



Akciğer Röntgen Görüntülerinden Covid-19 ve Zatürre Hastalığının Kuantum Evrişimli Sinir Ağları Yöntemi ile Tahmini

Prediction of Covid-19 and Pneumonia Diseases from Lung X-ray Images Using Quantum Convolutional Neural Networks

Seçmen Şahin¹ , Güneş Harman^{2*} 

¹Yalova Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Ana Bilim Dalı, Lisansüstü Eğitim Fakültesi, Yalova, Türkiye

²Yalova Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Yalova, Türkiye

Öz

Kuantum Evrişimli Sinir Ağları (QCNN'ler) kuantum hesaplamanın güçlü yönlerinden faydalanarak evrişimli sinir ağlarının yeteneklerini artırmayı amaçlar. Girdi verilerini yerel olarak dönüştürerek ve kuantum devreleri kullanarak çalışırlar. Bu çalışmada, kuantum kodlu bir COVID-19 veri kümesi üzerinde iki model oluşturulmuştur. Model-1, 'Normal Kişi' ile 'Covid19/Viral Pnömoni' arasında sınıflandırma yaparken, Model-2 'Covid-19' ile 'Viral Pnömoni' arasında sınıflandırma yapmaktadır. Oluşturulan bu modeller için kübit sayısına göre (öznitelik sayısı) 3 farklı sınıflandırma yapılmıştır. Kuantum Sınıflandırıcı 1 için, temel veri analizi ile elde edilen 256 özellikli giriş verisinden 11 özellik çıkarılarak yaklaşık %70 doğruluk elde edilmiştir. Kuantum Sınıflandırıcı 2'de, TruncatedSVD yöntemi kullanılarak her bir görüntünün 256 özelliği 4'e indirilmiş ve %72 doğruluk elde edilmiştir. Son olarak Kuantum Sınıflandırıcı 3'te sadece 2 özellik kullanarak beklenmedik bir şekilde %76 doğruluk elde ettiği belirtilmiştir. Bu modeller, akciğer röntgen görüntülerinden hastalık teşhisi konusunda önemli bilgiler sağlamak ve kuantum bilgisayarlarının sağlık alanında nasıl etkili bir şekilde kullanılabileceğini göstermektedir. Ayrıca, Pennylane'in "varsayılan qubit" cihazındaki farklı parametrelerin model performansına etkisi incelenmiştir. Çalışmada, Kuantum Sınıflandırıcı 3'ün veri boyutunu önemli ölçüde azaltarak yüksek doğruluk oranına nasıl ulaştığı, QCNN'lerin gelecekte daha az kaynak kullanımıyla yüksek performans sağlama potansiyelini göstermektedir.


Anahtar Kelimeler: Covid'19, kuantum devresi, kuantum makine öğrenmesi, kuantum evrişimli sinir ağları


Abstract

Quantum Convolutional Neural Networks (QCNNs) aim to enhance the capabilities of convolutional neural networks by leveraging the strengths of quantum computing. They operate by locally transforming input data using quantum circuits. In this study, two models have been built on a quantum-encoded COVID-19 dataset. Model-1 classifies between 'Normal Person' and 'Covid19/Viral Pneumonia', while Model-2 classifies between 'Covid-19' and 'Viral Pneumonia'. Three different classifications have been made based on the number of qubits (feature count) for these models. For Quantum Classifier 1, approximately 70% accuracy was achieved by extracting 11 features from the 256-feature input data obtained through basic data analysis. In Quantum Classifier 2, using the TruncatedSVD method, each image's 256 features were reduced to 4, resulting in 72% accuracy. Finally, Quantum Classifier 3 achieved an unexpected 76% accuracy using only 2 features. These models provide significant insights into diagnosing diseases from lung X-ray images and demonstrate how quantum computers can be effectively utilized in the healthcare domain. Additionally, the impact of different parameters in the "default qubit" device of Pennylane on model performance has been investigated. The study highlights how Quantum Classifier 3 achieves high accuracy by significantly reducing the data dimension, indicating the potential of QCNNs to provide high performance with less resource usage in the future.

Keywords: Covid'19, quantum circuit, quantum machine learning, quantum convolutional neural networks

*Sorumlu yazarın e-posta adresi: gunes.guclu@yalova.edu.tr

Seçmen Şahin  orcid.org/0009-0006-1085-2831

Güneş Harman  orcid.org/0000-0001-5413-124X



1. Giriş

Makine öğrenimi (ML), birçok alanda (hesaplamalı biyoloji, bilgisayarla görme, bilgisayar güvenliği vb.) hızla gelişen bir disiplindir. ML, verileri genellikle matrisler olarak temsil eder ve matris işlemlerini çözmek için doğrusal cebir kullanır. Ancak, ML uygulamaları ve tekniklerinin özellikle büyük veri işleme ve depolama sürelerinde bazı eksiklikleri vardır. Gelecek nesil araştırmacılar, bu sorunları çözmek için kuantum bilgisayarların gücünden yararlanarak daha akıllı bir çözüm geliştirmişlerdir (Rebentrost vd. 2014). Kuantum hesaplama (QC), klasik ML görevlerini daha hızlı hale getirebilen çeşitli doğrusal cebir hesaplamalarını iyileştirebilir. Örneğin, Kuantum Gradyan İnişi (QGD) (Kerenidis ve Prakash 2017) ve Kuantum Yaklaşık Optimizasyon Algoritması (QAOA) gibi kuantum optimizasyon teknikleri bu alanda öne çıkar. Bu teknikler, Kuantum Boltzman Makineleri (QBM) (Amin vd. 2018) gibi kuantum sinir ağları (QNN) içeren yeni nesil ML modellerinde etkin bir şekilde kullanılır.

Kriptografi ve sağlık alanında sunduğu hizmetlerin üstünlüğü ve kuantum hesaplamasının ilerlemesi nedeniyle klasik makine öğrenimi ve kuantum bilgi işleme kombinasyonu kuantum makine öğrenimi olarak adlandırılan yeni bir alan haline gelmiştir. Kuantum bilgi işleme, parazit, süperpozisyon ve dolaşma gibi kuantum mekanik özelliklerini kullanarak bilgileri işler. Bu nedenle, kuantum bilgi işleme klasik algoritmaları geliştirmek için makine öğrenimi (ML) gibi çeşitli alanlarla entegre edilmiştir. Kuantum makine öğrenimi (QML), kuantum özellikleri kullanarak makine öğrenimi algoritmalarını geliştirmeyi amaçlar. QML, yüksek etkinlikle farklı problemleri çözmek için kuantum **süperpozisyonu** ve kuantum *dolanıklığı* gibi kuantum özelliklerini kullanır (Schuld vd. 2015). Bu, ML'lerin esnekliği ve öğrenme kabiliyetinin yanı sıra kuantum bilgisayarların etkisine sahip çeşitli algoritmaların geliştirilmesini hedefler. QML, kuantum algoritmalarını sinir ağları (NN), grafik modeller ve destek vektör makineleri (SVM) gibi çeşitli ML modellerine entegre eder. Ayrıca, QML, klasik ML algoritmalarının kuantum versiyonlarını da içerir (Rahman ve Geiger 2016). Örneğin, Kuantum Destek Vektör Makineleri (QSVM) ve Kuantum Temel Bileşen Analizi (QPCA) (Lloyd vd. 2013).

Klasik ve Kuantum Makine Öğrenmesi (Quantum Machine Learning - QML) şeklinde yapılmış olan bu hibrit çalışmanın literatüre sağlayacağı katkı;

- **Hız ve İşlem Kapasitesi:** Klasik bilgisayarlar, belirli problemleri çözmek için sınırlı işlem kapasitesine sahip-

tir. Kuantum bilgisayarlar ise belirli tipteki problemleri daha hızlı çözebilir. Hibrit bir sistem, klasik bilgisayarların genel hesaplama yeteneklerini kullanırken, özellikle kuantum avantajlarına sahip problemleri çözmek için kuantum bilgisayarları kullanabilir.

- **Veri İşleme ve Analizi:** Hibrit bir yaklaşım, büyük veri setlerinde daha hızlı ve etkili bir şekilde işlem yapabilir. Kuantum bilgisayarlar, belirli veri analizi problemlerinde paralel hesaplamaları kullanarak klasik bilgisayarlardan daha etkili olabilir.
- **Belirli Algoritmaların İyileştirilmesi:** Klasik algoritmaların belirli zorlu problemlerde yetersiz olduğu durumlar vardır. Kuantum algoritmaları, bu tür problemleri çözmek için özel olarak tasarlanabilir. Hibrit bir yaklaşım, belirli algoritmaların klasik versiyonlarına kuantum iyileştirmeleri ekleyerek performansı artırabilir.
- **Yeni Algoritmaların Geliştirilmesi:** Hibrit sistemler, kuantum ve klasik bilgisayarlar arasında etkileşim sağlayarak yeni ve daha etkili algoritmaların geliştirilmesine olanak tanır. Bu, belirli problemleri çözmek için özel olarak tasarlanmış algoritmaların oluşturulmasına imkan tanır.
- **Çeşitli Uygulama Alanları:** Hibrit bir yaklaşım, finans, sağlık, yapay zeka, optimizasyon problemleri gibi çeşitli uygulama alanlarında kullanılabilir. Bu, klasik ve kuantum bilgisayarların güçlü yanlarını birleştirerek daha geniş bir problem yelpazesine hitap edebilir.

2. Literatür Taraması

Son yıllarda ML tabanlı QC ilgili çok önemli çalışmalar yapılmış ve yapılmaya devam etmektedir. Bu bölüm, kuantum makine öğrenimi (QML) paradigmaları (örn., Tamamen QML, hibrid klasik-quantum ML, kuantumdan ilham alan ML) ve kuantum derin öğrenmesinde yapılmış olan son çalışmalar hakkında kapsamlı bir literatür çalışması yapmak için düzenlenmiştir. Kuantum otomatik kodlayıcılar (Khoshaman vd. 2018, Pepper vd. 2019), Kuantum Biyomimetisi (Alvarez vd. 2018, Lamata 2020), Kuantum İletişimi (Nawaz vd. 2019, Sheng ve Zhou 2017, Wallnöfer vd. 2020), Kuantum Tavlama (Rieffel vd. 2015), Hesaplama Kimyası (McArdle vd. 2020, Von Lilienfeld 2018) ve Boltzmann makinesi (Amin vd. 2018).

Huang vd. (2021), ML görevlerinde yeni bir yaklaşım önermek için potansiyel kuantum avantajını kullandılar. Bu yaklaşım, giriş veri alanı aracılığıyla geometrik çekirdek işlevine dayanmaktadır. Ayrıca, klasik alanda "öngörülen kuantum

çekirdekleri” (POK) adı verilen kuantum ve klasik ML modellerini kullanarak bir kuantum çekirdeği sağladılar. Bu kuantum çekirdeği, veriler arasındaki benzerliği ölçer ve öğrenme görevlerinde kuantum hızlandırma sağlar. Burada kullanılan geometrik sabit, çeşitli çekirdek fonksiyonlarına sahip klasik ve kuantum ML algoritmalarındaki geometrik farkı ölçer ve potansiyel kuantum avantajının veri miktarına dayandığını bildirdiler. Yapılmış olan bir diğer çalışmada Schuld vd. (2016), denetimli öğrenmeye dayanan örüntü tanıma için yeni bir kuantum algoritması önermişlerdir. Bu algoritma, kuantum doğrusal regresyon adı verilen doğrusal regresyonun bir versiyonudur. Kuantum lineer regresyon, logaritmik zaman içinde özelliklerin n-boyutları ile kuantum verileri üzerinde çalışır. Bir diğer çalışmada Ezhov ve Ventura (2000), klasik NN'lere göre QNNS avantajları, kuantum paralellik, daha yüksek stabilite, daha yüksek bilgi işleme hızı ve bellek kapasitesi tartışılmaktadır. Bu çalışmada Da Silva vd. (2016), bir alan Kuantum Potansiyel Frekansları (QPF) üzerinde kuantum algılama adı verilen yeni bir Kuantum Network Solution (QNS) ve öğrenme algoritması, süperpozisyon tabanlı mimari öğrenme (SAL) olarak adlandırdı. SAL algoritması üst üste binme özelliğine ve kuantum operatörüne dayanmaktadır. Ayrıca, NN mimarisini polinom zamanıyla işler. QPF, kuantum algılama modellerinin sınırlamalarının üstesinden gelir. Başka bir çalışmada, yazarlar (Schuld vd. 2015), kuantum donanımı üzerinde kuantum faz tahmini kullanarak klasik algılama kuantum bir versiyonunu tanıttılar. Kuantum algılama algoritması, NNS'deki aktivasyon fonksiyonunu (adım işlevi) simüle eder.

Rekabetçi NN'lerde, Zhou (2010) iki ana parça sundu: birincisi, QC ile QC adı verilen Rekabetçi Öğrenme NN'lerine dayanan yeni bir model. QCNN modeli, kuantum paterni rekabetini kullanarak giriş modellerini sınıflandırır. İkinci bölümde Zhou, önerilen QCNN için bellek kapasitesi sağladı. QCNN, ağ ağırlığı olmadan bir kuantum kaydı kullanarak rekabetçi öğrenme elde eder. Kuantum dolaşımını ve Grover'ın algoritmasını kullanan bir başka QCNN modeli Zhong ve Yuan (2012) tarafından önerilmektedir. Bu model, sahte desenler nedeniyle kuantum ilişkilendirici bellek kullandı. Ayrıca, bu model rekabet sürecinde sahte durumları eksik kalıplarda hatırlar. Zidan vd. (2019) yapmış oldukları çalışmada QCPNN adı verilen ikili sınıflandırma için dolaşma önlemine dayanan başka bir QCNN önermişlerdir. QCPNN, giriş verilerini bir kuantum bilgisayardaki eksik desenlerde sınıflandırır.

Son zamanlarda, Abbas vd. (2021) QNN'nin gücünü mevcut yakın vadeli kuantum donanımı ile tartışmıştır. Yazarlar,

adlandırdıkları modelin kapasitesi, etkili boyut için yeni bir önlem önermişlerdir. Bu etkili boyut, modelin yeni/görünmeyen veriler üzerinde genelleme yeteneğini sınırlamak için kullanılır. Buna ek olarak, önlemlerinin bir Fisher bilgi matrisi ile veriye bağlı bir genelleme yöntemi olduğunu bildirdiler. Son olarak, yazarlar QNN'nin mevcut gürlülüğü kuantum cihazı ile klasik NN'ye kıyasla daha hızlı eğitim aldığı bildirmişlerdir. Ayrıca QNN'nin klasik NN'den daha yetenekli olduğunu gösterdiler. Chen ve Yoo (2021) yapmış oldukları çalışmada hibrit kuantum-klasik ML'ye dayanan yeni bir eğitim modeli önerdi. Mevcut problemi sınırlı mevcut kuantum donanımı ile çözmek için kuantum cihazların özelliğini kullandılar. Kuantum donanımını (yani, cihaz veya simülatör okuma) yerel istemciler olarak kullandılar. Ayrıca, çalışmada özellik çıkarma için VGG16 ile klasik -Kuantum Transfer Öğrenimi kullanmışlardır. Önerilen çerçevenin avantajı klasik ve kuantum verileri üzerinde çalışır.

Dang vd. (2018) görüntü sınıflandırması için kuantum KNN algoritması olarak adlandırılan yeni bir kuantum modeli önerdi. Kuantum KNN modeli iki bölümden oluşur: klasik ve kuantum bölümü. Yazarlar klasik bilgisayarı görüntülerin özelliklerini çıkarmak için kullandılar. Çıkarılan özellikler bir kuantum cihaz tarafından bir kuantum duruma dönüştürülür. Ardından, kuantum devresi, görüntüler arasındaki benzerliği hesaplamak için kullanılır. Son olarak, sınıflandırma işlemi bir ölçüm devresi tarafından gerçekleştirilir. Kuantum KNN modeli, verimlilik ve sınıflandırma performansı açısından klasik modellerden daha iyi performans gösterir. Yapılmış olan çalışmada Adhikary vd. (2020) tek bir kuantum sistemi ile yeni bir varyasyonlu kuantum sınıflandırıcısı sunmak ve tek-atış eğitimi adı verilen bir eğitim algoritması ile n-boyutlu verileri kodlamak için bir kuantum devresi kullanmıştır. Ayrıca, yazarlar tüm veri kümesini tek bir kuantum durumuna kodladılar. Tek atış eğitim, eğitim için daha az parametre kullanır ve daha yüksek hassasiyet elde eder. Mitarai vd. (2018) sınıflandırma, regresyon ve kümeleme, kuantum devre öğrenimi (QCL) gibi farklı görevleri yerine getirmek için hibrit bir Klasik -Kuantum tekniği sundu. QCL, küçük ölçekli kuantum cihazlarda hareket eder. Çalışmada, QCL'nin yüksek boyutlu sınıflandırma/regresyon görevleri ile performans gösterme ve kuantum çok vücut dinamiklerini de gerçekleştirme yeteneğini bildirmişlerdir.

Başka bir hibrit çalışmada, Henderson vd. (2020) görüntü sınıflandırması için standart evrimsel sinir ağlarına sahip kuantum devreleri kullandılar. Yazarlar, mevcut küçük ölçekli ve NISQ kuantum donanımında uygulamak için küçük

derinlikli bir kuantum devresi kullandılar. Kuantum devresi, bilgilendirici özellikleri çıkarmak için bir evrişim katmanı olarak uygulanır. Kuantum evrişim tabakasında üç aşama vardır: kodlama, kuantum devresi ve ölçüm. Başka bir mimaride Bausch (2020) QRNN adı verilen tekrarlayan sinir ağının (RNN) kuantum bir versiyonunu önerdi. QRNN'nin temel bileşeni kuantum bir nörondur. QRNN, rakam verilerini sınıflandırmak için kullanılır. Ayrıca, QRNN üretken bir model olarak kullanılır.

QML yeni bir araştırma alanı haline geldi ve birçok uygulamada yer aldı. QML'in hem yalnızca kuantumun özelliklerinden yararlandığı uygulamalar hem de yapılan hibrit çalışmalarda (QML+ML) elde edilen sonuçlar itibarıyla başarısı yaygınlığı artmaktadır. Bu nedenle QML'nin şuan için mekanik dezavantajlarından kaynaklanan (mutlak sıfır sıcaklığında çalıştırılması zorunlu ve kuantum gürültü (quantum noise) gibi) sorunların gelişen teknoloji ile birlikte çözülmesi ve bunun birlikte geliştirilecek olan yeni algoritmalarla, kuantum bilgisayarın ilerleyen yıllarda daha çok hayatımızda yer alacağı görülmektedir. Burada itici gücün şuan için QML'nin avantajlarının ML'ye uygulanması şeklinde olduğu görülmektedir. Bu konuda yapılan çalışmalara baktığımızda, Chrisley (1995) bu konuda geliştirilen uygulamalarda ilk QML kavramını ortaya atmıştır. Sonraki çalışmalardan olan Aimeur vd. (2006) ve Lloyd vd. (2013) deneysel ve denetimsiz öğrenme ile QC'de birlikte kullanılmıştır. Yakın zamanda yaptıkları çalışmada Aimeur vd. (2006), Dunjko vd. (2016) ve Schuld (2018) QML algoritmalarını kuantum veya klasik algoritmanın entegrasyonuna bağlı olarak Çizelge 1'de olduğu gibi dört kategoriye ayırmıştır.

- ✓ Kuantum-Quantum (QQ) kategorisi, bu kategori tamamen QML olarak da bilinir. QQ kategorisi kuantum algoritmaları ve verileri kullanır.
- ✓ Kuantum -Klasik (QC) kategorisi olan bu kategori, klasik ajanlardan öğrenmek için bir kuantum algoritması kullanır (Kuo vd. 2021).
- ✓ Klasik-Quantum (CQ) kategorisi, CQ algoritmaları standart ML'nin kuantum sürümleridir ve bu algoritmalar gerçek bir kuantum cihazda yürütülebilir.
- ✓ Kuantumdan ilham alan ML kategorisi tarafından yaygın olarak kullanılan klasik-klasik (CC) kategorisi. İlham ile CC kategorisinde kuantum bilgi işlem özellikleri (yani kuantum bitleri, süperpozisyon ve dolaşma) kullanılır.

Çizelge 1. Kuantum/klasik verilere ve kuantum/klasik algoritmaya dayalı kuantum makinesi öğrenme algoritmaları.

		Algoritma Tipi	
		Klasik	Kuantum
Veri Tipi	Klasik	CC	CQ
	Quantum	QC	QQ

Literatürde yapılmış olan çalışmaların kısa özeti Çizelge 2'de verilmiştir.

3. Metodoloji

Bu çalışma Kuantumsal Sinir Ağı kullanılarak Covid'19 veri setlerinin analizi, tahmini ve değerlendirilmesi yapılmıştır. Çalışmanın uygulama kısmı ilerleyen bölümlerde ayrıntılı olarak verilmiştir.

3.1. Veri seti ve Ön İşleme

Uygulamada kullanılan veri seti <https://www.kaggle.com/datasets/pranavraikokte/covid19-image-dataset> adresinden elde edilmiştir. Veri seti Covid-19, Viral Pnömoni ve Normal göğüs röntgenlerini içermektedir. Veri dağılımı; test verisi için 26 adet Covid-19, 20 adet Normal ve 20 adet Viral Pnömoni görüntüsü olmak üzere toplama 66 adet görüntüden oluşmaktadır. Eğitim veri setinin dağılımı ise, 111 adet Covid-19, 70 adet Normal ve 70 adet de Viral Pnömani olmak üzere toplamda 251 görüntüden oluşmaktadır. Veri kümesi, her biri 3 sınıfın görüntülerinden oluşan 3 klasör içeren eğitim ve test dizinlerine bölünmüştür.

Çalışma kapsamında, giriş verileri olarak akciğer röntgen görüntülerinin kuantum evrişimli sinir ağları (QCNN) ile işlenmesi ve sınıflandırılması sürecinde özellik seçme yöntemleri önemli bir rol oynamıştır. İşlenen görüntülerden elde edilen yüksek boyutlu özellikler, hesaplama kaynaklarının sınırlılığı göz önüne alınarak ve kuantum bit (kübit) sayısının kısıtları nedeniyle azaltılmak zorunda kalmıştır. Bu süreçte özellik seçme ve boyut indirgeme teknikleri kullanılmıştır.

Özellikle, her bir görüntü için elde edilen 256 özelliği, daha yönetilebilir ve kuantum hesaplama için uygun hale getirebilmek adına özellik seçme yöntemleriyle sırasıyla 11, 4 ve 2 özelliğe indirgenmiştir. Bu indirgeme işlemi, kuantum sınıflandırıcı modellerin performansını doğrudan etkileyen bir faktördür. Bu indirgeme işlemlerinde kullanılan özellik seçme yöntemlerinin başında, basitçe kübit sayısına göre manuel seçim veya matematiksel bir indirgeme tekniği olan

Çizelge 2. Literatür çalışması özeti.

Çalışma	Yöntem	Görev	Sonuçlar
Khoshaman vd.2018	Kuantum varyasyonel kendi kendini kodlama	Veri sıkıştırma	Kuantum kendi kendini kodlama algoritması deneysel olarak gerçekleştirildi.
Pepper vd. 2019	Kuantum kendi kendini kodlama	Veri sıkıştırma	Kuantum kendi kendini kodlama algoritması deneysel olarak gerçekleştirildi.
Alvarez vd. 2018	Kuantum yapay yaşam	Yapay yaşam simülasyonu	Kuantum yapay yaşam IBM kuantum bilgisayarında araştırıldı.
Nawaz vd. 2019	Kuantum makine öğrenmesi	6G iletişim ağları	6G iletişim ağları için kuantum makine öğrenmesi incelendi.
Wallnöfer vd. 2020	Makine öğrenimi	Uzak mesafe kuantum iletişimi	Uzak mesafe kuantum iletişimi için makine öğrenimi araştırıldı.
Von Lilienfeld 2018	Kuantum makine öğrenimi	Kimyasal bileşik uzayı	Kuantum makine öğrenimi kimyasal bileşik uzayında uygulandı.
Rieffel vd. 2015	Kuantum tavlama	Operasyonel planlama problemleri	Kuantum tavlama algoritması zorlu operasyonel planlama problemleri için programlandı.
Amin vd. 2018	Kuantum Boltzmann makinesi	Makine öğrenmesi	Kuantum Boltzmann makinesi önerildi.
McArdle vd. 2020	Kuantum hesaplamalı kimya	Kimyasal hesaplamalar	Kuantum hesaplamalı kimya incelendi.
Beer vd. 2020	Derin kuantum sinir ağları	Makine öğrenmesi	Derin kuantum sinir ağları eğitimi araştırıldı.
Dunjko ve Briegel 2018	Kuantum makine öğrenimi ve yapay zeka	Makine öğrenmesi ve yapay zeka	Kuantum alanındaki makine öğrenimi ve yapay zeka üzerine bir inceleme yapıldı.
Levine vd . 2019	Kuantum dolaşıklık	Derin öğrenme mimarileri	Derin öğrenme mimarilerinde kuantum dolaşıklık araştırıldı.
Mari vd. 2020	Transfer öğrenimi	Hibrit klasik-kuantum sinir ağları	Hibrit klasik-kuantum sinir ağlarında transfer öğrenimi araştırıldı.
Gao vd. 2017	Kuantumdan esinlenen derin sinir ağı	Uçak yakıt sistemi arıza teşhisi	Uçak yakıt sistemi arıza teşhisi için kuantumdan esinlenen derin sinir ağı önerildi.
Pomarico vd. 2021	Kuantumdan esinlenmiş makine öğrenimi	Tıbbi teşhis	Tıp amaçlı kuantumdan esinlenmiş makine öğrenimi önerildi.
Huang vd.2021	Kuantum makine öğrenmesi	Makine öğrenmesi	Kuantum makine öğrenmesinde verilerin gücü araştırıldı.
Schuld vd. 2016	Kuantum doğrusal regresyon	Örüntü tanıma	Denetimli öğrenmeye dayanan örüntü tanıma için kuantum doğrusal regresyon algoritması önerildi.
Ezhov ve Ventura 2000	Kuantum sinir ağları	Makine öğrenmesi	Kuantum sinir ağlarının klasik sinir ağlarına göre avantajları tartışıldı.

Çizelge 2. Devamı

Çalışma	Yöntem	Görev	Sonuçlar
da Silva vd.2016	Kuantum algılama	Makine öğrenmesi	Bir alan üzerinde kuantum algılama ve süperpozisyon tabanlı mimari öğrenme algoritması önerildi.
Schuld vd. (2015)	Kuantum algılama	Makine öğrenmesi	Kuantum donanımı üzerinde kuantum faz tahmini kullanarak klasik algılama kuantum bir versiyonu tanıtıldı.
Zhou 2010	Kuantum rekabetçi sinir ağı	Makine öğrenmesi	Rekabetçi öğrenme sinir ağlarına dayanan kuantum bir model önerildi.
Zhong ve Yuan 2012	Kuantum rekabetçi sinir ağı	Makine öğrenmesi	Kuantum dolaşıklık ve Grover'ın algoritmasını kullanan bir kuantum rekabetçi sinir ağı modeli önerildi.
Zidan vd 2019	Kuantum rekabetçi sinir ağı	İkili sınıflandırma	Dolaşma önlemine dayanan ikili sınıflandırma için kuantum rekabetçi sinir ağı önerildi.
Abbas vd. 2021	Kuantum sinir ağları	Makine öğrenmesi	Kuantum sinir ağlarının gücü ve klasik sinir ağlarına göre avantajları tartışıldı.
Chen ve Yoo 2021	Birleşik kuantum-klasik makine öğrenmesi	Makine öğrenmesi	Hibrit kuantum-klasik makine öğrenmesi modeli önerildi.
Dang vd. 2018	Kuantum KNN algoritması	Görüntü sınıflandırması	Görüntü sınıflandırması için kuantum KNN algoritması önerildi.
Adhikary vd 2020	Varyasyonlu kuantum sınıflandırıcısı	Veri sınıflandırması	Tek bir kuantum sistemi ile varyasyonlu kuantum sınıflandırıcısı ve tek-atış eğitim algoritması sunuldu.
Mitarai vd. 2018	Kuantum devre öğrenimi	Sınıflandırma, regresyon, kümeleme	Sınıflandırma, regresyon ve kümeleme gibi farklı görevleri yerine getirmek için hibrit bir klasik-kuantum tekniği sunuldu.
Henderson vd. 2020	Kuantum evrişimli sinir ağları	Görüntü sınıflandırması	Görüntü sınıflandırması için standart evrişimsel sinir ağlarına sahip kuantum devreleri kullanıldı.
Bausch 2020	Tekrarlayan kuantum sinir ağları	Makine öğrenmesi	Tekrarlayan sinir ağının kuantum bir versiyonu önerildi.

Truncated Singular Value Decomposition (TruncatedSVD) yöntemi gelmektedir. Bu yöntemler, yüksek boyutlu verileri daha az sayıda özelliğe indirirken bilgi kaybını minimize etmeye çalışır. Geliştirilen sınıflandırıcı modellerin başarısını değerlendirmek için kullanılan bu özellik seçme yöntemleri, QCNN'nin giriş veri alanını, işlem için gereken kübit sayısını karşılayacak şekilde uygun boyuta getirmekte önemli bir işleve sahiptir. Bu süreç, hesaplama kaynaklarının kısıtlı olduğu durumlarda dahi, kuantum makine öğrenmesi alanında etkili modellerin geliştirilmesine olanak tanımıştır.

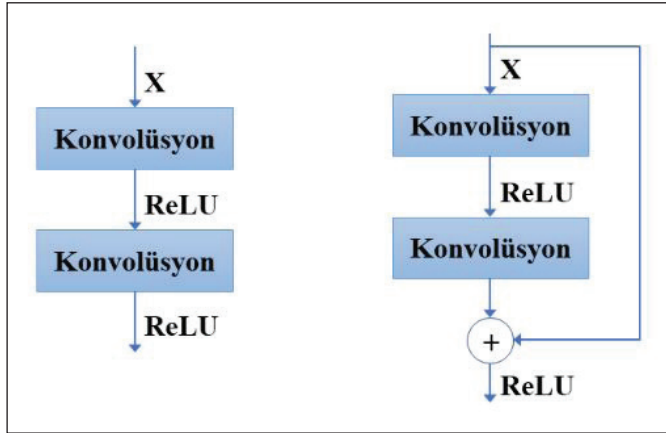
Kullanılan veri seti modeli için 251 eğitim ve 66 test görüntüsü içermektedir. Veri setine ait görüntüler gerçek hayattaki göğüs röntgenidir ve önceden değiştirilmemiştir. Yani hepsinin farklı boyutları vardır. Bundan dolayı görsellerin ölçüsü belirli bir boyuta indirilmiştir. Bir görüntüyü yeniden boyutlandırmak, yalnızca genişlik, yalnızca yükseklik veya her ikisini birden değiştirmek olsun, boyutlarının değiştirilmesi anlamına gelir. Başlangıçta veri seti, her sınıfın tüm görüntülerinin farklı klasörlere yerleştirildiği bir klasör formatında kullanılmaktadır. Bu görselleri openCV kütüphanesini

kullanarak 28x28'e dönüştürmek için bir Python betiği kullanılmıştır. Son olarak csv formatında kaydedilmiştir.

3.2. Resnet-50 Modeli

ResNet-50, "Residual Network" (ResNet) adı verilen bir derin öğrenme modeli ailesinin bir üyesidir ve 2015 yılında Kaiming He ve arkadaşları tarafından Microsoft Research'te geliştirilmiştir. ResNet, bilgisayar görüşü (computer vision) görevlerinde büyük başarı elde etmiş ve ImageNet gibi büyük veri setlerindeki görüntü sınıflandırma görevlerinde özellikle etkili olmuştur. ResNet, diğer derin sinir ağlarına kıyasla daha derin ağların eğitilmesini kolaylaştırmak için geliştirilmiş bir mimariye sahiptir. Ana yenilik, "residual bloklar" olarak adlandırılan özel bir yapıdır. Bu bloklar, daha önceki katmanların çıktılarını (giriş) son katmana ekler. Bu, ağın daha derin hale getirilmesine olanak tanırken, aynı zamanda aşırı uçlarını (vanishing gradients) çözer ve eğitimi daha verimli hale getirir.

ResNet-50 modeli özellikle 50 katmanlı bir derin ağıdır ve ortalama olarak 3.9×10^9 parametreye sahiptir. Model aşağıdaki ana bileşenleri içerir:



Şekil 1. Standart ESA (sol); ResNet mimarilerinde kullanılan kısayol bağlantıları (sağ).

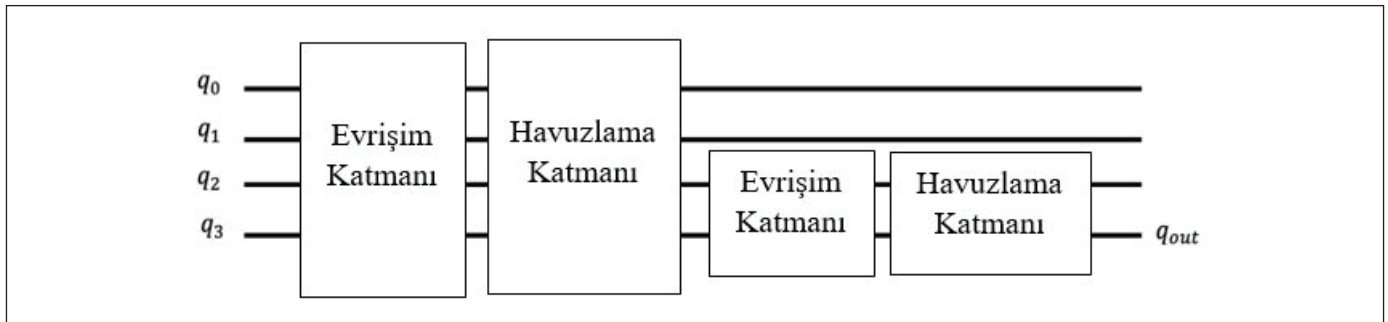
- **Giriş Katmanı:** Resimlerin RGB renk kanallarını (genellikle 224x224 piksel) kabul eder.
- **Beş İçerikli (Convolutional) Grup:** Bu gruplar, birbirini takip eden beş residual blok içerir. Her biri farklı filtre sayılarına ve evrişim çekirdek boyutlarına sahip olabilir.
- **Global Ortalama Havuzlama (Global Average Pooling):** Son residual blok çıktılarını alır ve bunları global ortalama havuzlama katmanına ileterek her bir özellik haritasını tek bir değere dönüştürür.
- **Tam Bağlantı Katmanı (Fully Connected Layer):** Global ortalama havuzlama sonucunu, sınıflandırma yapmak için kullanılır. Genellikle 1000 farklı sınıfı tanıyabilen bir sınıflandırma katmanına sahiptir.
- **Softmax Katmanı:** Sınıflandırma sonuçlarını olasılık dağılımlarına dönüştürür.

ResNet-50 modeli, çeşitli görsel görevlerde önceden eğitilmiş bir ağırlık modeli olarak kullanılabilir veya özelleştirilerek belirli görevler için eğitilebilir. Bu model, özellikle nesne tespiti, görüntü sınıflandırma ve transfer öğrenme görevlerinde popüler bir seçenektir. Şekil 1'de standart bir Evrişimli Sinir Ağı(ESA) ile ResNet mimarilerinde kullanılan kısayol bağlantıları görülmektedir.


3.3. Kuantum Devresi ve Modeli

QCNN'de her katman parametrelendirilmiş devreler içerir; bu, her katmanın parametrelerini ayarlayarak çıktı sonucumuzu değiştirdiğimiz anlamına gelir. QCNN'yi eğitirken, kayıp fonksiyonunu azaltmak için ayarlananlar bu parametrelerdir. Dört kübitlik QCNN örneği aşağıda Şekil 2'de gösterilmiştir.


Yapılmış olan bu çalışma kapsamında kullanılan kuantum devresinin evrişim katmanı Şekil 3 ve havuzlama katmanı Şekil 4'te verilmiştir.



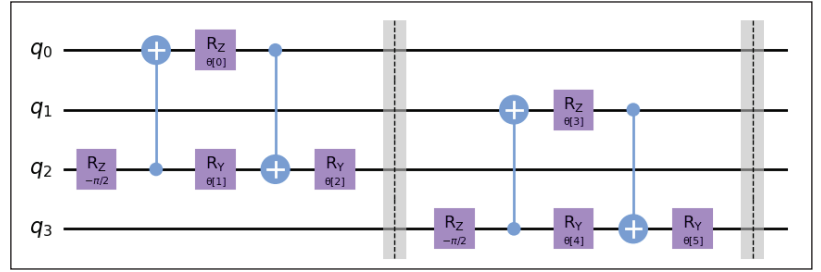
Şekil 2. Dört kübitlik QCNN örneği.



Şekil 3. Kuantum devresi evrişim katmanı.



Şekil 4. Kuantum devresi havuzlama katmanı..



Şekil 5. Kuantum devresi.

Bu yaklaşımda, her havuzlama katmanındaki kubitleri göz ardı edilmiştir. N kubit Kuantum Devre boyutlarını $N/2$ 'ye dönüştüren bir QCNN Havuzlama Katmanı oluşturulmuştur. Dört kubit devrenin boyutsallığı son iki kubitte, yani bu özel örnekteki son iki kubitte indirgenmiştir. Bu kubitler daha sonra bir sonraki katmanda kullanılırken, ilk ikisi QCNN'nin geri kalanında ihmal edilir. Bu iki kubitlik üniter devreyi uyguladıktan sonra sonraki katmanlarda ilk kubit (q_0) ihmal edilmiş ve sadece ikinci kubit (q_1) kullanılmıştır. N kubit için havuzlama katmanımızı oluşturmak amacıyla bu iki kubit havuzlama katmanı farklı kubit çiftlerine uygulanmıştır. Bu çalışmada kuantum sınıflandırmada kullanılan devre Şekil 5'te gösterilmiştir.

Kuantum evrişimli sinir ağları (QCNN), klasik sinir ağlarının yeteneklerini kuantum hesaplamaların benzersiz avantajlarıyla genişleten gelişmiş bir modeldir. Her katmanı, belirli parametrelerle donatılmış kuantum devrelerinden oluşur, böylece bu parametrelerin ayarlanmasıyla modelin çıktısını doğrudan etkileyebiliriz. Öğrenme süreci, kayıp fonksiyonunu en aza indirecek şekilde bu parametrelerin ayarlanması üzerine kuruludur.

Bir QCNN örneği olarak, dört kubitlik bir yapı göz önüne alınabilir. Bu yapı, kuantum evrişim ve havuzlama katmanlarını içerir. Örneğin, bir dört kubit devresinde, devrenin boyutsallığı son iki kubitte indirgenebilir. Bu süreçte, ilk iki kubit ihmal edilirken, son iki kubit sonraki işlemler için kullanılır. Bu yaklaşım, kuantum devresinin boyutunu yarıya indirgeyerek verimliliği artırır.

Kuantum devresindeki evrişim katmanı, verilerin kuantum mekanik özelliklerini kullanarak işlenmesini sağlar. Benzer şekilde, havuzlama katmanı, veri boyutunun azaltılmasını ve önemli özelliklerin korunmasını hedefler. Bu katmanlar, kuantum bilgisayarlarının paralel işleme kabiliyetlerinden faydalanarak veri setlerindeki karmaşık örüntüleri etkili bir şekilde tespit edebilir.

Bu çerçevede, QCNN'ler, kuantum mekaniğinin temel prensiplerini kullanarak, klasik evrişimli sinir ağlarının ulaşamayacağı bir veri işleme ve öğrenme kapasitesine ulaşır. Bu özellikleriyle QCNN'ler, özellikle büyük ve karmaşık veri setlerinde, yeni ve daha güçlü makine öğrenme modellerinin geliştirilmesine olanak tanır.

3.4. Evrişim Katmanının Uygulanması

Tek bir evrişim filtresinin, veri kümesindeki görüntülerin uzamsal olarak yerel alt bölümlerini girdi olarak alan rastgele bir kuantum devresi q kullandığı düşünülmüştür. Her giriş (u_i), $n \times n$ boyutunda 2 boyutlu bir matristir; burada $n > 1$ 'dir. 4 kübitlik bir sistemi simüle eden bir PennyLane default.qubit cihazı başlatılmıştır. Kuantum devresi aşağıdaki-lerden oluşmaktadır:

- Yerel Ry rotasyonlarının gömülü katmanı;
- n katmanlı, rastgele parametrelendirilmiş bir kuantum devresi;
- Hesaplamalı temelde 4 beklenti değerini tahmin eden son bir ölçüm.

Görüntü 2×2 piksellik karelere bölünür ve her kare kuantum devresi tarafından işlenir ve son olarak 4 beklenti değeri, tek bir çıkış pikselinin 4 farklı kanalına eşlenir.

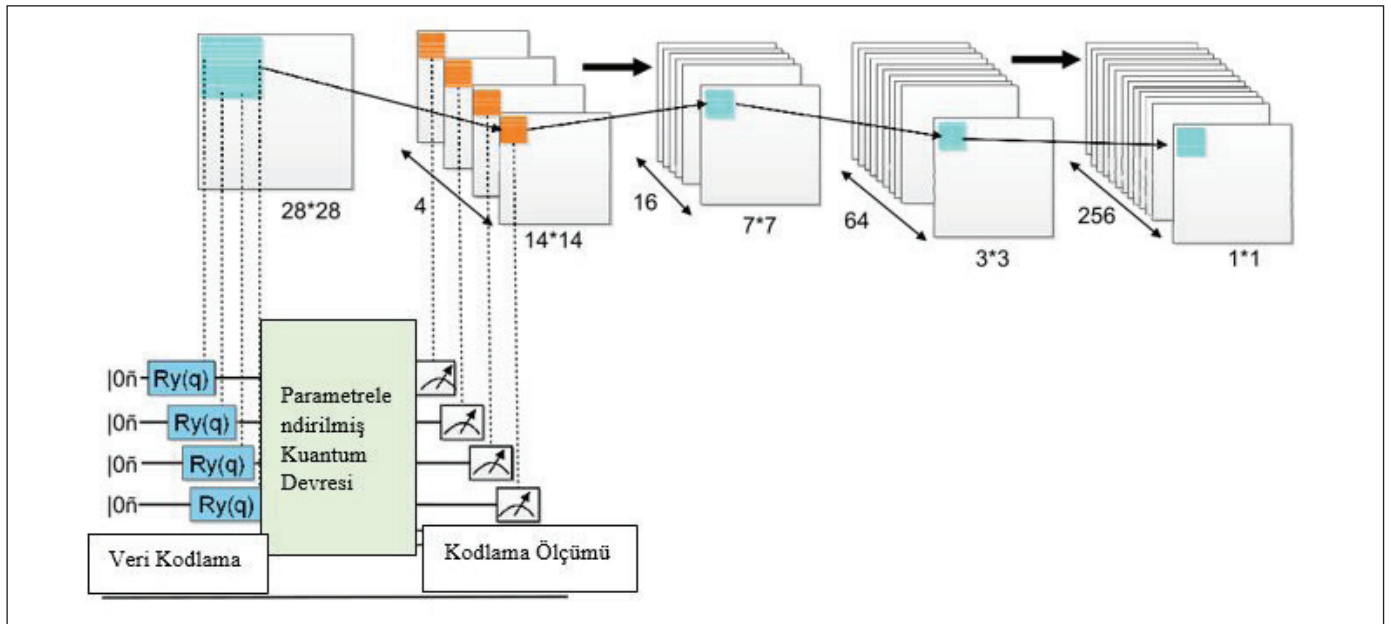
Evrişimli Sinir Ağının tek katmanlı yaklaşımı bu modelde tam 4 katman olacak şekilde çoklu katmanlara Şekil 6'da gösterildiği gibi genişletilmiştir. Başlangıçta her görüntü ($28 \times 28 \times 1$) boyutuna sahiptir ve bu boyut ilk Evrişim katmanıyla beslenerek ($14 \times 14 \times 4$) biçimine dönüştürülür. 2. Katman ($7 \times 7 \times 16$), 3. Katman ($3 \times 3 \times 64$) ve son olarak 4. ve son katman her birini ($1 \times 1 \times 256$) boyutlu bir veri matrisine dönüştürür. Kuantumsal Katman kapılarının parametreleri eşit şekilde rastgele olmasına rağmen, bu parametreleri eğitime yaklaşımı da göz önünde bulundurulmuştur ve bu uygulama

çalışmasının genişletilmiş versiyonunda daha sonra sonuçta herhangi bir gelişme olup olmadığı değerlendirilmiştir.

4. Sınıflandırma Modeli ve Bulgular

Yapmış olduğumuz çalışmada kullanılan kuantum sınıflandırıcı model parametrelerinin, model başarımı üzerinde önemli bir etkisi vardır. Kuantum Sınıflandırıcı-1, -2 ve -3'te kullanılan öznelik sayılarının optimizasyonu, doğruluk oranlarının artırılmasına yardımcı olabilir. Örneğin, Kuantum Sınıflandırıcı-2'de görüldüğü gibi, 256 öznelikten 4 özneliğe indirgeme, %72'lik bir doğruluk sağlamıştır. Bu, daha fazla öznelikle denemeler yaparak, ideal öznelik sayısını belirlemek için bir fırsat sunar. Ek olarak Araştırmamızda, "Kuantum Sınıflandırıcı-1" modelinde temel veri analizi ile elde edilen 256 özellikli giriş verisinden 11 öznelik kullanılmıştır ve bu model yaklaşık %70 doğruluk elde etmiştir. "Kuantum Sınıflandırıcı-2" modelinde, TruncatedSVD yöntemi ile 256 öznelik 4'e indirgenmiş ve model yaklaşık %72 doğruluk sağlamıştır. "Kuantum Sınıflandırıcı-3" modelinde ise, veri seti yalnızca 2 özneliğe indirgenmiş ve bu modelle %76 doğruluk elde edilmiştir.


Bu çalışmada, PennyLane'in "varsayılan qubit" cihazında kullanılan farklı parametrelerin model performansına etkileri incelenmiştir. Bu parametreler arasında yerel Ry rotasyonlarının gömülü katmanı, rastgele parametrelendirilmiş bir kuantum devresinin katmanları ve hesaplamalı temelde beklenti değerlerini tahmin eden son ölçümler bulunmaktadır. Kullanılan parametreler, bir kuantum devresindeki veri-



Şekil 6. Evrişimli sinir ağının uygulanması.

lerin işleniş şeklini etkileyerek modelin sonuçlarını doğrudan etkiler. Örneğin, yerel Ry rotasyonlarının gömülü katmanı, verilerin kuantum devresine nasıl gömüldüğünü belirlerken, kuantum devresinin katman sayısı ve türü, devrenin verileri nasıl işleyeceğini ve hangi özellikleri çıkaracağını belirler.

Evrişim katmanlardan sonra sırada sınıflandırıcı modeli vardır. Sınıflandırıcı modeli, her biri ikili sınıflandırıcı olan iki alt sınıflandırıcıdan oluşmaktadır. Bu ikisi 'Model-1' ve 'Model-2' olarak adlandırılmıştır. Şekil 7'de gösterilmiştir.



Şekil 7. Sınıflandırıcı model.


Model-1, 'Normal Kişi' ve 'Covid19/Viral Pnömoni' olmak üzere iki sınıf arasında sınıflandırma yapar. Model-2, 'Covid-19' ve 'Viral Pnömoni' olmak üzere iki sınıf arasında sınıflandırma yapar.

Tahmin yaparken öncelikle Model-1'e girdi verilmiştir. Normal kişi olarak tahmin yapıyorsa bu, girişe atanan son tahmindir. Değilse, aynı girdi Model-2'ye verilir ve sonunda göğüs röntgeninin hastalarda Covid'19 veya Viral Pnömoni olup olmadığını ortaya çıkaracağını tahmin edilir.

Her giriş görüntüsünün altında kuantum evrişimi tarafından oluşturulan 4 çıkış kanalı gri tonlamayla görselleştirilir. Kuantum çekirdeği ve çözünürlüğün aşağı örnekleme (down sampling) tarafından bazı yerel bozulmaların ortaya çıktığı açıkça gözlemlenebilir. Bununla birlikte, bir evrişim katmanından beklendiği gibi görüntünün global şekli korunur. Bu durum Şekil 8'de gösterilmiştir.

Performans metriklerinin gösterildiği Çizelge 3'te en sol sütunda yer alan 0,1 ve 2 değerleri sınıflandırmada kullanılan sınıfları ifade etmektedir. Bunlar sırasıyla Covid'19, Normal, Viral Pnömonidir. Doğrulama setinde elde edilen accuracy puanı %96,97'dir. Ayrıca karmaşıklık matrisine baktığımızda temel tanı unsurlarının çok yüksek, diğerlerinin ise sıfır olduğunu görüyoruz. Anlaşılacağı üzere test setindeki tüm veri noktaları doğru şekilde sınıflandırılmaktadır.

Sonuç olarak; Transfer öğrenimi yoluyla Imagenet üzerinde ResNet-50 ağırlıklarıyla evrişimli bir sinir ağı eğitildi. Ayrıca karmaşıklık matrisine baktığımızda temel tanı unsurlarının çok yüksek, diğerlerinin ise sıfır olduğunu görüyoruz.



Şekil 8. A) Sıkıştırılmış görüntüler 14*14, B) Covid'19 veri kümesindeki kuantumsal sinir ağı.


Çizelge 3. Performans metrikleri.

	Kesinlik	Duyarlılık	f1-skoru	Destek*
0	1	1	1	94
1	1	0.90	0.95	71
2	0.91	1.00	0.95	73
Doğruluk	0.97	0.97	0.97	238


*: Destek, o sınıfta yer alan gerçek yanıtın örneklerinin sayısıdır.

Çizelge 4. Kuantum sınıflandırıcı model parametreleri.

Kuantum Sınıflandırıcı	Kubit Sayısı	Öğrenme Oranı	İterasyon Başına İşlenen Örnek Sayısı	Eğitim Döner Sayısı	Kuantum Devre Derinliği	Maksimum Katman Sayısı
Sınıflandırıcı-1	11	1e-3	4	20	4	15
Sınıflandırıcı-2	4	1e-3	4	20	4	15
Sınıflandırıcı-3	2	1e-3	4	20	4	15



Şekil 9. Kuantum Sınıflandırıcı-1 model 1 için maliyet ve eğitim doğruluk grafiği.

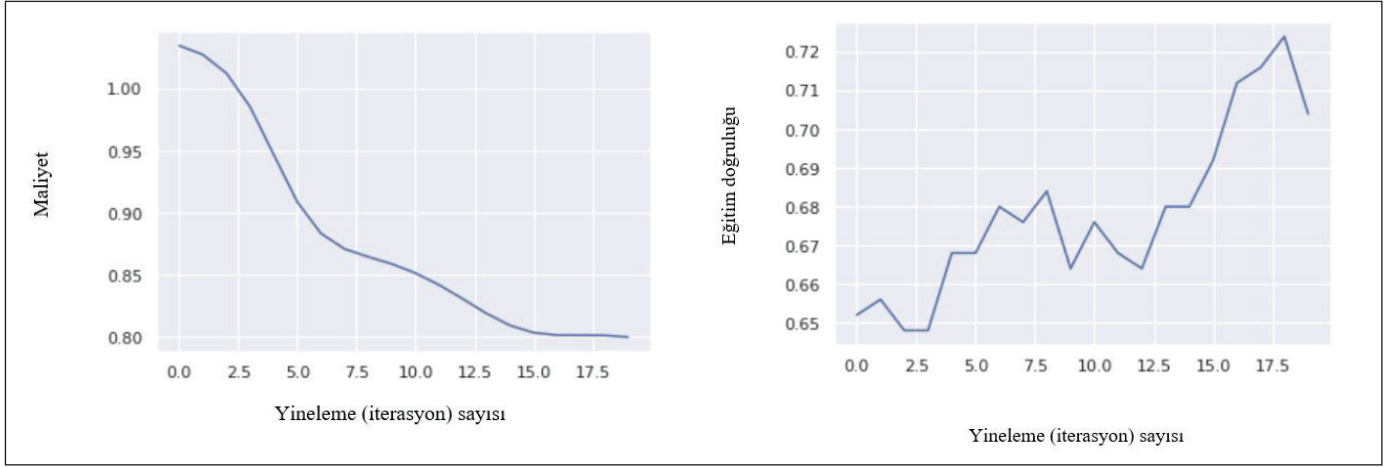


Şekil 10. Kuantum Sınıflandırıcı-1 model 2 için maliyet ve eğitim doğruluk grafiği.


Bu nedenle test setindeki tüm veri noktaları doğru şekilde sınıflandırılmaktadır

Çalışma kapsamında kullanılan kuantum sınıflandırıcı model parametreleri Çizelge 4'te verilmiştir.


Oluşturulan modelin performansını ölçmek (maliyet fonksiyonu) ve oluşturulan modelin eğitim sırasında ne kadar iyi performans gösterdiğinin ölçüsü olan (eğitim doğruluğu) analizler kullanılarak farklı kuantum sınıflandırıcının ve modellerin sonuçları Şekil 9-14'te verilmiştir.




Şekil 11. Kuantum Sınıflandırıcı-2 model 1 için maliyet ve eğitim doğruluk grafiği.



Şekil 12. Kuantum Sınıflandırıcı-2 model 2 için maliyet ve eğitim doğruluk grafiği.



Şekil 13. Kuantum Sınıflandırıcı-3 model 1 için maliyet ve eğitim doğruluk grafiği.



Şekil 14. Kuantum Sınıflandırıcı-3 model 2 için maliyet ve eğitim doğruluk grafiği.

- Kuantum Sınıflandırıcısı 1'de, Temel Veri Analizi ile çıkarılan 256 öznitelik boyutlu girdi verisinden 11 öznitelik kullanılmıştır. Burada yaklaşık %70 doğruluk elde edilmiştir.
- Kuantum Sınıflandırıcısı 2'de TruncatedSVD yöntemini kullanarak her görüntünün 256 özniteliği 4'e indirilmiştir. Yaklaşık %72 doğruluk (accuracy) elde edilmiştir.
- Kuantum Sınıflandırıcısı 3'de verileri yalnızca 2 öznitelige indirgenmiştir. Beklenmedik bir şekilde bu bize daha önce yaklaşılanların en yükseği olan %76 doğruluğu vermiştir.

5. Sonuç ve Öneriler

Kuantum evrişimli sinir ağları (QCNN'ler), kuantum hesaplamanın potansiyel olarak güçlü bazı yönlerinden yararlanarak CNN'lerin yeteneklerini genişletir. Bir dizi rastgele kuantum devresi kullanarak verileri yerel olarak dönüştürerek giriş verileri üzerinde çalışır. Klasik evrişimli sinir ağlarının verimliliğinden yola çıkarak, Evrişimli sinir ağını (QNN'ler) kullanarak veriler analiz edilmiş, tahminler yapılmış ve sonuçlar değerlendirilmiştir. Kuantum halinde kodlanmış covid-19 veri setinin ikili sınıflandırması gerçekleştirilmiştir. Ayrıca Pennylane'in "varsayılan qubit" cihazındaki farklı parametreleri de dikkate alarak performansı araştırılmıştır.

Bu bağlamda, kuantum devrelerinin, polinom boyutlu klasik hesaplama kaynakları kullanılarak gerçekleştirilmesi mümkün olmayan karmaşık fonksiyonel ilişkileri modelleyebildiği gösterilmiştir. Kuantum devresinin sağlamış olduğu fayda klasik olarak anlaşılması zor olan oldukça karmaşık çekirdekler üretebilmesidir.

Veri kümesindeki gerçek röntgen görüntüleri birçok bilgiyi barındıracak kadar büyüktür. Ancak hesaplama kaynaklarının eksikliği nedeniyle, openCV kütüphanesi kullanılarak boyut 28x28'e düşürülmüştür, bu da birçok önemli bilgiyi bastırılmış olabilir. Daha sonra, daha fazla hesaplama kaynağının bulunmasıyla birlikte, modelin doğruluğunu artıracak 256x256 boyutlu görüntüyü kullanmak mümkün olabilir.

Evrişim uygulanıp veriler düzleştirildikten sonra her görüntünün 256 özelliği elde edildi ve 11 özellik, kübit eksikliğinden dolayı özellik seçme yöntemiyle kullanıldı. Bu çalışma, kuantum sistemi hakkında fikir edinmek için daha fazla sayıda mevcut kübit ve kuantum devresinin gerçek zamanlı simülasyonu ile gerçek zamanlı bir kuantum bilgisayarında uygulanabilir. Dahası, daha fazla kübitin varlığıyla rastgele oluşturulmuş görüntü verileri üzerinde dört evrişim katmanının eğitimi test edilebilir. Sonuç olarak, geleceğe dönük çalışmalar ve öneriler aşağıda verilmiştir:

- Veri kümesindeki gerçek röntgen görüntüleri birçok bilgiyi barındıracak kadar büyüktür. Ancak önceden de açıklandığı üzere hesaplama kaynaklarının eksikliği nedeniyle, openCV kütüphanesini kullanarak boyutu 28x28'e düşürülmüştür, bu da birçok önemli bilgiyi bastırılmış olabilir. Daha sonra modelin doğruluğunu artıracak 256x256 boyutlu görüntü ile denemeler yapılabilir.
- Şu anda evrişimi uyguladıktan ve verileri düzleştirdikten sonra her görüntünün 256 özelliğine sahip olmamıza rağmen, çeşitli öznitelik boyutu küçültme yöntemleriyle sırasıyla Kuantum Sınıflandırıcı-1, Kuantum Sınıflandırıcı-2 ve Kuantum Sınıflandırıcı-3'te yalnızca 11 öznitelik, 4 öznitelik ve 2 öznitelik kullanılmıştır. Daha yüksek

boyutlu verilerle doğruluğun artıp artmadığını veya kuantum bilgisayarların yalnızca daha az sayıda özellik ile daha iyi çalışıp çalışmadığını denemek için daha fazla öznitelik denenebilir.

- Görüntü verilerine uygulanan dört evrişim katmanının tümü, daha fazla eğitilmeyen, tek biçimli oluşturulmuş rastgele parametreler kullanmaktadır. Daha sonra, değiştirilmiş veri kümesinin gerçek görüntüler hakkında çok daha fazla veri içerebilmesi için bu evrişim katmanların da eğitilmesi söz konusu olabilir.
- Son olarak, daha doğru simülasyonlar üzerinde eğitilen modellerin eğitim sonucunu ve nihai doğruluğu elde edilmesi ve daha gerçekçi deneysel veriler elde etmek için bunları yavaş yavaş gerçek kuantum bilgisayarlarında çalıştırmayı denemek doğruluk (accuracy) değerlerinin artmasını şüphesiz ki sağlayacaktır.

Yazar katkısı: Güneş Harman: çalışmayı planlamış ve tasarlamıştır, Seçmen Şahin: Çalışma hakkında verileri toplamıştır. Güneş Harman ve Seçmen Şahin: Çalışmanın analizlerini yapmıştır. Güneş Harman ve Seçmen Şahin: makaleyi yazmıştır.

Etik kurul onayı: Etik kurul onayı gerekmemektedir.

6. Kaynaklar

- Abbas, A., Sutter, D., Zoufal, C., Lucchi, A., Figalli, A., Woerner, S. 2021. The power of quantum neural networks. *Nature Computational Science*, 1, 403–409.
- Adhikary, S., Dangwal, S., Bhowmik, D. 2020. Supervised learning with a quantum classifier using multi-level systems. *Quantum Information Processing*, 19, 89.
- Aïmeur, E., Brassard, G., Gambs, S. 2006. Machine learning in a quantum world. In *Conference of the Canadian society for computational studies of intelligence* (pp. 431–442). Springer.
- Alvarez-Rodriguez, U., Sanz, M., Lamata, L., Solano, E. 2018. Quantum artificial life in an ibm quantum computer. *Scientific Reports*, 8, 1–9.
- Amin, MH., Andriyash, E., Rolfe, J., Kulchytskyy, B., Melko, R. 2018. Quantum boltzmann machine. *Physical Review X*, 8, Article 021050.
- Bausch, J. 2020. Recurrent quantum neural networks. In *Advances in neural information processing systems*, 33.
- Beer, K., Bondarenko, D., Farrelly, T., Osborne, T.J., Salzmann, R., Scheiermann, D., et al. 2020. Training deep quantum neural networks. *Nature Communications*, 11, 1–6.
- Chen, SYC., Yoo, S. 2021. Federated quantum machine learning. *Entropy*, 23, 460.
- Dang, Y., Jiang, N., Hu, H., Ji, Z., Zhang, W. 2018. Image classification based on Quantum KNN Algorithm
- Chrisley, R. 1995. Quantum learning. In *New directions in cognitive science: Proceedings of the international symposium*, Vol. 4. Saariseika: Citeseer.
- Dang, Y., Jiang, N., Hu, H., Ji, Z., Zhang, W. (2018). Image classification based on quantum K-Nearest-Neighbor algorithm. *Quantum Information Processing*, 17, 1-18.
- da Silva, AJ., Ludermir, TB., de Oliveira, WR. 2016. Quantum perceptron over a field and neural network architecture selection in a quantum computer. *Neural Networks*, 76, 55–64.
- Dunjko, V., Briegel, HJ. 2018. Machine learning & artificial intelligence in the quantum domain: a review of recent progress. *Reports on Progress in Physics*, 81, Article 074001
- Dunjko, V., Taylor, JM., Briegel, HJ. 2016. Quantum-enhanced machine learning. *Physical Review Letters*, 117, Article 130501.
- Ezhov, AA., Ventura, D. 2000. Quantum neural networks. In *Future directions for intelligent systems and information sciences*, 213–235. Springer
- Gao, Z., Ma, C., Song, D., Liu, Y. 2017. Deep quantum inspired neural network with application to aircraft fuel system fault diagnosis. *Neurocomputing*, 238, 13–23.
- Henderson, M., Shakya, S., Pradhan, S., Cook, T. 2020. Quantum neural networks: powering image recognition with quantum circuits. *Quantum Machine Intelligence*, 2, 1–9.
- Huang, HY., Broughton, M., Mohseni, M., Babbush, R., Boixo, S., Neven, H., et al. 2021. Power of data in quantum machine learning. *Nature Communications*, 12, 1–9.
- Kerenidis, I., Prakash, A. 2017. Quantum gradient descent for linear systems and least squares. arXiv:1704.04992 (quant-ph).
- Khoshaman, A., Vinci, W., Denis, B., Andriyash, E., Amin, MH. 2018. Quantum variational autoencoder. *Quantum Science and Technology*, 4, Article 014001. arXiv:1802.05779v1 (quant-ph).
- Lamata, L. 2020. Quantum machine learning and quantum biomimetics: A perspective. *Machine Learning: Science and Technology*, 1, Article 033002.
- Levine, Y., Sharir, O., Cohen, N., Shashua, A. 2019. Quantum entanglement in deep learning architectures. *Physical Review Letters*, 122, Article 065301.
- Lloyd, S., Mohseni, M., Rebentrost, P. 2013. Quantum algorithms for supervised and unsupervised machine learning. arXiv preprint arXiv:1307.0411.
- Mari, A., Bromley, TR., Izaac, J., Schuld, M., Killoran, N. 2020. Transfer learning in hybrid classical-quantum neural networks. *Quantum*, 4, 340.

- Mitarai, K., Negoro, M., Kitagawa, M., Fujii, K. 2018.** Quantum circuit learning. *Physical Review A*, 98, Article 032309.
- McArdle, S., Endo, S., Aspuru-Guzik, A., Benjamin, S.C., Yuan, X. 2020.** Quantum computational chemistry. *Reviews of Modern Physics*, 92, Article 015003.
- Nawaz, S.J., Sharma, S.K., Wyne, S., Patwary, M.N., Asaduzzaman, M. 2019.** Quantum machine learning for 6 g communication networks: State-of-the-art and vision for the future. *IEEE Access*, 7, 46317–46350.
- Pepper, A., Tischler, N., Pryde, G.J. 2019.** Experimental realization of a quantum autoencoder: The compression of qutrits via machine learning. *Physical Review Letters*, 122, Article 060501.
- Pomarico, D., Fanizzi, A., Amoroso, N., Bellotti, R., Biafora, A., Bove, S., et al. 2021.** A proposal of quantum-inspired machine learning for medical purposes: An application case. *Mathematics*, 9, 410.
- Rahman M., Geiger, D. 2016.** Quantum clustering and gaussian mixtures. arXiv:1612.09199v1 (stat.ML).
- Rebentrost, P., Mohseni, M., Lloyd, S. 2014.** Quantum support vector machine for big data classification. *Physical Review Letters*, 113, Article 130503.
- Rieffel, E.G., Venturelli, D., O’Gorman, B., Do, M.B., Prystay, E.M., Smelyanskiy, V.N. 2015.** A case study in programming a quantum annealer for hard operational planning problems. *Quantum Information Processing*, 14, 1–36.
- Schuld, M., Sinayskiy, I. ve Petruccione, F. 2015.** An introduction to quantum machine learning. *Contemporary Physics*, 56(2), 172-185.
- Schuld, M., Sinayskiy, I., Petruccione, F. 2015.** Simulating a perceptron on a quantum computer. *Physics Letters. A*, 379, 660–663.
- Schuld, M., Sinayskiy, I., Petruccione, F. 2016.** Prediction by linear regression on a quantum computer. *Physical Review A*, 94, Article 022342.
- Schuld, M. 2018.** Supervised learning with quantum computers. Springer.
- Sheng, Y.B., Zhou, L. 2017.** Distributed secure quantum machine learning. *Science Bulletin*, 62, 1025–1029.
- Von Lilienfeld, O.A. 2018.** Quantum machine learning in chemical compound space. *Angewandte Chemie International Edition*, 57, 4164–4169.
- Wallnöfer, J., Melnikov, A.A., Dür, W., Briegel, H.J. 2020.** Machine learning for long-distance quantum communication. *PRX Quantum*, 1, Article 010301.
- Zhou, R. 2010.** Quantum competitive neural network. *International Journal of Theoretical Physics*, 49, 110–119.
- Zhong, Y., Yuan, C. 2012.** Quantum competition network model based on quantum entanglement. *Journal of Computers*, 7, 2312–2317.
- Zidan, M., Abdel-Aty, A.H., El-shafei, M., Feraig, M., Al-Sbou, Y., Eleuch, H., et al. 2019.** Quantum classification algorithm based on competitive learning neural network and entanglement measure. *Applied Sciences*, 9, 1277.