzer çalışmalara bakıldığında yapılan çalışmanın oluşturulan bölgesel ve ulusal BT toraks görüntü veritabanı ile farklı olarak öne çıktığı ve bu nedenle sınırlı görüntü sayısına rağmen başarılı olduğu görülmektedir.

Tablo 6. Literatürdeki benzer çalışmalara ait başarımlar

Literatür Çalışması	Yılı	Yöntem	Amaç	Veri sayısı	Veri t.	Doğru -luk	Duyar -lılık	Özgül -lük
GINNEKEN vd.(2)	2015	CNN	Nodül tespiti	865	LIDC	-	%71	-
Ciampi vd.(3)	2017	MS-CNN	Nodül tipi sınıflandırma	943	MILD	%72.9	%83	-
KUMAR vd.(4)	2015	Otokod-layıcı	B-M sınıflandırma	4303	LIDC	%75	%83	-
Riccardi vd.(5)	2011	CNN	Nodül tespiti	154	LIDC	%60	%71	-
Kai vd.(43)	2015	DBN CNN	B-M sınıflandırma	1010	LIDC	-	%73.4 %73.3	%82 %78
Li vd.(44)	2016	CNN	Nodül tespiti	1010	LIDC	%86	%89	-
Zhao vd.(45)	2018	A-CNN	B-M sınıflandırma	1018	LIDC	%82	-	-
Shen vd.(42)	2017	MC-CNN	B-M sınıflandırma	1010	LIDC	%87	%77	%93
Sun vd.(46)	2017	CNN	B-M sınıflandırma	90000	LIDC	%89	-	-
Silva vd.(47)	2017	CNN	B-M sınıflandırma	3243	LIDC	%94.5	%94.7	%95.1
Causey vd.(48)	2018	CNN	B-M sınıflandırma	12000	LIDC	%94.6	%94.8	%94.3
Zhu vd.(49)	2018	CNN	B-M sınıflandırma	1000	LIDC	%90	-	-
Nóbrega vd.(50)	2018	CNN	B-M sınıflandırma	1018	LIDC	%88.4	%85.3	-
Song vd.(51)	2017	CNN	B-M sınıflandırma	4576	LIDC	%84.2	%84	%84.3
Han vd.(52)	2018	CNN	B-M sınıflandırma	1160	LIDC	%82.5	%96.6	%71.4
Xie vd.(53)	2018	CNN	B-M sınıflandırma	1972	LIDC	%89.5	584.2	%92
Önerilen Çalışma	2020	CNN	B-M sınıflandırma	1070	KTÜ Farabi H.	%76.6	%77	%75

Geliştirilen karar destek sisteminin radyologlar için teşhiste ikinci görüş sağlayacak yararlı bir sistem olacağı düşünülmektedir. Bölgesel ve ulusal BT akciğer toraks görüntü veritabanı olarak öne çıkmaktadır. Bu bağlamda, bu konuda ileride yapılacak çalışmalara ışık tutacağı düşünülmektedir. Bununla birlikte gelecek çalışmalarda CNN ağının entegre yöntemler ile kullanılarak başarımın artırılması ayrıca tıbbi görüntü verilerinin klinik ve genetik verilerle desteklenerek daha sağlam bir karar destek sistemi geliştirilmesi hedeflenmektedir.



6. KAYNAKLAR

1. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, Wang Y, Dong Q, Shen H, Wang Y (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology* 2: 230–243.
2. van Ginneken B, Setio AAA, Jacobs C, Ciompi F (2015). Off-the-shelf convolutional neural network features for pulmonary nodule detection in computed tomography scans. *IEEE 12th International Symposium on Biomedical Imaging*, New York, 16-19 April 2015, 286–289.
3. Ciompi F, Chung K, Van Riel SJ, Setio AAA, Gerke PK, Jacobs C, Scholten ET, Schaefer-Prokop C, Wille MMW, Marchiano A (2017). Towards automatic pulmonary nodule management in lung cancer screening with deep learning. *Scientific Reports* 7: 46479.
4. Kumar D, Wong A, Clausi DA (2015). Lung nodule classification using deep features in CT images. *IEEE 12th Conference on Computer and Robot Vision*, Canada, 3-5 June 2015, 133–138.
5. Riccardi A, Petkov TS, Ferri G, Masotti M, Campanini R (2011). Computer-aided detection of lung nodules via 3D fast radial transform, scale space representation, and Zernike MIP classification. *Medical Physics* 38: 1962–1971.
6. Clinic C (2016). Pulmonary Nodules [online]. Available from: <https://my.clevelandclinic.org/health/diseases/14799-pulmonary-nodules>. [Accessed 23 October 2019].
7. Swensen SJ, Jett JR, Hartman TE, Midthun DE, Mandrekar SJ, Hillman SL, Sykes AM, Aughenbaugh GL, Bungum AO, Allen KL (2005). CT screening for lung cancer: five-year prospective experience. *Radiology* 235: 259–265.
8. Armato SG, Giger ML, Moran CJ, Blackburn JT, Doi K, MacMahon H (1999). Computerized detection of pulmonary nodules on CT scans. *Radiographics* 19: 1303–1311.
9. Dangeti P (2017). *Statistics for machine learning* Packt Publishing Ltd, Birmingham, Sayfa: 8-10.

10. Krizhevsky A, Sutskever I, Hinton GE (2012). Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 1097–1105.
11. Alpaydin E (2009). Introduction to machine learning MIT press, London, Sayfa: 11-12.
12. Bulut T (2019). Yapay Zeka [online]. Available from: <https://tevfikbulut.com/2019/11/03/yapay-zeka/>. [Accessed 5 January 2020].
13. Karahan M (2011). İstatistiksel tahmin yöntemleri: Yapay sinir ağları ile ürün talep tahmini uygulaması Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Konya.
14. Kayış MK (2019). Mimari tasarımda yapay zeka: Evrişimli yapay sinir ağlarının vaziyet planı tasarımında kullanımı İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Gayrimenkul Geliştirme Anabilim Dalı, İstanbul.
15. Öztemel E (2003). Yapay Sinir Ağları Papatya Yayıncılık, İstanbul, Sayfa: 75-77.
16. Allahverdi N (2002). Uzman sistemler: Bir yapay zeka uygulaması Atlas Yayın Dağıtım, İstanbul, Sayfa: 100-116.
17. Saygılı YS (2008). İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi Ankara Kara Harp Okulu Savunma Bilimleri Enstitüsü, Harekat Araştırması Anabilim Dalı, Ankara.
18. Şeker A, Diri B, Balık HH (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi 3: 47–64.
19. Schmidhuber J (2015). Deep learning in neural networks: An overview. Neural Networks 61: 85–117.
20. Deng L, Yu D (2014). Deep learning: Methods and Applications. Foundations and Trends in Signal Processing 7: 197–387.
21. Song HA, Lee SY (2013). Hierarchical representation using NMF. International conference on neural information processing, Malaysia, 3-6 November, 466–473.

22. Nielsen M (2019). Introducing convolutional networks [online]. Available from: <http://neuralnetworksanddeeplearning.com/chap6.html>. [Accessed 1 November 2019].
23. Rasheed SM (2019). Object Detection From Images Using Deep Learning. *Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Elazığ*.
24. Saha S (2018). A Comprehensive Guide to Convolutional Neural Networks [online]. Available from: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>. [Accessed 29 October 2019].
25. Marco L, Farinella GM (2018). Computer Vision for Assistive Healthcare Academic Press, London, Sayfa: 131-132.
26. Liu L, Shen C, van den Hengel A (2015). The treasure beneath convolutional layers: Cross-convolutional-layer pooling for image classification. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, 7-12 June, 4749–4757*.
27. Kızrak A (2019). Comparison of Activation Functions for Deep Neural Networks [online]. Available from: <https://towardsdatascience.com/comparison-of-activation-functions-for-deep-neural-networks-706ac4284c8a>. [Accessed 28 October 2019].
28. Ramachandran P, Zoph B, Le Q V (2017). Searching for activation functions. *arXiv preprint arXiv:171005941*.
29. Çınar AC (2017). ImageNet Classification with Deep Convolutional Neural Networks [online]. Available from: <https://ahmetcevahircinar.com.tr/2017/08/11/imagenet-classification-with-deep-convolutional-neural-networks/>. [Accessed 15 October 2019].
30. Heaton J (2013). Fundamental Algorithms. Artificial intelligence for humans Heaton Research, 32-35. <https://www.heatonresearch.com/book/aifh-vol1-fundamental.html>.

31. Chollet F, Allaire JJ (2018). Deep Learning mit R und Keras: Das Praxis-Handbuch von den Entwicklern von Keras und RStudio MITP-Verlags GmbH & Co. KG, New York, Sayfa: 1-20.
32. Beysolow II T (2017). Introduction to Deep Learning Using R: A Step-by-Step Guide to Learning and Implementing Deep Learning Models Using R Apress, San Francisco, Sayfa:110-112.
33. Ergin T (2018). Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır? [online] Available from: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>. [Accessed 18 October 2019].
34. Rahmon G (2018). Evaluation of procedurally generated terrains via artificial and convolutional neural networks İzmir Ekonomi Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, İzmir.
35. Deshpande A (2017). A Beginner's Guide To Understanding Convolutional Neural Networks [online] Available from: <https://adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>. [Accessed 05 October 2019].
36. Goodfellow I, Bengio Y, Courville A (2016). Deep learning MIT press, Cambridge, Sayfa: 110-115.
37. Özkan İ, Ülker E (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi 6: 85–104.
38. Simsek HK (2018). Overfitting-Underfitting-Cross Validation [online]. Available from: <https://medium.com/data-science-tr/overfitting-underfitting-cross-validation-b47dfda0cf4e>. [Accessed 05 November 2019].
39. Arnold TB (2017). kerasR: R Interface to the Keras Deep Learning Library. J Open Source Software 2: 296.
40. Chollet F, others (2015). Keras: The python deep learning library Manning Publications, New York, Sayfa: 48-50.

41. Sun W, Zheng B, Qian W (2016). Computer aided lung cancer diagnosis with deep learning algorithms. *Medical imaging 2016: computer-aided diagnosis* (Vol. 9785), p 97850Z.
42. Li W, Cao P, Zhao D, Wang J (2016). Pulmonary nodule classification with deep convolutional neural networks on computed tomography images. *Computational and mathematical methods in medicine* 2016.
43. Shen W, Zhou M, Yang F, Yu D, Dong D, Yang C, Zang Y, Tian J (2017). Multi-crop convolutional neural networks for lung nodule malignancy suspiciousness classification. *Pattern Recognition* 61: 663–673.
44. Hua K-L, Hsu C-H, Hidayati SC, Cheng W-H, Chen Y-J (2015). Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets and therapy* 8.
45. Zhao X, Liu L, Qi S, Teng Y, Li J, Qian W (2018). Agile convolutional neural network for pulmonary nodule classification using CT images. *International journal of computer assisted radiology and surgery* 13: 585–595.
46. Sun W, Zheng B, Qian W (2017). Automatic Feature Learning Using Multichannel ROI Based on Deep Structured Algorithms for Computerized Lung Cancer Diagnosis. *Computers in Biology and Medicine*. 89: 530–539.
47. Da Silva GLF, da Silva Neto OP., Silva AC, de Paiva AC, Gattass M (2017). Lung nodules diagnosis based on evolutionary convolutional neural network. *Multimedia Tools and Applications*. 76: 19039–19055.
48. Causey JL, Zhang J, Ma S, Jiang B, Qualls JA, Politte DG, Prior F, Zhang S, Huang X (2018). Highly accurate model for prediction of lung nodule malignancy with CT scans. *Scientific Reports*. 8: 9286.
49. Zhu W, Liu C, Fan W, Xie X (2018). DeepLung: Deep 3D dual path nets for automated pulmonary nodule detection and classification. In Proceedings of the IEEE Winter Conference on Applications of Computer Vision (WACV), Lake Tahoe, NV, USA, 12–15 March, 673–681
50. Da Nóbrega RVM, Peixoto SA, Da Silva SPP, Filho PPR (2018). Lung Nodule Classification via Deep Transfer Learning in CT Lung Images. In Proceedings of the

- IEEE 31st International Symposium on Computer-Based Medical Systems (CBMS), Karlstad, Sweden, 18–21 June. 244–249.
51. Song QZ, Zhao L, Luo XK, Dou XC (2017). Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *Journal of Healthcare Engineering*. 2017.
 52. Han G, Liu X, Zheng G, Wang M, Huang S (2018). Automatic recognition of 3D GGO CT imaging signs through the fusion of hybrid resampling and layer-wise fine-tuning CNNs. *Medical and Biological Engineering and Computing*. 2201–2212.
 53. Xie Y, Zhang J, Xia Y, Fulham M, Zhang Y (2018). Fusing texture, shape and deep model-learned information at decision level for automated classification of lung nodules on chest CT. *Information Fusion*. 42: 102–110.



Ek 1. Etik Kurul Onay Belgesi



T.C.
KARADENİZ TEKNİK ÜNİVERSİTESİ REKTÖRLÜĞÜ
KTÜ TIP FAKÜLTESİ
BİLİMSEL ARAŞTIRMALAR ETİK KURUL
BAŞKANLIĞI

Sayı : 24237859- 15

31.12.2018

Konu: Etik Kurul onay belgesi

Sayın; Dr. Öğr. Üyesi Burçin KURT
Biyoistatistik ve Tıp Bilişimi ABD.

“Derin Öğrenme Yaklaşımı ile Pulmoner Nodül Karar Destek Sistemi” başlıklı etik kurul 2018/291 protokol numaralı tez çalışma önerisi raportör ve etik kurul görüşleri doğrultusunda; tıbbi etik açıdan uygun olduğuna karar verilmiştir.

Bilginizi ve gereğini rica ederim.

Prof. Dr. Faruk AYDIN
Etik kurul Başkanı

Ek: 1 adet onay belgesi

Ek 1. (Devam)

KTÜ TIP FAKÜLTESİ BİLİMSSEL ARAŞTIRMALAR
ETİK KURULU KARAR FORMU

BAŞVURU BİLGİLERİ	ARAŞTIRMANIN AÇIK ADI	“Derin Öğrenme Yaklaşımı ile Pulmoner Nodül Karar Destek Sistemi”		
	ARAŞTIRMANIN PROTOKOL/PLAN KODU	2018 / 291		
	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Dr. Öğr. Üyesi Burçin KURT		
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Biyoistatistik ve Tıp Bilişimi		
	TEZ SAHİBİ/DİĞER ARAŞTIRICILAR, UNVANI/ADI/SOYADI	Yük.Lis.Öğr.Hilal TIRYAKI, Prof.Dr.Polat KOŞUCU		
	DESTEKLEYİCİ			
	ARAŞTIRMANIN NİTELİĞİ			
	ARAŞTIRMANIN TÜRÜ	TEZ ☒ AKADEMİK AMAÇLI ☐		
	ARAŞTIRMAYA KATILAN MERKEZLER	TEK MERKEZ ☒	ÇOK MERKEZLİ ☐	ULUSAL ☐

DEĞERLENDİRİLEN BELGELER	Belge Adı	Tarihi	Versiyon Numarası	Dili
	ARAŞTIRMA PROTOKOLÜ/PLANI			Türkçe ☒ İngilizce ☐ Diğer ☐
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
	OLGU RAPOR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
DEĞERLENDİRİLEN DİĞER BELGELER	Belge Adı		Açıklama	
	TÜRKÇE ETİKET ÖRNEĞİ	☐		
	SİGORTA	☐		
	ARAŞTIRMA BÜTÇESİ	☐		
	BIYOLOJİK MATERYEL TRANSFER FORMU	☐		
	İLAN	☐		
	YILLIK BİLDİRİM	☐		
	SONUÇ RAPORU	☐		
	GÜVENLİLİK BİLDİRİMLERİ	☐		
	DİĞER:	☐		

Ek 1. (Devam)

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR
ETİK KURULU KARAR FORMU

KARAR BİLGİLERİ	Karar No: 8	Tarih: 24.12.2018
	Dr.Öğr.Üyesi Burçin KURT'un sorumluluğunda yürütülmesi planlanan Yük.Lis.Öğr.Hilal TIRYAKI'ye ait "Derin Öğrenme Yaklaşımı ile Pulmoner Nodül Karar Destek Sistemi" başlıklı 2018/291 no.lu ve yukarıda başvuru bilgileri verilen araştırma/tez başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş, gerçekleştirilmesinde etik sakınca bulunmadığına; toplantıya katılan etik kurul üyelerinin oy birliği ile karar verilmiştir.	

KTÜ TIP FAKÜLTESİ BİLİMSEL ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
ÇALIŞMA ESASI	Klinik Araştırmalar Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof. Dr. Faruk AYDIN

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet	İlişki *	Katılım **	İmza
Prof. Dr. Faruk AYDIN Başkan:	Tıbbi Mikrobiyoloji	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Gamze ÇAN Başkan Yrd.	Halk Sağlığı	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Murat LİVAOĞLU Üye:	Plastik, Rekons. ve Estetik Cer.	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. S. Murat KESİM Raportör:	Tıbbi Farmakoloji	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Yılmaz BÜLBÜL Üye:	Göğüs Hastalıkları	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Murat ÇAKIR Üye:	Çocuk Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Şafak ERSÖZ Üye:	Tıbbi Patoloji	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☐ H ☒	İZİNLİ
Dr. Öğr. Üyesi Demet SAĞLAM AYKUT Üye:	Ruh Sağlığı ve Hastalıkları	KTÜ Tıp Fakültesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Dr. Öğr. Üyesi Hüseyin YAMAN Üye:	Tıbbi Biyokimya	KTÜ Tıp Fakültesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	

* :Araştırma ile İlişki
** :Toplantıda Bulunma

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Soyadı, Adı : TİRYAKİ, Hilal
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 30.08.1993-TRABZON
E-Posta : hilalbayrak.t@gmail.com

EĞİTİM BİLGİLERİ

Derece	Mezun Olduğu Kurumun Adı	Mezuniyet Yılı
Yüksek Lisans	Biyoistatistik ve Tıp Bilişimi	2020
Lisans	KTÜ İstatistik ve Bilgisayar Bilimleri Bölümü	2016
Lise	Akçaabat Anadolu Lisesi	2011

YABANCI DİL

İngilizce

BİLDİRİLER

Kesemen O, Bayrak H, Tezel Ö (2015). Goodness-of-fit test for directional data. 9th International Statistics Congress, Antalya, 28 Ekim- 1 Kasım 2015, 45-46.