



# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## X-ışınlı Göğüs İmgelerini Kullanarak Solunum Yolu Hastalıklarının Tespitinde Kuantum Transfer Öğrenme Modelinin Rolü

 Mesut TOĞAÇAR<sup>a,\*</sup>

<sup>a</sup> *Bilgisayar Teknolojileri Bölümü, Teknik Bilimler Meslek Yüksekokulu, Fırat Üniversitesi, Elazığ, TÜRKİYE*

*\* Sorumlu yazarın e-posta adresi: mtogacar@firat.edu.tr*

DOI: 10.29130/dubited.903358

### ÖZ

Solunum yolu hastalıkları çeşitli kanallar vasıtasıyla insanların solunum yollarına bulaşan; virüs ve bakteri gibi mikro organizmaların neden olduğu hastalıklardır. Bu canlılar vücudun bağışıklık sistemini zayıflatarak enfeksiyon oluşmasına yol açar ve bireyde kulak, burun, boğaz, solunum borusu ve akciğer gibi organlarda çoğalabilirler. Bunun sonucunda; zatürre, Ciddi Akut Solunum Sendromu (SARS), Orta Doğu Solunum Sendromu (MERS), Korona Virüs Hastalığı (COVID-19) gibi hastalıkların oluşmasına neden olabilmektedir ve erken müdahale alınmadığı takdirde hastaların ölümüne yol açabilmektedir. Bu çalışmada Kuantum modeli, derin öğrenme modeli ile yoğrularak farklı bir öğrenme yaklaşımı önerilmiştir. Bu model çeşitli kütüphane yazılımcıları tarafından verilen destekler ile gelişimini sürdürmektedir. Çalışmada kullanılan veri seti, solunum hastalıkları ve normal X-ışınları görüntülerinden oluşmaktadır. Deney analizinde, Kuantum Transfer Öğrenme (KTÖ) modeli kullanılarak veri setinin eğitimi gerçekleştirildi ve analiz sonuçlarından elde edilen doğruluk %92,50'di. Sonuç olarak, kuantum öğrenme modelinin derin öğrenme modelleri gibi umut verici sonuçlar verdiği bu çalışmada gözlemlendi.

**Anahtar Kelimeler:** *Derin öğrenme, Kuantum transfer öğrenme, Solunum hastalıkları, X-ışınları.*

## The Role of Quantum Transfer Learning Model in the Detection of Respiratory Diseases Using X-ray Chest Images

### ABSTRACT

Respiratory diseases are transmitted to the respiratory tract of people through various channels; diseases caused by micro-organisms such as viruses and bacteria. These creatures weaken the body's immune system, leading to the formation of infection, and can reproduce in the individual in organs such as the ear, nose, throat, respiratory tract and lung. As a result; it can cause diseases such as "pneumonia, Serious Acute Respiratory Syndrome (SARS), Middle East Respiratory Syndrome (MERS), Corona Virus Disease (COVID-19)" and can lead to the death of patients if early intervention is not received. In this study, a different learning approach is proposed by combining the quantum model and the deep learning model. This model continues its development with the support provided by various library software developers. The dataset used in the study consists of respiratory diseases and normal X-ray images. In the experimental analysis, the dataset was trained using the Quantum Transfer Learning (QTL) model and the accuracy rate obtained from the analysis results was 92.50%. As a result, it was observed in this study that the Quantum approach gave promising results like deep learning models.

**Keywords:** *Deep learning, Quantum transfer learning, Respiratory diseases, X-ray.*

# I. GİRİŞ

Son zamanlarda hava kirliliği insan sağlığı için küresel bir sorun haline gelmiştir ve dünyada milyonlarca insan bu durumdan etkilenmiştir. Solunum yolu hastalıklarının oluşmasında hava değişimi önemli rol oynamaktadır. Özellikle kirli bir hava ortamının oluşmasına neden olan mevsim geçişlerinde virüs ve bakterilerin insanlara buluşma riski oldukça yüksektir [1]. Ortak ve kapalı alanlarda insanların birbiri ile etkileşimi bulaşıcı organizmaların yayılmasını daha da hızlandırır. İnsanın bağışıklık sistemini zayıflatan bu organizmalar, solunum yolu organlarına enfekte olup çeşitli hastalıkların oluşmasına sebep olmaktadır [2]. Bu hastalıkların başında; Koah, SARS, MERS, COVID-19 hastalıkları gelir. Erken tanı konulmadığı ve tedavi edilmediği takdirde bu hastalıklara yakalanan bireylerde ölüm oranı daha da yüksektir. Bu hastalıkların oluşmasına neden olan virüslerin bazıları RNA tiplidir ve süreç içerisinde mutasyona uğrayabilirler. Nitekim COVID-19 hastalığına yol açan virüs RNA türüdür ve son zamanlarda bu virüsten dünyada milyonlarca kişi etkilendi ve yüzbinlerce kişinin ölümüne sebep oldu [3]. COVID-19 virüsünün en çok etkilediği ülkeler arasında sırasıyla; Amerika, Brezilya, Hindistan, Çin, Güney Afrika, Rusya gibi ülkeler gelmektedir [4]. Bu tür hastalıklara sebep olan mikroorganizmalar genellikle akciğer organını olumsuz etkiler ve solunum yolu rahatsızlıklarının oluşmasına neden olur [5].

Solunum yolu hastalıklarının tespitinde erken teşhis önemlidir. Hastalığın tanı ve tedavi süreçlerinde uzmanların karar verme yetisi zaman alabilmektedir. Son zamanlarda yapay zekâ tabanlı sistemler, medikal alanda adını duyurmuşlardır. Bu teknolojiler, uzman kişilerin karar verme sürecini kısaltarak daha çok tanı tespitini gerçekleştirebilmektedir [6]. Solunum yolu hastalıklarının tanı sürecinde genelde uzmanlar; Bilgisayar Tomografi (BT), X-ışın, Röntgen gibi cihazlardan elde edilen görüntüleri kullanarak karar verebilmektedir. Yapay zekâ teknolojisi ile derin ağların bulunduğu modeller bu veriler ile eğitilerek hastalığın tespitini gerçekleştirebilmektedir [7]. Bu alandaki bazı çalışmalar incelenirse; AlMoammar vd. [8] çalışmasında gözetimli öğrenme yöntemlerini kullanarak SARS, MERS, COVID-19 görüntülerinin bulunduğu veri setini sınıflandırmışlar. Çalışmalarında sınıflandırıcı olarak; En Yakın Komşu (EYK), Karar Ağacı ve Destek Vektör Makinesi (DVM) yöntemlerini kullanmışlar. En iyi sınıflandırma sonucunu %86,44 oranında DVM ve Karar Ağacı yöntemleri ile elde etmişler. Hemdan vd. [9] çalışmasında COVID-19 görüntülerini analiz etmişler. Çalışmalarında kullandıkları görüntülerde korona virüsün pozitif ve negatif tespitini gerçekleştirmişler. Deney kısmında derin öğrenme modelleri (VGG, ResNet, Inception, MobileNet, Xception, DenseNet vs.) ile eğitimleri gerçekleştirerek veriyi sınıflandırmışlar. Çalışmalarında elde ettikleri en iyi sınıflandırma sonuçlarını VGG ve DenseNet modelleri ile gerçekleştirmişler. Deneysel analiz sonucunda elde ettikleri genel doğruluk oranı %90'dı. Xiaowei vd. [10] çalışmasında üç sınıftan oluşan (zatürre, normal ve COVID-19) BT görüntülerini analiz etmişler. Çalışmalarında kullandıkları veri setindeki her bir görüntüyü bölütleme işleminden geçirmişler. Ardından sınıflandırma sürecinde Bayes yöntemini kullanmışlar. Sonuç olarak %86,7 genel doğruluk oranı elde etmişler. Mei vd. [11] çalışmasında korona tipli BT görüntülerini kullanarak hastanın pozitif veya negatif vaka olma durumlarını analiz etmişler. Çalışmalarında yeni bir evrişimsel sinir ağı (ESA) modeli tasarlamışlar. Sınıflandırıcı olarak DVM ve Çok Katmanlı Algılayıcı (ÇKA) yöntemlerini kullanmışlar. Sınıflandırma sürecinde ÇKA yöntemi ile %92 genel doğruluk oranı elde etmişler. Houssein vd. [12] COVID-19 hastalığının tanı sürecinde hibrit kuantum evrişimli sinir ağları (HK-ESA) modelini kullanmışlar. Çalışmalarında kullandıkları veri seti zatürre, normal ve COVID-19 görüntü türlerinden oluşmaktaydı. HK-ESA modeli ile %98,4 genel doğruluk oranı elde etmişler. Acar ve Yılmaz [13], COVID-19 hastalığının tanı sürecinde klasik kuantum transfer öğrenimi modelini kullanmışlar. Çalışmalarında kullandıkları veri seti, normal ve COVID-19 görüntü türlerinden oluşmaktaydı. Bölütleme yöntemini kullanarak veri setini ön işlem sürecinden geçirmişler. Ardından önerdikleri yaklaşımın çeşitli kuantum bilgisayarlarda analizlerini gerçekleştirdiler. Kuantum bilgisayarlar üzerinden elde edilen genel doğruluk oranları %94 ile %100 aralığında değişmekteydi.


Bu makalenin amacı, X-ışınlarından elde edilen göğüs görüntülerini kullanarak solunum yolu hastalıklarının başarılı bir şekilde tespit edilebileceği hibrit bir yaklaşım sunmaktır. Önerilen yaklaşım, transfer öğrenme tabanlı derin öğrenme modeli ile kuantum modelin birleştirildiği bir

mimariden oluşmaktadır. Bu amaç doğrultusunda kuantum öğrenmenin derin öğrenme modeline katkı sunması hedeflenmiştir.

Makalenin diğer bölümleri hakkında özet şu şekildedir; veri seti ile ilgili bilgilere 2. bölümde yer verilmiştir. Çalışmanın gerçekleştirilmesinde kullanılan yöntem ve modeller hakkındaki bilgilere 3. bölümde yer verilmiştir. Deneysel analizlere 4. bölümde yer verilmiştir. Tartışma ve Sonuç bölümleri sırasıyla son iki bölümde yer almıştır.

## **II. VERİ SETİ**

Veri seti, BT tabanlı göğüs görüntülerinden oluşan açık kaynak erişimlidir. Sınıf türü olarak ikiye ayrılmıştır. Bu türler normal göğüs görüntüleridir ve solunum yolu hastalıklarının tespit edildiği görüntülerdir. Solunum yolu hastalıklarının yer aldığı sınıf; zatürre, SARS, MERS, COVID-19 hastalarından elde edilmiş görüntülerden oluşmaktadır. Görüntüler uzmanlar tarafından kontrol edilerek erişime sunulmuştur. Her bir görüntü uzantısı JPEG formatındadır ve görüntü derinliği 8 bittir. Veri setini oluşturan görüntüler farklı kaynaklardan toplandı için çözünürlük değerleri sabit değildir. Veri seti, eğitim ve test verileri olmak üzere iki kısma ayrılmıştır. Dolayısıyla bu çalışmada gerçekleştirilen deneysel analizler veri setinin orijinal hali ile gerçekleştirilmiştir. Eğitim verileri, her bir sınıf türü için 74 adet BT görüntüsünden oluşmaktadır. Test verileri, her bir sınıf türü için 20 adet BT görüntüsünden oluşmaktadır. Veri seti toplam 198 adet BT görüntüsünden oluşmaktadır [14]. Veri setinin sınıflarını temsil eden örnek görüntüler Şekil 1'de gösterildi.




*Şekil 1. Veri setindeki farklı sınıflara ait görüntüler; (a) solunum hastalıkları barındıran BT göğüs görüntüleri, (b) normal BT göğüs görüntüleri.*

## **II. MODELLER VE ÖNERİLEN YAKLAŞIM**

### **A. RESNET-18 MODEL**


ResNet-18, artık blokların mimari yapısında yer aldığı evrişimsel sinir ağlardan oluşan bir modeldir. Bu model, ImageNet veri tabanında yer alan 1000 nesne kategorisindeki veri görüntülerini başarılı bir şekilde sınıflandırmıştır. ResNet'in girdi boyutu 224×224'tür ve yapısında evrişimsel, havuzlama, tam bağlantılı gibi katmanları bulundurmaktadır. Bu temel katmanlar ResNet-18 modelini bir ESA modeli özelliğini taşıdığını göstermektedir [15]. Evrişimsel katman, girdi görüntüleri üzerinde filtreler dolaştırarak (3×3, 5×5) özniteliklerin çıkarılmasını sağlar. Havuzlama katmanı, genelde evrişimsel katmanlardan sonra kullanılır ve girdi boyutunu düşürerek bir sonraki katmana aktarılmasını sağlar. Tam bağlantılı katman, derin öğrenme modellerinin genellikle son katmanlarında yer alır ve bu katman, kendisinden önceki katmanlardan aktarılan değerleri işler. Ardından çıkış katmanına sınıf sayısı kadar olasılık değeri üretilmesini sağlar [16]. ResNet modelini ESA modellerinden ayıran en

önemli özellik artık katmanlara sahip olmasıdır. Artık katmanlar, girdi özelliklerini işleyerek çıkışa aktarır ve kendinden sonraki katmana çıkış özelliklerini aktarmadan bir veya iki sonraki katmana doğrudan aktarılmasını gerçekleştirir. Bu yönü ile "kısa yol" veya "atlayan katman" olarak da adlandırılabilir ve bu sayede, modelin daha kolay öğrenmesini sağlar [17]. Artık katmanların işlevini gösteren tasarım Şekil 2'de gösterildi. Son olarak ResNet gibi ESA modellerinde farklı bir makine öğrenme tabanlı sınıflandırıcı eklenmemiş ise, tam bağlantılı katmanlardan sonra sınıflandırma sürecinde aktivasyon fonksiyonları genelde kullanılır. Bu çalışmada, Softmax yöntemi tercih edildi. Softmax yöntemi, iki veya çok sınıflı problemlerin çözümünde tercih edilir ve girdi özelliklerin taşıdığı sayısal değerleri işleyerek 0 ile 1 arasında olasılık değerleri üretir. Bu olasılık değerleri içerisinde yüksek olan sınıfa girdi verisi atanır [18]. ResNet-18 modelinin genel tasarımı Şekil 3'te gösterildi.



Şekil 2. ResNet modellerinde artık blokların gösterimi.

Bu çalışmada önceden eğitilmiş ResNet-18 modeli kuantum öğrenme ile birlikte hibrit bir yapı oluşturularak kullanıldı. ResNet-18 modelinin eğitim sürecinde varsayılan tüm katmanları kullanıldı ve modelin bilgi transferinin gerçekleştirilmesinde ImageNet veri tabanı kullanıldı. ResNet-18 modelinin bu çalışma için seçilmesinin nedeni; girdi çözünürlüğü, artık bloklar ve ResNet modelleri içerisinde en az derinliğe sahip olmasıdır. Ayrıca, ResNet-18 modeli için tercih edilmiş parametreler varsayılan değerlerdir. Modelin derlenmesinde açık kaynak kodlar kullanıldı [19].



Şekil 3. ResNet-18 modelinin tasarımı.

## B. KUANTUM ÖĞRENME MODELİ

Kuantum fiziği, iki benzer parçacığın eş zamanlı olarak birbiri ile etkileşim içerisinde olduğunu savunur ve bu parçacıklar farklı yerlerde olsa dahi bir parçacıktan olan bir değişiklik diğerini etkiler [20]. Yapay sinir ağlarında ise bu durum iki nöron grubunda olan parçacıklar arasında olan etkileşimi inceler ve bu etkileşime kuantum öğrenme adı verilir. Kuantum öğrenme, nöronlar içerisinde yer alan parçacıklar arasında etkileşimi sağlamak için algılayıcılar kullanılır. Bu sırada algılayıcılar doğrusal aktivasyon fonksiyonları da kendi yapılarında kullanılır. Kuantum öğrenmenin en büyük problemi doğrusal olmayan aktivasyon fonksiyonları ile karşılıklı çalışmamasıdır ve bu durum kuantum için kullanılan matematiksel formüllerin doğrusal olmayan aktivasyon fonksiyonları işlem yürütememesinden kaynaklanmaktadır. Kuantum öğrenme hesaplama işlemlerinde temel birim olarak kubit kavramını kullanılır. Kubit terimi, bit teriminin aksine 0 veya 1 ile temsil edilmez. Kubitler, iki

durumun (0 ile 1) kombinasyonunda var olmasını sağlar [21,22]. Bu durum Eş. 1'de şu şekilde izah edilmiştir;


$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

İki hesaplamalı temel durum sırasıyla  $|0\rangle$  ve  $|1\rangle$  parametreleri ile temsil edilir ve bu duruma karşılık gelen karmaşıklık genlikleri ise sırasıyla  $\alpha$  ile  $\beta$  ile temsil edilir. Karmaşıklık genliklerinin karelerinin toplamı 1'e eşittir ( $|\alpha|^2 + |\beta|^2 = 1$ ). Dolayısıyla bir kubit, basit bir kuantum öğrenmeyi fiziksel bir çerçevede gerçekleştirebilir. Bunu da süper pozisyon olarak adlandırılan iki durumu (0 ile 1), yatay ve dikey polarizasyona karşılık gelecek şekilde yerleştirerek çözebilmektedir. Çok sınıflı problemlerin çözümünde tek bir kubit yetersiz kaldığı zaman  $\vartheta(\log K)$  çıkış kubitleri etiketleri temsil etmek için kullanılır. Bu denklemde  $K$  etiket sayısını temsil eder [22]. Kuantum öğrenmede veri girişleri kuantum veri olmak zorundadır veya normal girdiler kuantum biçimine dönüştürülerek modelin eğitimi gerçekleştirilir [21]. Kuantum öğrenmede eğitim gerçekleştirilirken maliyet hesaplanması Eş. 2'ye göre hesaplanır. Eş. 2 incelendiğinde;  $C$  maliyet birimini,  $N$  eğitim çifti sayısını temsil eder. Ayrıca,  $\langle \theta_x^{giris} | \rho_x^{cikis} | \theta_x^{cikis} \rangle$  giriş ve çıkış değerleri için ağ çıkış yakınlığı  $\rho_x^{cikis}$  parametresi ile temsil edilir. Maliyet birimi ( $C$ ) sıfır ile bir arasında bir değer alır; eğer  $C$  parametresi sıfıra yakınsa kötü veya bire yakınsa iyi bir maliyet değeri anlamına gelir. Kuantum öğrenmenin eğitimi gerçekleştirilirken ağ yapısında ağırlık güncellemeleri her bir iterasyon için gerçekleştirilir [23].

Kuantum öğrenme, Şekil 4'te gösterildiği gibi giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Burada eğitim algılayıcılar tarafından sırasıyla yukarıdan aşağı doğru uygulanır (mor renkten sarı renge doğru). Kuantum öğrenmede gerçekleştirilen işlem sırası bu açıdan önemlidir ve kuantum algılayıcıları bir kuantum devresi şeklinde hareket ederler. Bu devre Eş. 3'te gösterildiği gibi temsil edilir.

$$C = \frac{1}{N} \sum_{x=1}^N \langle \theta_x^{giris} | \rho_x^{cikis} | \theta_x^{cikis} \rangle \quad (2)$$

$$U \equiv U^{cikis} U^L U^{L-1} \dots U^1 \quad (3)$$



Şekil 4. Kuantum sinir ağı yapısı [23].

Kuantum ağlar ResNet-18 modelinin tam bağlantılı katmanından elde edilen özneliliklerin kuantum devreleri tarafından genişletilerek güçlendirilmesini sağlar. Bunu gerçekleştirirken bitlerden farklı kubitleri kullanır ve her bir değer hafızada saklanarak işlem görür. Özellikle girdi boyutu yüksek çözünürlüğe sahip verilerin analizinde kuantum öğrenmenin ESA modellerine göre daha verimli

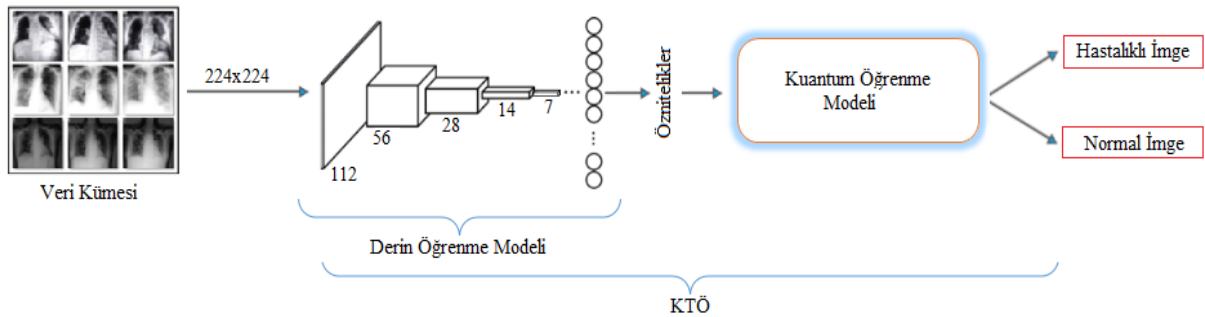
sonuçlar verebileceği tahmin edilebilmektedir. Son teknolojik alt yapılara sahip kuantum bilgisayarlar bu durumu daha da mümkün kılmaktadır. Bu sebeplerden dolayı kuantum öğrenme önerilen yaklaşımda kullanıldı. Bu çalışmada önerilen yaklaşımda kuantum öğrenme modeli, ESA modeli ile birleştirilerek deneysel analizler gerçekleştirildi [19,23]. Kuantum öğrenme modeli için tercih edilmiş önemli parametre değerleri Tablo 1’de verildi. Tablo 1’de belirtilen değerler varsayılan değerler değildir. Görüntü sayısına, görüntü büyüklüğüne ve bilgisayar donanım özelliklerine göre bu değerler seçildi.

**Tablo 1.** Bu çalışmada kullanılan KTÖ modeli için tercih edilen parametre değerleri.

Kubit Sayısı	Öğrenme Oranı	İterasyon Başına İşlenen Örnek Sayısı	Eğitim Dönem Sayısı	Kuantum Devresinin Derinliği	Maksimum Katman Sayısı
4	$4 \times 10^{-4}$	4	64	6	15

### C. ÖNERİLEN YAKLAŞIM: KUANTUM TRANSFER ÖĞRENME MODELİ

Önerilen yaklaşım, önceden eğitilmiş ResNet-18 modeli ile kuantum modelinin birlikte kullanılmasını sağlayan hibrit bir modeldir. ResNet-18 modeli dışında diğer derin öğrenme modelleri de (AlexNet, VGG, GoogLeNet) hibrit model içerisinde kullanılabilir. Kuantum öğrenmeye verimli girdi özellikleri aktarıldığı vakit başarılı sonuçlar verebilmektedir. Bu yüzden önceden eğitilmiş ResNet-18 modeli kullanılarak verimli özniteliklerin çıkarılması sağlandı. Bu öznitelikler ResNet-18 modelinin son katmanında yer alan tam bağlantılı katmandan elde edildi ve Kuantum öğrenme modeline girdi verisi olarak aktarıldı. Sınıflandırma sürecinde “Linear Regresyon” yöntemi [24] tercih edildi ve hibrit modelin optimizasyon işlemleri için “Adam” yöntemi [25] kullanıldı. Bu iki yöntemin tercih edilmesinin en önemli nedeni diğer alternatif yöntemler (adamax, rmsprop vb.) arasında en iyi performansı vermesidir. Önerilen yaklaşımın tasarımı Şekil 5’te gösterildi.



**Şekil 5.** Önerilen yaklaşımın genel tasarımı.

## III. DENEYSEL SONUÇLAR

Bu çalışmanın yazılım kodları, Google Colab arayüzü kullanılarak derlendi. Donanımsal gereksinimler Google Sunucuları tarafından sağlatıldı. Deneysel analizler ve sonuçların değerlendirilmesi için karmaşıklık matrisi kullanıldı. Karmaşıklık matrisindeki metriklerin hesaplanmasında Tablo 2’den yararlanıldı. Karmaşıklık matrisinin hesaplanmasında kullanılan metrikler şunlardır; duyarlılık (Duy), özgüllük (Özg), hassasiyet (Has), f-skoru (F-skr) ve doğruluk (Dğr). Metrikler, Eş. 4 ile Eş. 8 arasındaki formüller ile hesaplanmaktadır. Bu eşitliklerde kullanılan parametreler; Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP), Yanlış Negatif (YN)’tir. Bu parametrelerin açıklanması şu şekildedir;

- DP: Veri setinin normal sınıfında olup, normal olarak tahmin edilen görüntü sayısı.

- DN: Veri setinin hastalıklı sınıfında olup, hastalıklı olarak tahmin edilen görüntü sayısı.
- YP: Veri setinin hastalıklı sınıfında olup, normal olarak tahmin edilen görüntü sayısı.
- YN: Veri setinin normal sınıfında olup, hastalıklı olarak tahmin edilen görüntü sayısı [15,26].

**Tablo 2.** Karmaşıklık matrisi.

		Tahmin	
		Normal	Hastalıklı
Gerçek	Normal	DP	YN
	Hastalıklı	YP	DN

$$Duy = \frac{DP}{(DP + YN)} \quad (4)$$

$$Özg = \frac{DN}{(DN + YP)} \quad (5)$$

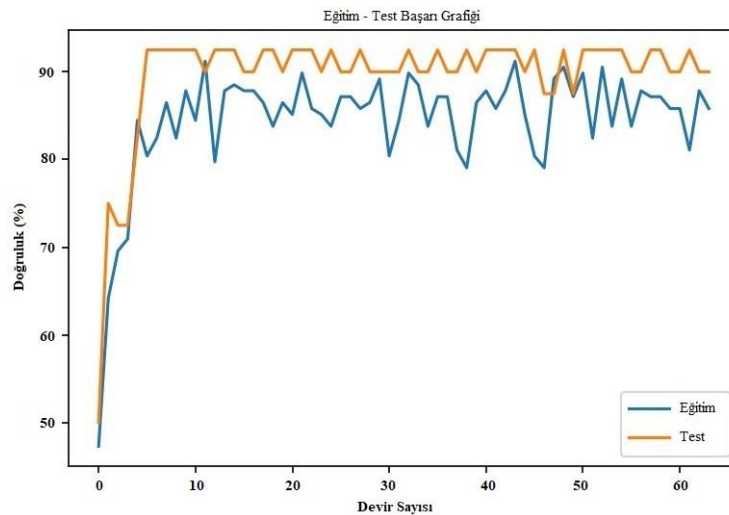
$$Has = \frac{DP}{(DP + YP)} \quad (6)$$

$$F - skr = \frac{(2xDP)}{(2xDP + YP + YN)} \quad (7)$$


$$Dğr = \frac{(DP + DN)}{(DP + DN + YP + YN)} \quad (8)$$

Bu çalışmanın deneysel analizlerinde iterasyon başına işlenen örnek sayısı 4 seçildi ve devir sayısı 64 tercih edildi. İterasyon başına işlenen örnek sayısı, önerilen modelin girdi görüntülerini eş zamanlı olarak seçilmiş değer kadar işlenmesini sağlar ve donanımsal özellikler ile doğrudan alakalıdır [27].

Birinci analiz KTÖ modeli (önerilen yaklaşım) kullanılarak gerçekleştirildi. KTÖ modelin eğitim süresi 61 dakika 33 saniyeydi. Deneysel analizin eğitim genel doğruluk oranı %91,22'di. Test verilerinde elde edilen genel doğruluk oranı ise %92,50'yd. Eğitim-test başarı grafikleri Şekil 6'da gösterildi ve eğitim-test kayıp grafikleri Şekil 7'de gösterildi. Birinci analizin eğitim-test başarı grafiklerinde test verilerindeki başarı eğitim verilerindeki başarıdan daha yüksektir. Test verilerinin karmaşıklık matris değerlerini analiz eden tablo Şekil 8'de gösterildi. Karmaşıklık matrisinden elde edilen analiz sonuçları Tablo 3'te verildi.



**Şekil 6.** Birinci analizin eğitim-test verilerine ait doğruluk başarı grafiği.




Şekil 7. Birinci analiz için eğitim-test verilerine ait kayıp grafiği.

		Tahmin Etiket	
		Normal	Hastalıklı
Gerçek Etiket	Normal	19	1
	Hastalıklı	2	18
		Normal	Hastalıklı

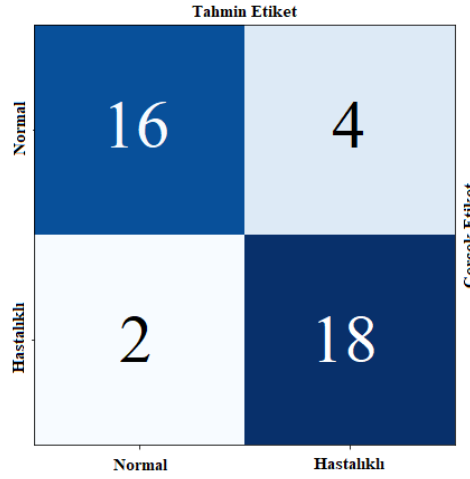
Şekil 8. Bu çalışmanın birinci analizinde elde edilen karmaşıklık matrisi.

Kuantum öğrenmenin ResNet-18 modelinin eğitimine sunmuş olduğu katkıyı gözlemleyebilmek için ikinci analiz gerçekleştirildi. Bu analizde ResNet-18 model kullanıldı ve veri seti ResNet-18 model tarafından eğitildi. Modelin eğitim süresi 45 dakika 20 saniyeydi. ResNet-18 modelinden elde edilen eğitim genel doğruluk oranı %81,76'ydı. Test verilerinden elde edilen genel doğruluk oranı ise %85'ti. İkinci analiz için eğitim-test başarı grafikleri Şekil 9'da gösterildi. Birinci analiz için eğitim-test başarı grafiklerinde olduğu gibi bu analizde de test başarısı eğitim başarısından daha iyi sonuç verdi. Test verilerinin karmaşıklık matris değerlerini analiz eden tablo Şekil 10'da gösterildi. İkinci analiz için karmaşıklık matrisinden elde edilen metrik başarı oranları Tablo 3'te verildi.





Şekil 9. İkinci analizin eğitim-test verilerine ait doğruluk başarı grafiği, b) karmaşıklık matrisi.



Şekil 10. İkinci analizin eğitim-test verilerine ait karmaşıklık matrisi.

Tablo 3. Deneysel analizlerden elde edilen karmaşıklık matrislerinin metrik sonuçları (%).

Analiz No	Yaklaşım	F-Skr	Duy	Özg	Has	Dğr
#1	ResNet-18 ve Kuantum Öğrenme	92,68	90,48	94,74	95,0	92,50
#2	ResNet-18 ve Transfer Öğrenme	84,21	88,89	81,82	80	85

Birinci analizin sonuçları ikinci analizin sonuçlarından daha başarılı olduğu gözlemlendi. Gerçekleştirilen iki analiz sonucunda kuantum öğrenmenin önerilen yaklaşıma katkı sunduğu görüldü.

## IV. TARTIŞMA

Solunum yolu enfeksiyonları ile oluşan çeşitli hastalıklar, bireylerde ölümcül sonuçlar verebilmektedir. Dolayısıyla erken tanı ve tedavi bu durumda büyük önem kazanmaktadır. Bu çalışmada, solunum yolu hastalıklarının tespitinde derin öğrenme ile kuantum öğrenmenin birbiriyle modellenmesi gerçekleştirilmiştir. Kuantum öğrenme, derin öğrenme modellerine göre farklı mimari yapısında olduğu ve kuantum fizik teorisine göre oluşturulduğu için henüz her veri setinde başarılı

sonuçlar elde edilmesi mümkün değildir. Bu çalışmanın deneyinde önerilen model ile başarılı analizler gerçekleştirildi. Önerilen yaklaşımın deneysel analizlerinde görülen eksik yönü kubit değerinin fazla artırılmamasıydı. Kubit değerinin artırılması modelin eğitiminin donanımsal kaynaklardan dolayı (Google Colab'ın zaman sınırlaması) tamamlanmayacağı problemini karşımıza çıkaracaktır. Kuantum işlemcili bilgisayarlar tarafından analizlerin gerçekleştirilmesi bu problemi ortadan kaldıracaktır. Çalışmamıza benzer veri seti ile katkı sunan bir çalışmada Almoammar vd. [8] tarafından 2018 yılında gerçekleştirilmiştir. Bu çalışma ile ilgili analiz sonucu Tablo 4'te verildi.

*Tablo 4. Benzer veri setleri ile gerçekleştirilmiş çalışmaların karşılaştırılması.*

Makale	Yıl	Veri seti içeriği	Görüntü sayısı	Model / Yöntem	Dğr
Almoammar vd. [8]	2018	(SARS, MERS) ve Normal	1410	DVM, Karar Ağacı, EYK	%86,44
Hemdan vd. [9]	2020	COVID-19 (+), COVID-19 (-)	Eğitim: 40 Test: 10	VGG, DenseNet	%90
Xiaowei vd. [10]	2020	COVID-19, Zatürre ve Normal	Eğitim: 528 Test: 90	ResNet-18, Gürültülü Bayes İşlevi	%86,7
Mei vd. [11]	2020	COVID-19 (+), COVID-19 (-)	Eğitim: 543 Test: 362	ESA, ÇKA	%92
Houssein vd. [12]	2021	COVID-19, Zatürre ve Normal	Eğitim: 6216 Test: 1736	HK-ESA	%98,4
Acar ve Yılmaz [13]	2021	COVID-19 ve Normal	Eğitim: 226 Test: 2432	Klasik KTÖ	%94-100
<b>Bu çalışma</b>	2021	(SARS, MERS, COVID-19) ve Normal	Eğitim: 148 Test:40	ResNet-18 ve Kuantum Öğrenme	<b>%92,50</b>

Almoammar vd. [8] çalışmasında iki sınıflı veri setini önerdikleri yaklaşımda kullanarak analizleri gerçekleştirmişler. Onlar, makine öğrenme yöntemlerini (DVM, Karar Ağacı, EYK) deneysel analizlerde kullanmışlar. Sınıflandırma aşamasında çapraz doğrulama yöntemini kullanmışlar. Makine öğrenme yöntemleri ile veri setini doğrudan sınıflandırmaları, elde ettikleri %86,44'lük genel doğruluk oranını düşük kılmıştır. Hemdan vd. [9] çalışmasında elde ettikleri doğruluk oranı yüksek olsa da kullandıkları veri setinin sayısının az olması yaptıkları teste olan güvenilirliği azaltmıştır. Bu çalışmanın hem Xiaowei vd.'nin [10] çalışmasına hem de Mei vd.'nin [11] çalışmasına göre avantajı uçtan uca bir yaklaşım önermesidir. Fakat deneysel analizlerin kuantum bilgisayarlar tarafından gerçekleştirilememesi ise bir dezavantaj olarak görülmüştür. Neticesinde kuantum öğrenmenin analizlerini kuantum bilgisayarlar ile gerçekleştiren çalışmalarda performansın arttığı gözlemlenmiştir [12, 13]. Acar ve Yılmaz [13] çalışmalarında eğitim-test sayısı dağılımını diğer çalışmalardan farklı olarak gerçekleştirmiştir. Az sayıda eğitim verisi kullanarak önerdikleri KTÖ modeli ile başarılı sonuçlar elde etmişlerdir.

## V. SONUÇ

Kuantum öğrenme modelleri farklı açık kaynaklı kütüphaneler (Tensorflow [28], Torch vb.) tarafından son zamanlarda desteklenmektedir. Bu çalışmada kuantum öğrenme modelinin derin öğrenme modeli ile birlikte hibrit bir model oluşturularak solunum yolu hastalıklarının tespiti gerçekleştirildi. Kuantum öğrenmenin derin öğrenme modeli ile birlikte uyum içerisinde eğitimini gerçekleştirmesi, çalışmanın başarısını artırdı. Deneysel analizde elde edilen genel doğruluk oranı %92,50'di. Bu sonuç umut

verici olmuştur ve bu çalışma ile kuantum öğrenme yapısının derin öğrenme modeline göre benzer/farklı yönlerini inceleme fırsatı oldu.

Gelecek çalışmada, kuantum öğrenmenin farklı yapay zekâ destekli modeller üzerinden eğitimi gerçekleştirilecektir ve meta-sezgisel optimizasyon yöntemleri kullanılarak performansa katkı sunmadıkları değerlendirilecektir.

## **V. KAYNAKLAR**

- [1] D. Kim, Z. Chen, L.-F. Zhou, and S.-X. Huang, “Air pollutants and early origins of respiratory diseases,” *Chronic Dis. Transl. Med.*, vol. 4, no. 2, pp. 75–94, 2018.
- [2] Z. Shi and A. T. Gewirtz, “Together forever: bacterial-viral interactions in infection and immunity,” *Viruses*, vol. 10, no. 3, pp. 122, Mar. 2018.
- [3] N. Petrosillo, G. Viceconte, O. Ergonul, G. Ippolito, and E. Petersen, “COVID-19, SARS and MERS: are they closely related?,” *Clin. Microbiol. Infect.*, vol. 26, no. 6, pp. 729–734, Jun. 2020.
- [4] Wikipedia. (2021, Jun 28). *COVID-19 pandemic by country and territory* [Online]. Available: [https://en.wikipedia.org/wiki/COVID-19\\_pandemic\\_by\\_country\\_and\\_territory](https://en.wikipedia.org/wiki/COVID-19_pandemic_by_country_and_territory).
- [5] W. H. Man, W. A. A. de Steenhuijsen Piters and D. Bogaert, “The microbiota of the respiratory tract: gatekeeper to respiratory health,” *Nat. Rev. Microbiol.*, vol. 15, no. 5, pp. 259–270, 2017.
- [6] Amisha, P. Malik, M. Pathania, and V. K. Rathaur, “Overview of artificial intelligence in medicine,” *J. Fam. Med. Prim. Care*, vol. 8, no. 7, pp. 2328–2331, 2019.
- [7] E. Bercovich and M. C. Javitt, “Medical imaging: from roentgen to the digital revolution, and beyond,” *Rambam Maimonides Med. J.*, vol. 9, no. 4, pp. e0034, Oct. 2018.
- [8] A. AlMoammar, L. AlHenaki, and H. Kurdi, “Selecting accurate classifier models for a MERS-CoV dataset,” *Intell. Syst. Appl. Proc. 2018 Intell. Syst. Conf.*, vol. 1, no. 868, pp. 1070–1084, 2018.
- [9] E. Hemdan, M. A. Shouman and M. Karar. (2021, Jun 16). *Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images* [Online]. Available: <https://arxiv.org/abs/2003.11055>
- [10] X. Xu, X. Jiang, C. Ma, P. Du, X. Li, S. Lv, L. Yu, Q. Ni, Y. Chen, J. Su, G. Lang, Y. Li, H. Zhao, J. Liu, K. Xu, L. Ruan, J. Sheng, Y. Qiu, W. Wu, T. Liang and L. Li, “A deep learning system to screen novel coronavirus disease 2019 pneumonia,” *Engineering*, vol. 6, no. 10, pp. 1122–1129, 2020.
- [11] X. Mei, H. Lee, K. Diao, M. Huang, B. Lin, C. Liu, Z. Xie, Y. Ma, P. Robson, M. Chung, A. Bernheim, V. Mani, C. Calcagno, K. Li, S. Li, H. Shan, J. Lv, T. Zhao, J. Xia, Q. Long, S. Steinberger, A. Jacobi, T. Deyer, M. Luksza, F. Liu, B. P. Little, Z. A. Fayad and Y. Yang, “Artificial intelligence-enabled rapid diagnosis of patients with COVID-19,” *Nat. Med.*, 2020, doi: 10.1101/2020.04.12.20062661.
- [12] E.H. Houssein, Z. Abohashima, M. Elhoseny and W.M. Mohamed. (2021, July 10). *Hybrid quantum convolutional neural networks model for COVID-19 prediction using chest X-Ray images* [Online]. Available: <https://arxiv.org/abs/2102.06535v1>.

- [13] E. Acar and İ. Yılmaz, “COVID-19 detection on IBM quantum computer with classical quantum transfer learning,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 29, pp. 46–61, 2021.
- [14] W.H. Khoong, (2021, Jun 16). *COVID-19 x-ray dataset (train & test sets) | Kaggle* [Online]. Available: <https://www.kaggle.com/khoongweihao/covid19-xray-dataset-train-test-sets>.
- [15] X. Zhang, L. Fu, M. Karkee, M. D. Whiting and Q. Zhang, “Canopy segmentation using ResNet for mechanical harvesting of apples,” *IFAC-PapersOnLine*, vol. 52, no. 30, pp. 300–305, 2019.
- [16] C. R. Alimboyong and A. A. Hernandez, “An improved deep neural network for classification of plant seedling images,” in *2019 IEEE 15th International Colloquium on Signal Processing & Its Applications (CSPA)*, Penang, Malezya, 2019, pp. 217–222.
- [17] A. A. Ardakani, A. R. Kanafi, U. R. Acharya, N. Khadem and A. Mohammadi, “Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: results of 10 convolutional neural networks,” *Comput. Biol. Med.*, vol. 121, pp. 103795, Jun. 2020.
- [18] S. Maharjan, A. Alsadoon, P. W. C. Prasad, T. Al-Dalain, and O. H. Alsadoon, “A novel enhanced softmax loss function for brain tumour detection using deep learning,” *J. Neurosci. Methods*, vol. 330, pp. 108520, 2020.
- [19] A. Mari, N. Killoran, and J. Izaac, (2021, Jun 10). *Quantum transfer learning* [Online]. Available: [https://github.com/XanaduAI/quantum-transferlearning/blob/master/c2q\\_transfer\\_learning\\_ants\\_bees.ipynb](https://github.com/XanaduAI/quantum-transferlearning/blob/master/c2q_transfer_learning_ants_bees.ipynb).
- [20] S. Ornes, “News Feature: Quantum effects enter the macroworld,” *Proc. Natl. Acad. Sci.*, vol. 116, no. 45, pp. 22413 LP – 22417, Nov. 2019.
- [21] M. Andrea, B. R. Thomas, I. Josh, S. Maria and K. Nathan. (2021, July 1). *Transfer learning in hybrid classical quantum neural networks* [Online]. Available: <https://arxiv.org/abs/1912.08278v2>.
- [22] S. Garg and G. Ramakrishnan. (2021, July 10). *Advances in quantum deep learning: an overview* [Online]. Available: <https://arxiv.org/abs/2005.04316>.
- [23] K. Beer, D. Bondarenko, T. Farrelly, T. J. Osborne, R. Salzmänn and R. Wolf, “Training deep quantum neural networks,” *Nat. Commun.*, vol. 11, no. 1, pp. 808, 2020.
- [24] P. L. Bartlett, P. M. Long, G. Lugosi, and A. Tsigler, “Benign overfitting in linear regression,” *Proc. Natl. Acad. Sci.*, pp. 201907378, Apr. 2020.
- [25] H. Zhong, Z. Chen, C. Qin, Z. Huang, V. W. Zheng, T. Xu and E. Chen., “Adam revisited: a weighted past gradients perspective,” *Front. Comput. Sci.*, vol. 14, no. 5, pp. 145309, 2020.
- [26] F. Demir, A. Şengür, V. Bajaj, and K. Polat, “Towards the classification of heart sounds based on convolutional deep neural network,” *Heal. Inf. Sci. Syst.*, vol. 7, no. 1, pp. 16, 2019.
- [27] Z. Yang, C. Wang, Z. Zhang, and J. Li, “Mini-batch algorithms with online step size,” *Knowledge-Based Syst.*, vol. 165, pp. 228–240, 2019.
- [28] TensorFlow, (2021, Jun 4). *TensorFlow quantum* [Online]. Available: <https://www.tensorflow.org/quantum>.