



**T.C.**

**ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**FİZİK ANABİLİM DALI**

**BAZI TIBBİ GÖRÜNTÜLERİN KUANTUM TEKNOLOJİK  
YÖNTEMLER İLE ANALİZİ**

**YÜKSEK LİSANS TEZİ**

**NİLAY DURMUŞ**

**Tez Danışmanı**

**PROF. DR. İHSAN YILMAZ**

**ÇANAKKALE – 2022**





T.C.

ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

FİZİK ANABİLİM DALI

**BAZI TIBBİ GÖRÜNTÜLERİN KUANTUM TEKNOLOJİK YÖNTEMLER İLE  
ANALİZİ**

YÜKSEK LİSANS TEZİ

NİLAY DURMUŞ

Tez Danışmanı

PROF. DR. İHSAN YILMAZ

ÇANAKKALE – 2022





T.C.  
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



Nilay DURMUŞ tarafından Prof. Dr. İhsan YILMAZ yönetiminde hazırlanan ve **05/09/2022** tarihinde aşağıdaki jüri karşısında sunulan “**Bazı Tıbbi Görüntülerin Kuantum Teknolojik Yöntemler ile Analizi**” başlıklı çalışma, Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü **Fizik Anabilim Dalı**’nda **YÜKSEK LİSANS YETERLİK TEZİ** olarak oy birliği ile kabul edilmiştir.

**Jüri Üyeleri**

**İmza**

Prof. Dr. İhsan YILMAZ  
(Danışman)

.....

Prof. Dr. Emine Dilara ATALAY

.....

Dr. Öğr. Üyesi Ali AKMAN

.....

Tez No : 10493326

Tez Savunma Tarihi :05/09/2022

.....  
Doç. Dr. Yener PAZARCIK  
Enstitü Müdürü

../09/2022

## ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

Nilay DURMUŞ  
(Tarih) 05/09/2022

## TEŐEKKÜR

Bu tezin gerekleŐtirilmesinde, alıŐmam boyunca bir an olsun benden yardımlarını esirgemeyen, bilgi ve tecrübelerinden ok yararlandıđım sayđı deđer danıŐman hocam Prof. Dr. İhsan YILMAZ'a, eđitimim boyunca bana her konuda yardımcı olan Fizik Anabilim Dalı öđretim üyesi hocalarımız: Prof. Dr. Emine Dilara ATALAY, Prof. Dr. Hüseyin AVUŐ ve merhum Do. Dr. Gülnur İKİS GÜN'e, kuantum hesaplamalarla ilgili bilgilerinden ok faydalandıđım Öđr. Gör. Erdi ACAR'a, BT görüntülerine ulaşmamı sađlayan Yeni Yüzyıl Üniversitesi Özel GaziosmanpaŐa Hastanesi Radyasyon Onkolojisi Bölümü alıŐanlarına, derslere gelebilmem için bana her türlü kolaylıđı sađlayan Esenler Nuri Pakdil Bilgi Evi Ailesine, hayatım boyunca beni her zaman destekleyen ve beni bugünlere getiren canım ailem, annem Saime ORT, babam Tufan ORT ve kardeŐim Faruk ORT'a, ve maddi, manevi her zaman yanımda olan canım eŐim İsmail Faruk DURMUŐ'a en içten duygularıyla teŐekkür ederim.

Nilay DURMUŐ  
anakkale, Eylül 2022

## ÖZET

### BAZI TIBBİ GÖRÜNTÜLERİN KUANTUM TEKNOLOJİK YÖNTEMLER İLE ANALİZİ

Nilay DURMUŞ

Çanakkale Onsekiz Mart Üniversitesi

Lisansüstü Eğitim Enstitüsü

Yüksek Lisans Tezi

Fizik Anabilim Dalı

Danışman: Prof. Dr. İhsan YILMAZ

05/09/2022, 46

Son yıllarda yapay zekâ ve makine öğrenmesi uygulamaları günlük hayatımızda yaygın olarak karşımıza çıkmakta ve hayatımızı kolaylaştırmaktadır. Özellikle veri analizi, istatistiksel optimizasyon ve karar verme süreçlerinde büyük kolaylık sağlarlar. Benzer şekilde tıp alanında da veri analizi ve hastalıkların teşhisinde kullanılmıştır. Tıbbi görüntüleme cihazları ile teşhis konulabilmekte ve vücuttaki anormal yapılar tespit edilebilmektedir. Akciğer kanserinde kitlenin yeri ve boyutu bilgisayarlı tomografi ile kolaylıkla belirlenebilir. Bununla birlikte çalışmada kullandığımız makine öğrenmesiyle uzmanlar, görüntüden lezyonlu bölgeyi çok kısa sürede teşhis ve analiz etmek ve hata olasılığını azaltmak için kullanabilir. Kullandığımız hibrit çalışma modellerinden kuantum çekirdek ve kuantum sinir ağı modelleri iki farklı veri seti üzerinde eğitilip test edilerek doğruluk, kesinlik, duyarlılık, özgüllük ve F1- puanları metrikleriyle ölçülmüştür. Ayrıca her iki model de 5-Fold çapraz doğrulama ile eğitilmiştir. Elde edilen değerler kuantum çekirdek ve kuantum sinir ağı modelleri performans sonuçlarına göre karşılaştırılmıştır. Her iki veri setinden çıkan sonuçlara göre kuantum çekirdek yönteminin bu çalışma için daha kullanışlı olduğu görülmüştür. Bu nedenle, bu çalışmanın akciğer kanserinde bilgisayarlı tomografi görüntüleri üzerinde makine öğrenmesi yöntemleriyle yapılacak farklı çalışmalara rehberlik edecek bir kaynak olması amaçlanmıştır.

**Anahtar Kelimeler:** Kuantum Makine Öğrenmesi, Kuantum Bilgisayar, Makine Öğrenmesi, Hibrit Makine Öğrenmesi, Akciğer Kanseri.



## ABSTRACT

### ANALYSIS OF SOME MEDICAL IMAGES WITH QUANTUM TECHNOLOGICAL METHODS

Nilay DURMUŞ

Çanakkale Onsekiz Mart University

School of Graduate Studies

Master of Science Thesis in Physics Science

Advisor: Prof. Dr. İhsan YILMAZ

05/09/2022, 46

In recent years, artificial intelligence and machine learning applications have been widely encountered in our daily lives and have made our lives easier. They provide great convenience particularly in data analysis, statistical optimisation, and decision-making processes. Similarly, they have been used in medical field for data analysis and diagnosis of diseases. Diagnosis can be made and abnormal structures in the body can be detected with the help of medical imaging devices. The location and size of the mass in lung cancer can be easily determined by computed tomography. In addition to this, with the machine learning we used in the study, experts can diagnose and analyse the lesioned area in a very short time; hence reduce the possibility of an error. Among the hybrid working models we used, quantum core and quantum neural network models were trained on two different data sets

and tested, and measured with metrics of accuracy, precision, sensitivity, specificity and F1- scores. In addition, both models were trained with 5-Fold cross validation. The values obtained were compared according to the performance results of the quantum core and quantum neural network models. According to the results from both data sets, it has been concluded that the quantum kernel method is more useful for this study. For this reason, this study is aimed to be a source that will guide different studies that will be done on computed tomography images in lung cancer with machine learning methods.

**Keywords:** Quantum Machine Learning, Quantum Computing, Machine Learning, Hybrid Machine Learning, Lung Cancer.

# İÇİNDEKİLER

	Sayfa No
JÜRİ ONAY SAYFASI.....	İ
ETİK BEYAN.....	İi
TEŞEKKÜR.....	İii
ÖZET .....	İv
ABSTRACT .....	V
İÇİNDEKİLER .....	Vi
SİMGELER ve KISALTMALAR.....	İx
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	Xi
BİRİNCİ BÖLÜM	
GİRİŞ	1
İKİNCİ BÖLÜM	
KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR	3
2.1. Bilgisayarlı Tomografi (BT).....	3
2.2. Kuantum Bilgisayarlar.....	3
2.2.1. Süperpozisyon.....	6
2.2.2. Dolanıklık.....	6
2.2.3. Bloch Küresi.....	7

2.2.4. Kuantum Mantık Kapıları.....	7
2.3. Makine Öğrenmesi.....	16
2.3.1. Denetimli Öğrenme (Supervised Learning).....	18
2.3.2. Denetimsiz Öğrenme (Unsupervised Learning).....	18
2.3.3. Pekiştiricili Öğrenme (Reinforcement Learning).....	21
2.4. Kuantum Makine Öğrenmesi.....	21
2.4.1. Kuantum Bilgisayarlarda Kullanılan Bazı Algoritmalar.....	22
2.4.2. Kuantum Bilgisayarlara Uyarlanan Algoritmalar.....	23
2.4.3. Hibrit Makine Öğrenmesi.....	23

### ÜÇÜNCÜ BÖLÜM

#### ARAŞTIRMA YÖNTEMİ/MATERYAL YÖNTEM

3.1. Hibrit (Kuantum-Klasik) Makine Öğrenmesi ile Akciğer Kanseri Hastalarda Bilgisayarlı Tomografi Görüntüleri Analizi.....	27
3.1.1. Veri Kümesi.....	28
3.1.2. Kuantum Çekirdek Metot.....	31
3.1.3. Kuantum Simülatörler.....	33
3.1.4. Kuantum Transfer Öğrenme.....	34
3.1.5. Eğitim Prosedürü.....	35

### DÖRDÜNCÜ BÖLÜM

#### ARAŞTIRMA BULGULARI

### BEŞİNCİ BÖLÜM

#### SONUÇ ve ÖNERİLER

KAYNAKÇA .....	40
ÖZGEÇMİŞ .....	I

## SİMGELER VE KISALTMALAR

Kubit	Kuantum Biti
BT	Bilgisayarlı Tomografi
I	Birim Kapı
$\sigma_0$	Birim Kapı(I)
$\sigma_x$	Pauli X Kapısı
$\sigma_y$	Pauli Y Kapısı
$\sigma_z$	Pauli Z Kapısı
H	Hadamard Kapısı
$P(\theta)$	Genel Faz Kapısı
CU	Genel Kontrollü Kapı
SWAP	Yerdeğiştirme
CCNOT	Toffoli
CZ	Kontrollü Z Kapısı
KFD <sup>-1</sup>	Ters Kuantum Fourier Dönüşümü
TP	Gerçek Pozitif
TN	Gerçek Negatif
FP	Yanlış Pozitif
FN	Yanlış Negatif

## TABLULAR DİZİNİ

<b>Tablo No</b>	<b>Tablo Adı</b>	<b>Sayfa No</b>
<b>Tablo 1</b>	Veri kümeleri üzerindeki 5-Fold için ortalama performans sonuçları.	38



## ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Bloch Küresi.	7
Şekil 2	X kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).	9
Şekil 3	Y kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).	10
Şekil 4	Z kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).	11
Şekil 5	Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi.	16
Şekil 6	Makine öğrenme aşamaları.	17
Şekil 7	Makine öğrenmesi türleri.	18
Şekil 8	İki boyutlu bir uzayda ayırıcı hiperdüzlemin sınıflar arasındaki konumlandırılması (Meyer, 2018)	19
Şekil 9	K-Means kümeleme (Petersen,2010).	20
Şekil 10	Temel bileşen analizi örneği (Harrington, 2012).	21
Şekil 11	Varyasyonel devre şeması (Schuld, 2018a).	24
Şekil 12	Kuantum sinir ağı yapısı (Beer,2020).	25
Şekil 13	Evrişimsel sinir ağı çalışma örneği (Arı, 2019).	26
Şekil 14	Akciğer segmantasyonu için ConvLSTM-U Net Mimarisi (Acar, 2021).	29
Şekil 15	a) Örnek BT görüntüleri, (b) Akciğer maskeleri, (c) İlgili akciğer bölgesi	30
Şekil 16	VGG16 ağ mimarisi (Simonyan, 2014; Wikimedia, 2021).	31
Şekil 17	Kuantum çekirdek devresi.	32
Şekil 18	Kuantum sinir ağı modeli.	33
Şekil 19	Aktarımlı Öğrenme Şeması (Mari, vd. , 2020).	35

# BİRİNCİ BÖLÜM

## GİRİŞ

İnsanlar bilgisayarlardan önce çeşitli matematiksel tekniklerle verileri analiz etmişlerdir. Yirminci yüzyıl ortalarından itibaren dijital bilgisayarlarla veri analizi otomasyon yöntemleri geliştirilmiştir. Son zamanlarda da bilgisayar teknolojisindeki gelinen noktayla çok daha karmaşık öğrenme yöntemleri ortaya çıkmıştır. Verilerin analizi ve önceki verilere bakarak çıkarımda bulunabilmek için yeni bir yöntem olarak makine öğrenmesi kullanılmaktadır. Makine öğrenmesi veri modelleri oluşturmak için algoritmaları kullanan ve tahminlerde bulunan bir yaklaşımdır. Robot teknolojileri, ses ve görüntü tanıma, otomatik araçlar ve tıpta teşhis gibi birçok alanda makine öğrenmesi modellemeleri kullanılmaktadır (Müller ve Guido, 2016).

Büyük verilerle çalışmamız gerektiğinde kritik noktaları belirleyebilmek ve geçmişteki yapılan çalışmalarla karşılaştırma yaparak karar verebilmek için otomatik sistem geliştirdiğinden makine öğrenmesi birçok alanda yaygın olarak kullanılmaya başlanmıştır. Farklı sektörlerdeki kullanımlar sayesinde zamandan ve maliyetten kazandırdığı görülmüştür (Gyongyosi ve Imre, 2019).

Günümüzde bilgi işlemede kullanılan makinelerin çalışma prensipleri klasik mekanikle açıklanabilir. Ancak klasik bilgisayarlarda kullanılan transistör sistemi gelebileceği en küçük duruma gelmesi ve boyut olarak çok küçülmesiyle, artık klasik mekaniğin yetersiz kaldığı elektron, atom, atom altı parçacıkların davranışlarını ölçebilen, temeli kuantum mekaniğine dayalı olan kuantum bilgisayar teknolojisini kullanma ihtiyacı doğmuştur. Kuantum bilgisayarlar ise klasik bilgisayarların yapmakta zorlandığı işlemleri çok daha kısa sürede yapabilecek teknolojideki en büyük gelişmelerden biridir.

Klasik ve kuantum bilgisayarlarda binary denilen ikili kod sistemi kullanılmaktadır. Klasik bilgisayarlarda 0 ve 1 olarak kodlanan klasik bilgisayarların en küçük parçası olan bitler ya sadece 0 ya da sadece 1 değerleriyle çalışmaktadır. Kuantum bilgisayarlarda ise hem 0 hem de 1'i aynı anda ya da bunlar arasındaki tüm olası durumları değerlendiren kubitler (kuantum biti) kullanılmaktadır. Kuantum bitler aynı anda birden fazla durumda olabileceği için birden fazla durumu aynı anda değerlendirebilmektedir. Klasik algoritmalara

göre de üstel ve kuadratik hızlanma sağlayan algoritmalar kullanıldığı için daha hızlı olacağı düşünülmektedir (Yetiş ,2021).

Makine öğrenmesinde işlenen veri ne kadar büyükse yani ne kadar çok veri varsa elde edilen modelin genelleme performansı o kadar yüksek olur. Verilerin büyük olması sadece hacimsel olarak değil, anlamlı ve işlenebilir şekilde olması gerekmektedir. Tıbbi görüntüleme verilerinde hasta gizliliği, veriye ulaşmadaki süreç çok zaman alacağından büyük veri kümelerine erişmek oldukça zordur. Bu sebeple tıbbi görüntüleme cihazlarından alınan verilerin oluşturduğu veri kümeleri diğer alanlara göre çok daha küçük boyutlu olmaktadır. Bu küçük boyutlu veri grupları için kuantum bilgisayarlarla makine öğrenmesi yapılabilmesi için çalışmalar yapılmaktadır.

Bu çalışma ile hibrit makine öğrenmesi yöntemlerinden kuantum çekirdek metot ve kuantum sinir ağı modellerini kullanarak, Pennylane kuantum simülatörü ile iki veri setindeki tomografi görüntüleri ile iki makine öğrenmesi modeli eğitilmiştir yüksek hassasiyetli makine öğrenmesi gerçekleştirebilmiştir. Elde edilen sonuçlara göre akciğer kanserinde Bilgisayarlı Tomografi (BT) görüntüleri üzerinde kuantum makine öğrenme yöntemleri ile yapılacak farklı çalışmalara yol gösterecek bir kaynak olması hedeflenilmiştir.



## İKİNCİ BÖLÜM

### KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR

#### 2.1. Bilgisayarlı Tomografi (BT)

BT, x-ışın tüpü ve detektör sisteminin hasta etrafında senkron bir şekilde dönerek görüntüleme yapabilen bir cihazdır. Temel anlamda hastaya yönlendirilmiş ışının incelenecek olan doku ve organların, kesitsel imajlarını elde eden bir görüntüleme sistemidir. Bu kesit kesit elde edilen görüntüler birleştirilerek üç boyutlu hasta görüntüsü oluşturulur. Kesitsel görüntüleme sayesinde süperpoze dediğimiz organ ve dokuların üst üste binmesi olayı engellenir. Ayrıca x-ışın kolimasyonu sayesinde ışının pertürbasyonu minimuma indirilir ve doku kontrast farkları daha da belirgin olması sağlanır. Yüksek kolimasyon ile incelenecek bölgeden geçen x-ışını, doku boyunca etkileştiği her bir noktanın doğrusal azaltma katsayılarının toplamı sonucu oluşur. Sonuç olarak elde edilen kesitsel imajlar bu azaltma katsayılarının toplamı ile elde edilir. Bilgisayara aktarılan verilen doğrusal azaltma katsayılarına göre bir skalaya dönüştürülür. Bu skala hounsfield unit olarak adlandırılır. Burada skala -1024 ile +3071 arasında değerler alır. Bu sayede her bir doku ve organın görüntüleri gri tonlarına göre bu skala ile yapılır (Durmuş, 2018).

#### 2.2. Kuantum Bilgisayarlar

Mevcut bilgisayar teknolojisi dev bir hesap makinesi gibi çalışan ve birçok elektrik devresinden oluşan bir sistemdir. Bu devrelerden elektrik geçip geçmemesiyle istenen bilgilerle, hesaplamalar yapılabilir. Klasik bilgisayarlar en basit elemanı olan milyonlarca transistörden meydana gelmiştir. Bu transistörler anahtar görevini görüp devreden akım geçip geçmemesiyle bilginin işlenmesini sağlarlar. Bu bilgiler 'bit' denilen 0 veya 1 kodlamasıyla oluşur. Bitlerin çeşitli kombinasyonlarıyla da daha karmaşık bilgiler oluşturulabilir.

Transistör teknolojisi limitlerinin en uç noktasına kadar gelmiş, boyutu her geçen yıl daha da küçülmüştür (Shalf, 2020; Theis ve Wong, 2017). Boyutlarındaki küçülme sebebiyle içindeki elektronlar artık kuantum etkisi göstermektedir (Powell, 2008). Bu durum yeni bir teknolojinin gelişiminin önünü açmıştır. Klasik bilgisayarlardaki transistör

teknolojisinin ulaşabileceği son nokta olması sebebiyle son zamanlarda teknolojiye çığır açan kuantum bilgisayarlar ortaya çıkmıştır (Preskill, 2018).

Klasik bilgisayarlarda da kuantum bilgisayarlarda da ikili kod dili kullanılmaktadır. Klasik bilgisayarlarda en küçük parçası olan 0 veya 1 değerleri ile çalışan bit kullanılırken, kuantum bilgisayarlarda 0,1 ve 0 ile 1 arasındaki tüm olası durumları değerlendiren kuantum bitler (kubit) kullanılmaktadır. Klasik bilgisayarlar tek seferde sadece bir bit işlem yapabilirken kuantum bilgisayarlardaki kubitler aynı anda birçok durumda olabileceği için birden fazla işlem aynı anda hesaplayabilmektedir. Kuantum bilgisayarların temeli kuantum mekaniğine dayalı olan, parçacığın kuantumsal durumunu dikkate alan çalışma prensibiyle çalışır. Bu yüzden kuantumun üstün özellikleri olan süperpozisyon ve dolanıklık gibi özelliklerinden yararlanılmak istenilmektedir. Kuantumsal durumlardan yararlanılarak çalışan sistem olduğu için çok daha karmaşık problemleri çok kısa sürede çözebilmektedir. Çarpanlara ayırmayı sağlayan Shor algoritması (Shor, 1994) ve ikinci dereceden hızlanmada etkili olan Grover arama algoritması (Grover, 1996) gibi kuantum algoritmalarının önerilmesiyle birlikte çok daha gelişmiş ve çok fazla alanda kullanılmaya başlanmıştır.

Kuantum bilgisayarların en küçük bilgi birimi kuantum bit (kubit) olarak adlandırılır. Kuantum bilginin temel birimi olan Dirac notasyonu ile gösterilen bir kubitlik bilgi aşağıdaki Hilbert Uzayının bazlarından oluşmaktadır.

$$|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad |1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (2.1)$$

Ortanormal sistemler oluşturan bu bazlar;

$$\left. \begin{aligned} \langle 0|0\rangle &= \langle 1|1\rangle = 1 \\ \langle 0|1\rangle &= \langle 1|0\rangle = 0 \end{aligned} \right\} \quad (2.2)$$

şeklinde gösterilir ve bir kubit 0, 1 ve 0 ve 1 arasındaki tüm olası durumları gösteren süperpozisyon durumunda olabilir. Böylece bir kubit aşağıdaki şekilde ifade edilmektedir;

$$|\psi\rangle = \lambda_1|0\rangle + \lambda_2|1\rangle = \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix} \quad (2.3)$$

$\lambda_1$  ve  $\lambda_2$ ,  $|\psi\rangle$ 'nin  $|0\rangle$  ve  $|1\rangle$  bazındaki olasılık genliğidir.

$$\left. \begin{aligned} \lambda_1, \lambda_2 \in \mathbb{C} \text{ ve } |\lambda_1|^2 + |\lambda_2|^2 = 1 \\ \lambda_1 \lambda_1^* = |\lambda_1|^2 \text{ ve} \\ \lambda_2 \lambda_2^* = |\lambda_2|^2, \end{aligned} \right\} \quad (2.4)$$

$|\psi\rangle$ 'nin  $|0\rangle$  ve  $|1\rangle$  bazındaki ölçülme olasılıkları olarak adlandırılırlar.

Kubit, ölçüm durumuna getirildiğinde  $|0\rangle$  veya  $|1\rangle$  durumunda olur. Ölçüm yapıldığında sonuç hep  $|0\rangle$  veya  $|1\rangle$  durumunda olur ve sonra sırasıyla 0 ve 1 bit değeri olarak okunabilir.

Kubitin birden fazla olduğu durumlar tensörel çarpım ile ifade edilebilir. Bu sebeple,

$$\left. \begin{aligned} |\psi_1\rangle = \lambda_1|0\rangle + \lambda_2|1\rangle, \lambda_1, \lambda_2 \in \mathbb{C}, |\lambda_1|^2 + |\lambda_2|^2 = 1 \\ |\psi_2\rangle = \lambda_3|0\rangle + \lambda_4|1\rangle, \lambda_3, \lambda_4 \in \mathbb{C}, |\lambda_3|^2 + |\lambda_4|^2 = 1 \end{aligned} \right\} \quad (2.5)$$

olan  $|\psi_1\rangle$  ve  $|\psi_2\rangle$  bir kubitlik kuantum durumları da dahil olmak üzere iki kubitlik kuantum durumu,

$$\left. \begin{aligned} |\psi\rangle^{\otimes 2} &= |\psi_1\rangle \otimes |\psi_2\rangle = (\lambda_1|0\rangle + \lambda_2|1\rangle) \otimes (\lambda_3|0\rangle + \lambda_4|1\rangle) \\ &= \lambda_1|0\rangle \otimes \lambda_3|0\rangle + \lambda_1|0\rangle \otimes \lambda_4|1\rangle + \lambda_2|1\rangle \otimes \lambda_3|0\rangle + \lambda_2|1\rangle \otimes \lambda_4|1\rangle \\ &= \lambda_1\lambda_3|00\rangle + \lambda_1\lambda_4|01\rangle + \lambda_2\lambda_3|10\rangle + \lambda_2\lambda_4|11\rangle \end{aligned} \right\} \quad (2.6)$$

şeklinde ifade edilir.

Burada

$$|\lambda_1\lambda_3|^2 + |\lambda_1\lambda_4|^2 + |\lambda_2\lambda_3|^2 + |\lambda_2\lambda_4|^2 = 1 \quad (2.7)$$

dir. Yine aynı şekilde n- kubitlik kuantum durum için,

$$|\psi\rangle^{\otimes n} = |\psi_1\rangle \otimes |\psi_2\rangle \otimes \dots \otimes |\psi_n\rangle = \lambda_1|00\dots 0\rangle + \lambda_2|00\dots 1\rangle + \dots + \lambda_n|11\dots 1\rangle \quad (2.8)$$

olur. Burada  $\lambda_1, \lambda_2, \dots, \lambda_n \in \mathbb{C}$  ve

$$|\lambda_1|^2 + |\lambda_2|^2 + \dots + |\lambda_n|^2 = 1 \quad (2.9)$$

olur.

Yukarıdaki denklemlerde (Sutor, 2019; Hidary, 2019; Nielsen ve Chuang 2010; Marinescu, 2011) çalışmalarında yer alan kuantum hesaplamasının temel özellikleri verilmiştir.

### 2.2.1. Süperpozisyon

Kuantum süperpozisyon, kuantum mekaniğinin temel ilkelerindedir. İki veya daha farklı durumdaki verinin bir araya getirilip tek bir işleme dönüştürülmesi olarak ifade edilebilir. Klasik bilgisayarlarda 0 ve 1 bitlerinin tek bir tanesinin kullanılmasına rağmen kuantum bilgisayarlar süperpozisyon ilkesinden yararlanarak 0 ve 1 ve bunların arasındaki tüm durumlar değerlendirir. Yani aynı durumdaki bir kubit için çok sayıda ölçüm yapıldığında her zaman aynı sonuç alınamaz. Süperpozisyon durumu n kubitlik kuantum sisteminin aynı anda  $2^n$  farklı durumu temsil etmesine izin verebilir.


### 2.2.2. Dolanıklık

Kuantum dolanıklılık, kuantum bilgisayarların bir diğer fenomen özelliğidir. Dolanıklık, iki farklı kuantum durumun bazı özellikleri ilişkili ise ve bu ilişki sonsuz uzaklıkta dahi geçerli ise iki durum birbirine dolanık denir. İki kuantum durumun aralarındaki mesafeye bakılmaksızın bazı özellikleri birbirleriyle ilişkili ise bu iki kuantum durum birbirine dolanık hale gelebilir ve herhangi birinde yaşanan değişime diğeri tepki verebilir. Bu da bilgi transferinin hızını arttırdığı ve hesaplama süresini kısalttığı için

kuantum bilgisayarların üstün hale gelmesini sağlar. İki sistem dolanıksa kuantum bilginin durumu ışınlanabilir (Bennett, 1993: vd.). İki kubitin dolanık olduğu durumda kubitler hakkında bilgiler her parçacıkta değil iki kubitin korelasyonu ile sağlanabilir (Gisin, 2014).

### 2.2.3. Bloch Küresi

Bloch küresi, iki seviyeli bir kubit durumunu temsil etmek için kullanılmaktadır. Burada  $|0\rangle$  ve  $|1\rangle$  kuantum bitleri temsil ederler sırasıyla kuzey kutbunda ve güney kutbunda yer alırlar. Olası kuantum durumlarında herhangi bir kubitin durumu  $\theta$  ve  $\phi$  açılarını belirleyerek kürenin yüzeyindeki noktalarla temsil edilir ve bu yüzden kuantum durumlar çok daha fazla bilgi barındırabilir. Kubitte ölçüm yapıldığında hangi kutba daha yakınsa o kutba çökmesi beklenir. Şekil 1’de de verilen açılar bu olasılığı belirlemektedir. Ayrıca kürede vektörün yönü gösteriliyorsa her iki kutba da çökme olasılığı eşittir.



Şekil 1. Bloch Küresi.

### 2.2.4. Kuantum Mantık Kapıları

Kuantum bilgisayarlarda kubitler üzerinde işlem yapabilmek için kuantum kapılardan yararlanır.

Tek kubitte uygulanabilen kapılar olabildiği gibi birden çok kubitte etki eden kapılar da bulunabilmektedir. Kuantum bilgisayarlardaki hesaplamayla bütün değerler için paralel

işlem yapılır çünkü girişler süperpozisyon durumunda verilir. Çıkan sonuçlar olasılıksal olarak hesaplanır (Yetiş, 2021).

### 2.2.4.1. Bir Kubite Etki Eden Kapılar

#### Pauli Kapıları (I, X, Y, Z)

Dört Pauli Matrisi ( $\sigma_0 \sigma_x \sigma_y \sigma_z$ ) ve tek bir kubit üzerinde hareket eden Pauli Kapıları Birim Kapı(I), Pauli X, Pauli Y ve Pauli Z kapılarından oluşmaktadır. X, Y ve Z kapılarının Bloch Küresinin x,y,z eksenleri etrafındaki bir dönüşü  $\pi$  radyan kadardır.

#### Birim Kapı (I ( $\sigma_0$ ))

Kimlik operatörü olarak da tanımlanan birim kapı, tek bir kubit için şu şekilde tanımlanır:

$$I = |0\rangle\langle 0| + |1\rangle\langle 1|. \quad (2.10)$$

Ayrıca matris olarak gösterimi:

$$I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \text{ dir.} \quad (2.11)$$

$$I |0\rangle = |0\rangle, \quad I |1\rangle = |1\rangle, \quad (2.12)$$

$|0\rangle$  ve  $|1\rangle$  temel durumlara etkisi bu şekilde olur.

#### Pauli X Kapısı ( $\sigma_x$ )

Bu kapı Pauli X operatörü olarak da adlandırılır. Klasik bilgisayardaki değil kapısının (not gate) kapısının kuantum bilgisayarlarda kullanılan halidir yani girişi tersine döndürmeye yarayan kapıdır. X kapısının matrisi şu şekilde tanımlanır:


$$X = \sigma_x = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}. \quad (2.13)$$

X kapısının  $|0\rangle$  ve  $|1\rangle$  temel durumlarına etkisi şu şekildedir:

$$X|0\rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} = |1\rangle \quad (2.14)$$

$$X|1\rangle = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} = |0\rangle \quad (2.15)$$

X kapısı Bloch küresi üzerinde Şekil 2’de de görüldüğü gibi x eksenini etrafında  $\pi$  kadar döndürür.  $|0\rangle$  ve  $|1\rangle$  durumlarının ölçülme olasılıkları ise tam ters olur.



Şekil 2.X kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).

### Pauli Y kapısı ( $\sigma_y$ )

Pauli X kapısına benzer bu kapı da Pauli X kapısı gibi küre üzerinde döndürme işlemi yapmaktadır. Fakat y eksenini üzerinde döndürme işlemi yapılır. Pauli Y kapısı matrisi:

$$Y = \sigma_y = \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix} \quad (2.16)$$


şeklinde tanımlanır.

Y kapısının  $|0\rangle$  ve  $|1\rangle$  temel durumlarına etkisi;

$$\left. \begin{aligned} Y|0\rangle &= i|1\rangle \\ Y|1\rangle &= -i|0\rangle \end{aligned} \right\} \quad (2.17)$$

şeklinde olur.

Bu kapı uygulandığında kuantum durumun durumu ve fazı değişmektedir. Şekil 3’de de görüldüğü gibi Bloch Küresi üzerindeki etkisi ise y eksenini etrafında kubit  $\pi$  kadar döndürmesi şeklindedir.



Şekil 3.Y kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).

### Pauli Z kapısı ( $\sigma_z$ )

Faz çevirme kapısı, işaret kapısı ya da Pauli Z operatörü olarak da adlandırılır. Pauli Z kapısının matris gösterimi ise:

$$Z = \sigma_z = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad (2.18)$$

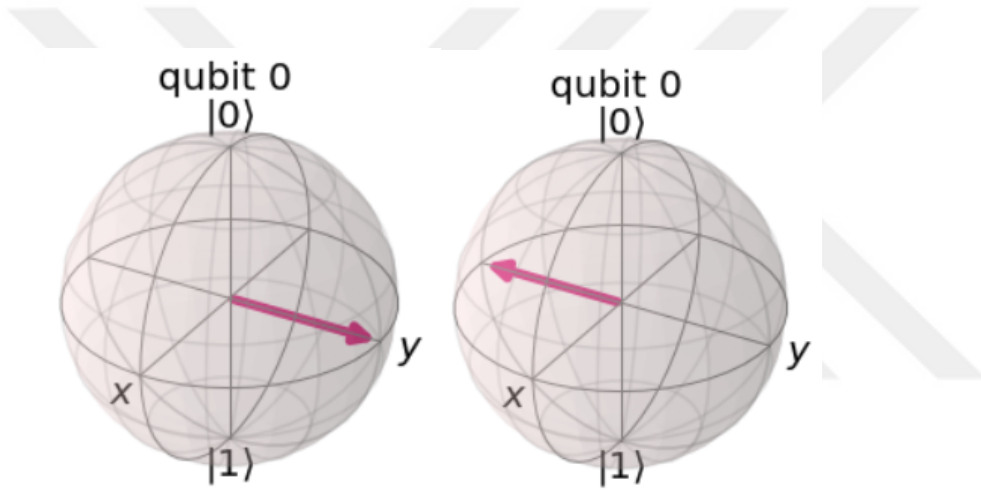
şeklindedir.



Z kapısının  $|0\rangle$  ve  $|1\rangle$  temel durumlarına etkisi:

$$\left. \begin{array}{l} Z|0\rangle = |0\rangle \\ Z|1\rangle = -|1\rangle. \end{array} \right\} \quad (2.19)$$

Şekil 4’de görüldüğü gibi Bloch Küresi üzerindeki etkisi ise z eksenini etrafında  $\pi$  kadar döndürmesi şeklindedir.  $|0\rangle$  ve  $|1\rangle$  durumlarının Z kapısı uygulandıktan sonraki olasılıkları değişmemektedir.



Şekil 4. Z kapısının Bloch Küresi üzerindeki gösterimleri (Qiskit, 2021).

### Genel Faz Kapısı (P( $\theta$ ))

Faz kapısı ile kubitin farklı faz durumları oluşturulabilmektedir. Genel faz kapısı matris gösterimi şu şekilde olur:

$$P(\theta) = \begin{bmatrix} 1 & 0 \\ 0 & e^{i\theta} \end{bmatrix} = |0\rangle\langle 0| + e^{i\theta}|1\rangle\langle 1|. \quad (2.20)$$

Burada  $\theta = \pi$  iken Z,  $\theta = \frac{\pi}{2}$  iken S ve  $\theta = \frac{\pi}{4}$  iken T kapısına karşılık gelir. P( $\theta$ ) kapısının  $|0\rangle$  ve  $|1\rangle$  temel durumlarına etkisi aşağıdaki gibidir:

$$\left. \begin{aligned} P(\theta)|0\rangle &= |0\rangle, \\ P(\theta)|1\rangle &= e^{i\theta}|1\rangle \end{aligned} \right\} \quad (2.21)$$

### Hadamard Kapısı (H)

Bu kapının en önemli özelliği işleme giren bir kubit eşit genlikli süperpozisyon durumuna getirmektedir. Klasik bilgisayarlarda karşılığı olmayan Hadamard kapısı aşağıdaki gibi tanımlanır:

$$H = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} = \frac{1}{\sqrt{2}} (|0\rangle\langle 0| + |0\rangle\langle 1| + |1\rangle\langle 0| - |1\rangle\langle 1|). \quad (2.22)$$

Hadamard kapısının  $|0\rangle$  ve  $|1\rangle$  temel durumlarına etkisi aşağıdaki gibidir:

$$H|0\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}} \quad (2.23)$$

$$H|1\rangle = \frac{|0\rangle - |1\rangle}{\sqrt{2}} = |-\rangle \quad (2.24)$$

Aynı zamanda Hadamard Kapısı aşağıdaki dönüşümleri de yapar:

$$H|0\rangle = |+\rangle \quad (2.25)$$

$$H|1\rangle = |-\rangle \quad (2.26)$$

### S Kapısı( Clifford Kapısı)

Kubit değerini z ekseninde  $\frac{\pi}{2}$  derece döndürmek için kullanılır. X ve y eksenleri arasında bilgi taşır.

## T Kapısı

Kubit değerini z ekseninde  $\frac{\pi}{4}$  derece döndürmek için kullanılır. Hataya dayanıklı bir kapıdır. Ölçeklendirilmiş kuantum bilgisayarlarla T kapısına kadar işlem gerçekleştirilebilir.

## Döndürme Kapıları

Bir kubit durumunu Bloch küresi üzerinde x, y ve z eksenleri etrafında  $\theta$  açısı kadar döndürmek için kullanılır.  $R_X$ ,  $R_Y$  ve  $R_Z$  döndürme kapıları aşağıda verilmiştir:

$$R_X(\theta) = \begin{bmatrix} \cos\left(\frac{\theta}{2}\right) & -i \sin\left(\frac{\theta}{2}\right) \\ -i \sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{bmatrix} \quad (2.27)$$

$$R_Y(\theta) = \begin{bmatrix} \cos\left(\frac{\theta}{2}\right) & -\sin\left(\frac{\theta}{2}\right) \\ \sin\left(\frac{\theta}{2}\right) & \cos\left(\frac{\theta}{2}\right) \end{bmatrix} \quad (2.28)$$

$$R_Z(\theta) = \begin{bmatrix} e^{-i\frac{\theta}{2}} & 0 \\ 0 & e^{i\frac{\theta}{2}} \end{bmatrix} \quad (2.29)$$

### 2.2.4.2. İki Kubite Etki Eden Kapılar

#### CNOT Kapısı

İki kubite etki eden kapılardan olan CNOT kapısı, kontrollü X kapısı olarak da adlandırılmaktadır. Bir kontrol ve bir hedef kubitten oluşmaktadır. Eğer kontrol kubiti  $|0\rangle$  ise hedef kubitinde değişiklik olmaz. Kontrol kubiti  $|1\rangle$  ise hedef kubite Pauli X kapısı uygulanır. CNOT kapısı aşağıdaki gibi tanımlanır:

$$\text{CNOT} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (2.30)$$

CNOT kapısının  $|00\rangle$ ,  $|01\rangle$ ,  $|10\rangle$  ve  $|11\rangle$  durumlarına etkisi,

$$\begin{aligned} \text{CX}|00\rangle &= |00\rangle \\ \text{CX}|01\rangle &= |01\rangle \\ \text{CX}|10\rangle &= |11\rangle \\ \text{CX}|11\rangle &= |10\rangle \end{aligned} \quad (2.31)$$

şeklindedir.

### Genel Kontrollü Kapı (CU)

U'nun tek kubitte etki eden birimsel bir kapı olduğu durumda, bir kubitin durumu başka bir kubitin durumuna bağlı ise, bu kapılara kontrollü kapılar denilmektedir ve Genel Kontrollü Kapı CU simgesiyle gösterilir. Burada U yerine X kapısı konularak CNOT kapısı veya Z kapısı konularak CZ kapısı elde edilir:

$$U = \begin{bmatrix} u_{00} & u_{01} \\ u_{10} & u_{11} \end{bmatrix} \quad (2.32)$$

$$\text{CU} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & u_{00} & u_{01} \\ 0 & 0 & u_{10} & u_{11} \end{bmatrix} \quad (2.33)$$

### Yerdeğiştirme (Swap) Kapısı

Yerdeğiştirme kapısı kuantum durumunda iki kubitin yerini değiştirmekte de kullanılır. Yerdeğiştirme kapısının matris gösterimi:

$$Swap = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.34)$$

İki kubitlik bir kuantum durumuna uygulanması sonucunda aşağıdaki durum

$$Swap|ab\rangle = |ba\rangle \quad (2.35)$$

elde edilir.

### 2.2.4.3. Üç Kubite Etki Eden Kapılar

#### Toffoli (CCNOT) Kapısı

Bu 3 kubite etki eden bir kapıdır. Bu kapı ilk iki kubit  $|11\rangle$  durumunda ise üçüncü kubite Pauli X kapısı etkisi gösterir. Bu kapı:

$$CCNOT = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.36)$$

şeklinde tanımlanır.

#### Fredkin Kapısı

Bu kapı 3 kubite etki eden bir kapıdır ve kontrollü- yerdeğiştirme kapısı olarak da bilinir. İlk kubit  $|1\rangle$  durumunda ise ikinci ve üçüncü kubitler üzerinde yerdeğiştirme kapısı etkisi gösterir. Bu kapı


$$Fredkin = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.37)$$

şeklinde tanımlanır.

Yukarıdaki kuantum kapılar (Liu, 2021) referansıyla hazırlanmıştır.

### 2.3. Makine Öğrenmesi

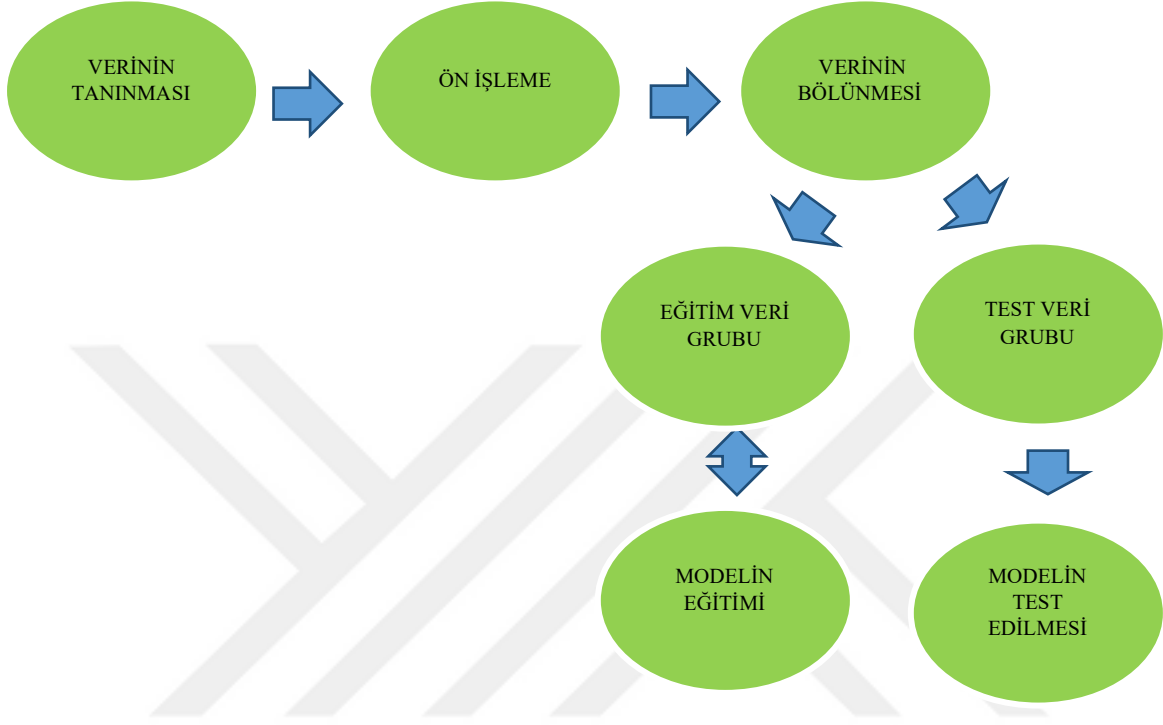
Bazı problemleri çözebilmek için ya da çözüm yöntemlerinde performans arttırmak için verilerden yararlanarak algoritmalar oluşturmaya yarayan bir araştırma alanıdır. Şekil 5’de gösterildiği gibi yapay zekanın bir parçası olarak da görülen Makine öğrenimi, örnek verilerden çözüm yolları sağlayan, tahminlerde bulunan bir modeldir. Makine öğrenimi geleneksel algoritmaların yeterli olmadığı durumlarda, e-posta filtreleme, bilgisayarla görme, konuşma, tanıma gibi çok çeşitli alanlarda kullanılmaktadır (Hu,2020).



Şekil 5. Yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisi.

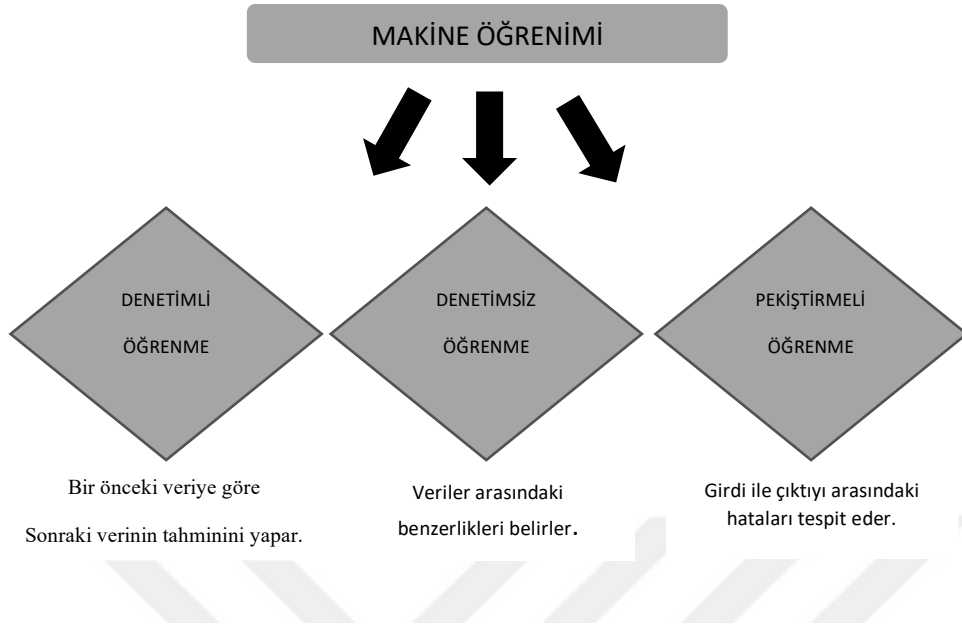
Makine öğrenmesinde işlem basamaklarına geçmeden öncelikle elimizdeki verinin analizi yapılır. Sonra Şekil 6’ da gösterildiği gibi verinin tanınmasından sonra ön işleme aşaması vardır. Burada veriler optimize edilerek makine öğrenmesine hazırlamak için bazı ön işleme metotları uygulanır. Daha sonra veriler belirli oranlarda Eğitim ve Test verisi

olarak ikiye bölünür. Sonraki aşama olarak verinin uyumlu olduğu bir model bulunur ve modele uygun olarak da verinin sınıflandırılması belirlenir. Son olarak bulunan modelin test edilip doğruluğunun kabul edilmesi gerekir.



Şekil 6. Makine öğrenme aşamaları.

Makine öğrenmesi 3 ana türde incelenir. Bunlar Şekil de görüldüğü gibi denetimli, denetimsiz ve pekiştirmeli öğrenmedir.



Şekil 7. Makine öğrenmesi türleri.

### 2.3.1. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenmede, önceden verilen girdi ve çıktılar kullanılır. Verilen girdi ile çıktılar kıyaslanarak öğrenme vardır. Denetimli makine öğrenmesi için her girdi için bir önceki girdi, çıktılar baz alındığı için geçmiş veriler arttıkça, algoritmaya girdi verildiğinde istenen çıktıyı verecek seviyeye gelir. Eğitilen her veriyi etiketlendiren bu öğrenme türünde bir denetmen gibi her veri grubu için algoritmaları denetlenir (Alpaydın, 2010).

### 2.3.2. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenmede ise çıktıdan bağımsız sadece girdi verileri dikkate alınır. Girdi değerleri birbirleriyle kıyaslayarak aralarındaki ilişki tespit edilir. Girdi değerlerinden birbirine yakın olan değerleri kümelene gibi çeşitli denetimsiz öğrenme türleri vardır.

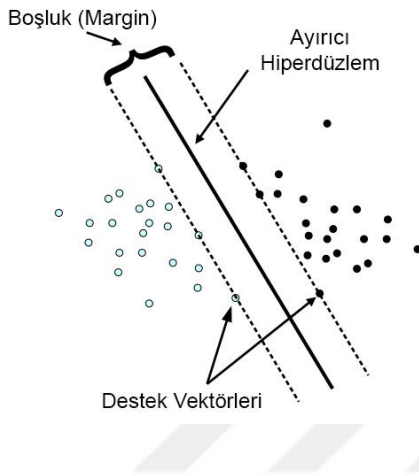
Denetimsiz öğrenmedeki en büyük problem algoritmanın yararlı mı yararsız mı olduğunu denetleyememesidir. Herhangi bir etiket içermez. Bir modelin başarılı olup olmadığını söylemek zordur (Müller ve Guido, 2016).

Denetimsiz makine öğrenme yöntemlerinden bazıları:



## Destek Vektör Makinesi

En sık kullanılan makine öğrenme tekniklerinden bir tanesi olan destek vektör makinesi, doğrusal ayrıştırma problemlerinde işlemleri kullanılmaktadır. Bu problemler de amaç, en iyi ayırım olan iki sınıf bölgesi için ve bundan sonra da yapılacak sınıflandırma işlemleri için karar sınırını görecektir bir hiperdüzlemi bulmaktır. Yani bu işlemle birlikte sınıfların birbirine minimum uzaklıktaki noktaları arasındaki sınırı en yüksek düzeyde olacak durumda gerçekleştirilmektedir (Şekil 8).



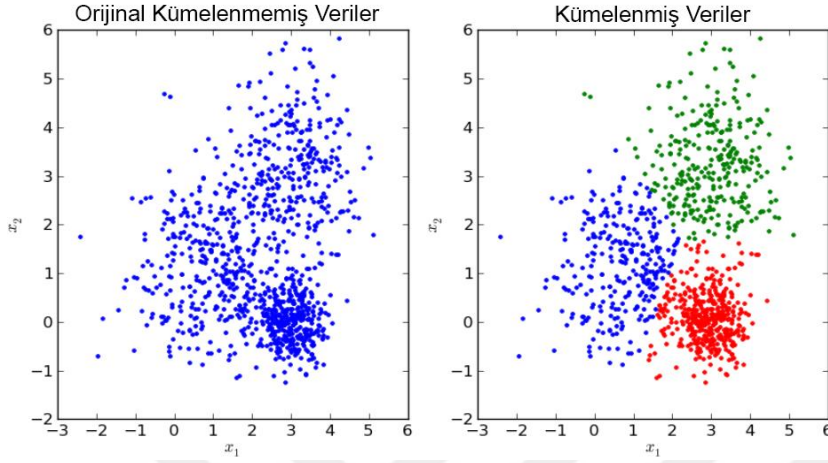
Şekil 8. İki boyutlu bir uzayda ayırıcı hiperdüzlemin sınıflar arasındaki konumlandırılması (Meyer, 2018).

Destek vektörleriyle sınıflar arasındaki en büyük ayrılma sınırı belirtilmektedir. Doğrusal ayrıştırma yöntemiyle işlem yapabilmek için, verilen problemin doğrusal olarak ayrıştırılabilir olması gerekmektedir. Destek vektörü yöntemi kullanılmak istenirse oluşturulabilen hiperdüzlem, iki sınıfın da bölgelerini birbirinden ayırması gerekir ve böylece ayrıştırılması mümkün görülmeyen problemlerin, boyutları arttırıldığında doğrusal olarak ayrıştırılabilecek şekilde haritalandırılabilir (Alpaydin, 2004).

## K-Means Kümeleme

K-means, birbirine yakın özelliklere sahip durumların aynı kümeye konulmasını sağlayan denetimsiz makine öğrenme algoritmalarından birisidir. Bu kümeleme algoritmasına K-means diye anılması, oluşturulan K farklı küme ve söz konusu kümedeki değerlerin ortalamalarının da o kümenin merkezini vermesinden dolayıdır (Dey, 2016).

K-means kümeleme algoritmasına örnekleri Şekil 9’da gösterilmiştir. Gösterilen şekillerin ilkinde henüz kümelanmemiş veriler temsil edilirken, ikinci şekilde ise K-means algoritması uygulandıktan sonraki kümelanmış verileri tanımlar.




Şekil 9. K-Means Kümeleme (Petersen, 2010).

### Temel Bileşen Analizi

Temel Bileşen Analizi hesaplamaları daha kolay ve hızlı olması için verilerin boyutunu azaltmayı sağlayan yaygın olarak kullanılan bir boyut azaltma yöntemidir. Verilerin durumuna göre oluşturulan yeni koordinat sistemi, temel bileşen analizinde veri kümesi koordinat sisteminin dönüştürülmesiyle oluşur. Tüm özellikler için tekrarlanan veri kümesi elemanları varyansın birçoğunun ilk birkaç ekseninde yer aldığı görülmektedir. Bu da akseler dışındakileri göz ardı edebileceğimiz anlamına gelir (Harrington, 2012).

Temel bileşen analiziyle uygulanan bir boyut azaltma örneği Şekil 10’da gösterilmektedir. Soldaki şekilde üç farklı sınıf, iki boyutta ifade edilmektedir. Sağdakinde ise bu verilere temel bileşen analizi uygulanmasıyla bir boyutta indirgenmesi gösterilmektedir. Bu boyut azaltma yöntemiyle sınıflandırmanın çok daha kolay bir şekilde yapılması hedeflenilmiştir.



Şekil 10. Temel bileşen analizi örneği(Harrington, 2012).

### 2.3.3. Pekiştiricili Öğrenme (Reinforcement Learning)

Amaç çıkış verilerinin önceki çıktılarla kıyaslanarak sonucun iyi ya da kötü olduğunun belirtilmesidir. Öğrenme sisteminin ajan olarak tanımlandığı pekiştiricili öğrenme yöntemi istediği gözlemi yapıp sonuçları seçip gerçekleştirir ve karşılığında ödül alır. Ajanın görevini iyi yapıp yapmadığını söyleyen dönüt ödülüdür. Bu sebeple buradaki amaç maksimum ödül veren durumu bulmaktır (Alpaydın, 2010).

### 2.4. Kuantum Makine Öğrenmesi

Kuantum makine öğrenimi, kuantum bilgisayarlar için makine öğreniminin nasıl kullanılacağını yani veri kümelerinden nasıl öğrenebileceğini araştıran, kuantum hesaplamaların bir alt alanı olarak geliştirilmiştir (Schuld,2018; Biamonte, 2017).

Kuantum hesaplamada makine öğrenimi üç farklı şekilde araştırılabilir:

- Kuantum ortamında öğrenme teorisini formülize eden temel yaklaşım (Arunachalam,2017; Ciliberto 2020),
- Hesaplama karmaşıklığından kurtulmak için kuantum algoritmaları bularak makine öğrenimini geliştiren yaklaşım (Lloyd,2014; Ciliberto2018),
- NISQ cihazları için hazırlanan makine öğrenimi uygulamaları kullanan yaklaşım (Perdomo-Ortiz,2018).

Kuantum makine öğrenmesi kuantum hesaplamaların gücünden yararlanarak bilgileri klasik hesaplamadan daha hızlı işler. Bu sayede geleneksel bilgisayarlarla elde edilemeyen

sonuçların elde edilmesi sağlanır. Kuantum makine öğrenmesi için amaç klasik bilgisayarlarla yapılabilen algoritmalarından çok daha fazla verim alınabilen kuantum makine algoritmaları oluşturmaktır. (Biomonte, 2017: vd.; Schuld, 2015: vd.; Phillipson, 2020). Kuantum makine öğrenmesinin klasik makine öğrenmesine göre üstünlük sağlayıp sağlayamadığını tespit etmek için araştırmalar devam etmektedir. (Schuld ve Petruccione, 2018).

Kuantum makine algoritmaları tasarlarken iki farklı strateji vardır. İlki, klasik makine öğrenme modellerini kuantum hesaplama diline çevirip algoritmik bir hızlanma elde etmeyi amaçlamaktır. İkincisi, hesaplama kaynaklarını düşük tutarak, klasik makine öğrenmesi araçları ile kuantum araçlarını bir araya getirerek hibrit bir yaklaşım benimsemektir. Sonuç olarak elde edilecek avantajlar kuantum makine öğrenmesini, disiplinler arası bir alandan ziyade kuantum bilişimin bir uygulaması haline getireceği öngörülmektedir (Buffoni ve Caruso, 2021; Schuld, 2015: vd).

#### **2.4.1. Kuantum Bilgisayarlarda Kullanılan Bazı Algoritmalar**

Klasik bilgisayarlar gibi kuantum bilgisayarlarda da algoritmalarla işlemler yapılır. Kuantum algoritmalar kubitler üzerinde bir dizi birimsel işlemlerle klasik bilgisayarlarda yapılamayacak işlemleri bile gerçekleştirebilir. Kullanılan bu kubitler klasik bilgisayarlarda olmayan kuantum hesaplamanın üstün özelliklerinden süperpozisyon ve dolanıklılık ilkeleriyle yapılabilir. Bu özellikler sayesinde kuantum algoritmalarla yapılan işlemlerin daha hızlı olması beklenirken çıktıda süperpozisyon dizilerinden bir tanesinin seçilmesi gerektiğinden ölçüm zor olmaktadır. Kuantum algoritmalarından bazıları: Deutsch Algoritması, Shor Algoritması ve Grove Algoritmasıdır.

##### **Deutsch Algoritması**

İlk kullanılan kuantum algoritmasıdır. Problemin nasıl çözüleceğinden ziyade nasıl hızlı çözülebileceğiyle ilgilenir. Yani Deutsch algoritması klasik bilgisayarlarda en az iki adımda çözülebilen problemi, tek adımda nasıl çözülebileceğini bulmaya çalışır. Tek kubit üzerinde işlem yapar ve kuantum hesaplamanın olağanüstü hızını kanıtlamaya yarayan bir algoritma olmasıyla bilinir. Daha sonra geliştirilen Deutsch-Jozsa algoritması da n sayıdaki kubitte etki edecek şekilde formülize edilen bir algoritmadır (Yetiş, 2021).

## **Shor Algoritması**

En önemli kuantum algoritmalarından olan Shor Algoritması 1994 yılında Peter Shor tarafından bulunmuştur ve bir pozitif  $N$  tam sayısının asal çarpanlarını bulmak için kullanılan bir algoritmadır. Çok büyük sayıları hesaplamak için kullanılan bu algoritma yerine klasik bilgisayarlarda hesaplamaların çok uzun zamanlar alacağı işlemleri çok kısa sürede yapmaktadır (Shor,1994).

## **Grover Algoritması**

Kuantum hesaplamalardaki uygulamaların temelini oluşturan kuantum hesaplama veri tabanından en uygun veriyi seçmek için arama yapmanın en optimum yoludur. Özellikle veri setinin çok büyük olduğu durumlarda kuantum ilkelerini kullanarak aranacak öğrenin bulunmasını çok kolaylaştıran ve hızlandıran bir yöntemdir. İlk olarak tüm durumlar süperpozisyona getirme, daha sonra aranan durumun genliği artırma ve işaretleme son olarak da ölçüm gerçekleştirme adımları olmak üzere üç adımda gerçekleşir (Grover,1997).

### **2.4.2. Kuantum Bilgisayarlara Uyarlanan Algoritmalar**

Yüksek makine öğrenmesi yöntemlerinin artması ve performans ihtiyacını karşılamak için mevcut bilgisayar teknolojisi bazen yetersiz kalabilmektedir. Bu yüzden kuantum hesaplamaların avantajlarından yararlanarak kullanılan yöntemlerin iyileştirilmesinin sağlayan kuantum uyarlamalı algoritmalar kullanılmaya başlamıştır. Tamamen kuantum teknolojisiyle makine öğrenmesi kullanılması için kuantum bilgisayarların kapı doğruluğu, kubit olarak geliştirilmesi, kaynak gereksinimlerinin giderilmesi gerekmektedir (Yetiş, 2021). Swap Testi Algoritması, Genel Faz Tahmin algoritması kuantum bilgisayarlara uyarlanan algoritmalarından bazılarıdır.

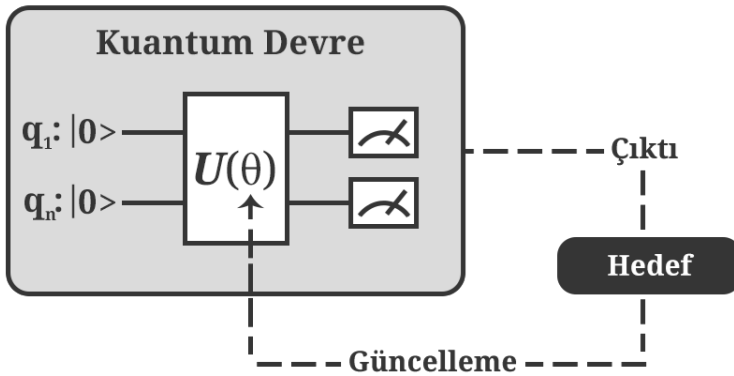
### **2.4.3. Hibrit Makine Öğrenmesi**

Klasik, kuantum makine öğrenimini birleştirerek daha yüksek verim almak için kuantum ve klasik algoritmaları birleştiren yöntemdir. Bu yöntemin çalışma prensibi kuantum işlemciyle gerçekleştirilen işlemlerle hem kuantum hem klasik işlemciyi bir arada kullanmaktır.

(Schuld ve Killoran, 2019) kuantum hesaplama ile özellik uzayları olarak Hilbert Uzayının kullanılmasını özellik eşleşmesi ve çekirdek yöntemi arasındaki bağlantıyı kurarak sınıflandırma problemleri için örtük ve açık olmak üzere iki hibrit klasik-kuantum teknik önermişlerdir. Açık yaklaşımdaki veriler özellik Hilbert uzayında doğrudan analiz edilebilirken örtük yaklaşımda kuantum bilgisayarları kullanılarak klasik olarak hesaplaması zor olan bir çekirdeğin hesabının yapılabilmesi için kuantum durumlarının iç çarpımı tahmin edilmeye çalışılır.

### Varyasyonel Kuantum Algoritması


Varyasyonel kuantum algoritması, klasik ve kuantum işlemcinin bir arada kullanıldığı, bir hedefi ha da bir maliyet fonksiyonunu optimize etmeyi amaçlaya, geriye yayılım döngüsü olarak işlem yapılan bir yöntemdir. Bu amaçla kuantum işlemci birçok değişken parametreyi ya da parametrelendirilmiş kuantum kapılarının bir kuantum durumunu hazırlamak için kullanılır. Tekrar tekrar yapılan ölçümlerle hedef fonksiyon tahmin edilir. Tahmin edilen bu durum yeni parametreler için hazırlanan klasik optimizasyon algoritmasında girdi olarak belirlenir. Bu durum optimizasyon prosedürü yakınsayana veya bazı durdurma kriterleri yerine getirilene kadar tekrarlanır. Daha sonra maliyet veya amaç fonksiyonunun son tahmini çıktı olarak alınır. (Benedetti,2019: vd.; Cerezo 2021: vd.; Zhu, 2019: vd.). Gürültülü orta ölçekli kuantum bilgisayarlarda kullanılmak için ana aday haline gelebilmesi için bu algoritmaların hataya karşı daha duyarlı olması amaçlanmıştır. (Cerezo, 2021: vd.). Bu tür kuantum algoritmaların çalışma prensibi Şekil 11’de verilmiştir.



Şekil 11. Varyasyonel devre şeması (Schuld, 2018a).

## Kuantum Sinir Ağı

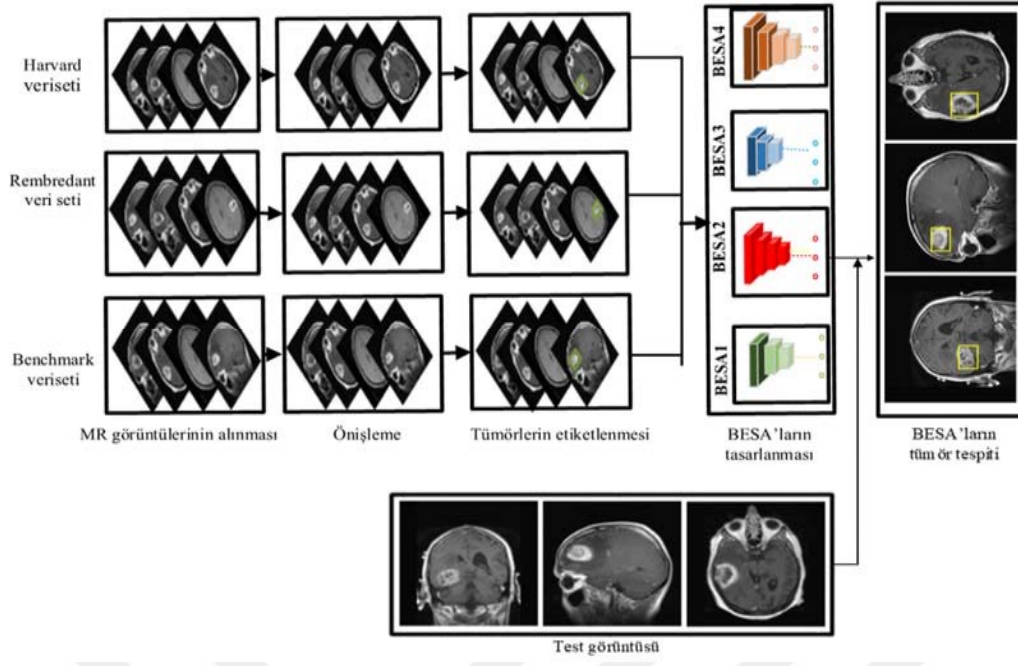
Bir diğer kuantum makine öğrenimi alanı olan ve çalışmamızda da kuantum çekirdek modellerle kıyasladığımız kuantum sinir ağı, klasik sinir ağlarını kuantum devreleriyle birleştirebilir. Verileri bir sonraki sinir katmanına ileten ve bunları parametrelendirilmiş kuantum katmanlarında inceleyen yapılar oluşturabilir. Kuantum öğrenme Şekil 12'deki kuantum sinir ağı modelinde gösterildiği gibi giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Mevcut durumda klasik algoritmalar hızlı olmamasına rağmen performansını arttırmak için çalışmalar devam etmektedir.



Şekil 12. Kuantum sinir ağı yapısı (Beer, 2020).

## Kuantum Evrişimsel Sinir Ağı

Kuantum Evrişimsel Sinir Ağı ise tıbbi görüntü analizi, görüntü sınıflandırma, tavsiye ve öneri sistemleri gibi uygulamalarda sıklıkla kullanılan bir tür klasik makine öğrenme modelidir. Bir dizi evrişim ve havuzlama katmanlarından oluşur. Bu katmanlardan evrişim katmanı, genellikle farklı boyutlarda olan filtrelerdir. Bu filtrelerle girdi verisi tanımlanır ve verideki en önemli özellik ortaya çıkarılır. Havuzlama katmanında parametre sayısı azaltılarak hesaplama yükü alınmış olur ve girdi alt örnekleme için kullanılır. Şekil 13'de MR görüntüleriyle evrişimsel sinir ağına dayalı bir tümör tespiti verilmiştir.



Şekil 13.Evrişimsel sinir ağı çalışma örneği (Arı, 2019).



## ÜÇÜNCÜ BÖLÜM

### ARAŞTIRMA YÖNTEMİ/MATERYAL VE YÖNTEM

#### **3.1. Hibrit (Kuantum- Klasik) Makine Öğrenmesi ile Akciğer Kanseri Hastalarda Bilgisayarlı Tomografi Görüntüleri Analizi**

Günümüzde verinin analiz edilmesi, sınıflandırılması, yorumlanması ve geçmiş çıktılara bakarak tahminde bulunarak işlemler yapmak çok önemli hale gelmiştir. Bunun için makine öğrenmesi de bir araç olarak kullanılmaktadır. Makine öğrenmesi, eldeki verilere dayanarak fonksiyonel olarak öğrenebilen ve veriler arasındaki ilişkileri bularak veriler üzerinden tahmin yapabilen algoritmik bir yaklaşımdır. Verilerin büyüklüğü ve boyutları arttıkça klasik bilgisayarlarda işlem yapmak çok uzun zaman almaktadır. Bu soruna çözüm bulmak adına yeni bir teknolojik gelişme olan temeli kuantum mekaniğine dayalı kuantum bilgisayarlar geliştirilmiştir (Acar, 2021).

Makine öğreniminin hassasiyetini arttırmak için çok sayıda veri gereklidir. Veri miktarı ve boyutu arttıkça önışlemede de geçen süre doğru orantılı olarak artacak ve buna paralel olarak algoritmanın çözüm üretme zamanı artacaktır. Her ne kadar çok çekirdekli, çok işlemcili ve grafik işlemcili bilgisayarlar ile hızlı hesaplamalar yapılsa bile bu işlemler klasik bilgisayarlarla çok uzun süreler alır (Deng, 2009).

Klasik ve kuantum bilgisayarların tek ortak yönü olan ikili kod dili kullanmalarıdır. Klasik bilgisayarlar, en küçük bilgi parçası bit denilen sadece 0 veya 1 değerleri ile çalışmaktadır. Klasik bilgisayarlar tek seferde sadece bir bit işlem yapabilirken kuantum bilgisayarlar da kuantum bitler (kubit), herhangi bir anda 0 ya da 1 olan klasik bitin aksine aynı anda hem 0 hem 1 ve bunların tüm olası durumunda işlem yapabilmektedir. Kubitler aynı anda birçok durumda olabileceği için birden fazla işin aynı anda hesabını da yapabilmektedirler (Simonyan, 2014).

Kuantum makine algoritmalarının iki temel hedefi vardır. Birincisi, klasik makine öğrenme modellerini kuantum hesaplama diline çevirip çok daha hızlı çözüm üretmeyi amaçlamaktır. İkincisi ise, hesaplama veri kaynaklarının az olduğu durumlarda, klasik makine öğrenmesi araçları ile kuantum araçlarını bir araya getirerek hibrit bir yaklaşım ile

çözüm üretmektir. Sonuç olarak kuantum makine öğrenmesi ile hızlı, daha az veri ile daha hassas çözümler üretebilen bir kuantum bilgisayar teknolojisi haline gelmesi öngörülmektedir (Abdi, 2010; Schuld 2019). Hibrit kuantum-klasik makine öğrenimi ile, daha yüksek performans elde etmek ve öğrenme maliyetini düşürmek için kuantum algoritmaları ile klasik algoritmaları birleştiren yöntemdir. Bu yöntemin ana fikri, kuantum işlemcide gerçekleştirilen minimum sayıda işlemle birlikte hem kuantum hem de klasik işlemciyi bir arada kullanmaktır (Deng,2009).

Bu çalışma ile, hibrit kuantum-klasik aktarımlı öğrenme yöntemini kullanarak kuantum simülatorlerden PennyLane simülatorüyle, akciğer kanserli hastaların Bilgisayarlı Tomografi (BT) görüntüleri eğitilmektedir. Hibrit kuantum-klasik makine öğrenimi, daha yüksek performans elde etmek ve öğrenme maliyetini düşürmek için kuantum algoritmaları ile klasik algoritmaları birleştiren yöntemdir.

### 3.1.1. Veri Kümesi

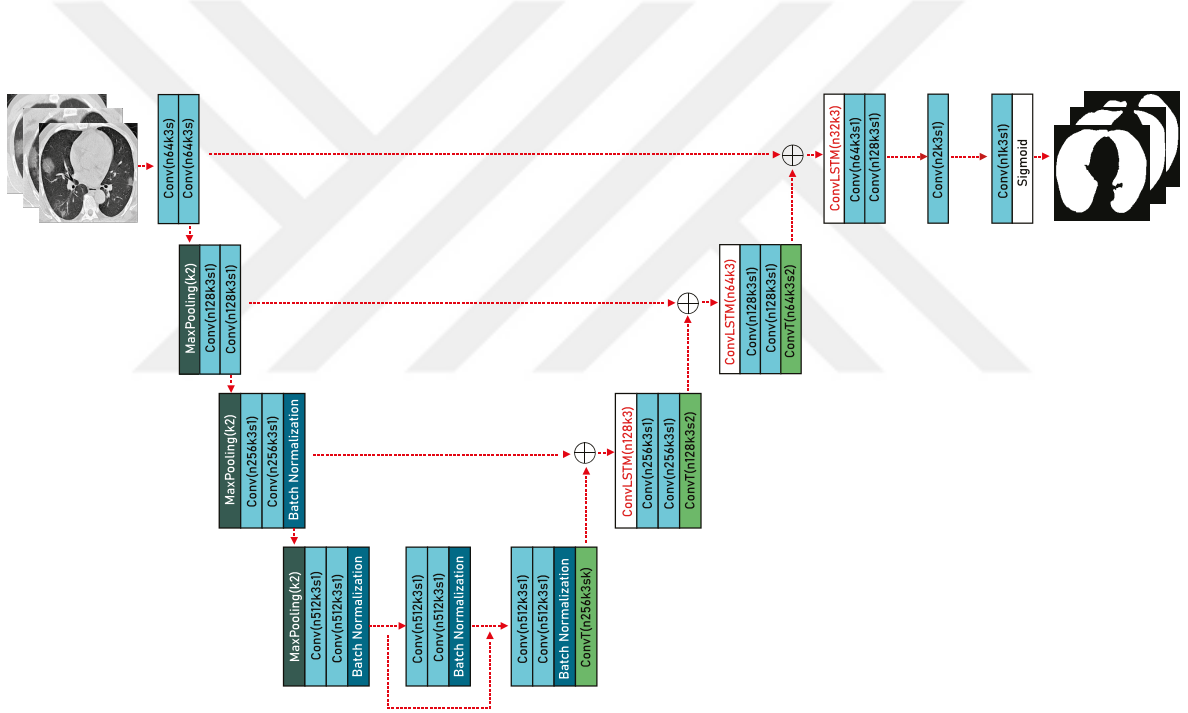
Bu çalışmada iki farklı veri kümesi kullanılmıştır. Detayları aşağıdaki gibidir:

- **Veri kümesi 1:** Akciğer adenokarsinom tanılı 58 hastanın BT görüntülerinden bir kesit aksiyel görüntü analiz için alındı. Veri kümesinde 32 lezyon içeren ve 26 normal akciğer dokusu olan BT aksiyel görüntüsü ile toplam 58 BT görüntüsü bulunmaktadır. Bu veri seti İstanbul Yeni Yüzyıl Üniversitesi Gaziosmanpaşa Hastanesi'nden izin alınarak elde edilmiştir.
- **Veri Kümesi 2:** Irak-Onkoloji Eğitim Hastanesi/Ulusal Kanser Hastalıkları Merkezi (IQ-OTH/NCCD) akciğer kanseri veri seti kullanılmıştır. Veri seti, 110 vakanın BT tarama dilimlerini temsil eden toplam 512 x 512 çözünürlüğe sahip 1190 görüntü içerir. Bu vakalar normal, iyi huylu ve kötü huylu olmak üzere üç sınıfa ayrılır. Bunlardan 40'ı kötü huylu, 15 vaka iyi huylu ve 55 vaka normal vakadır. Çalışmamız doğrultusunda iyi huylu ve kötü huylu sınıfları birleştiriyoruz. Böylece normal 461 ve kanserli 729 kanserli BT görüntüsü içeren veri kümesi elde edilir (Alyasriy, 2021).

## Önişleme:


Önişleme aşaması 6 aşamadan oluşmaktadır. Bunlar aşağıda verilmiştir;

1. Veri kümeleri farklı çözünürlüklere sahip olduğundan ve daha sonra uygulanacak segmentasyon ve özellik çıkarıcı önceden eğitilmiş evrişimli ağ için veri kümesindeki tüm görüntüler boyut olarak 224x224 piksele getirilir.
2. Bu çalışmada akciğer segmentasyonu için ortak yazarın önceki çalışmasında (Acar, 2021) kullandığı ConvLSTM-U Net mimarisi ile eğittikleri model kullanılmıştır. Bu model, 1606 BT görüntüsü ile eğitilmiş olup 0.9902 doğruluk elde etmişlerdir. Bu mimarinin şeması Şekil 14’de verilmiştir.



Şekil 14. Akciğer segmentasyonu için ConvLSTM-U Net mimarisi (Acar, 2021).

3. Örnek görüntüler, akciğer segmentasyonu sonucu elde edilen maske görüntüleri ve graphcut (Acar ve Şahin, 2021) görüntü işleme yöntemi sonucu elde edilen ilgili akciğer bölgesi Şekil 15’de verilmiştir.




Şekil 15. (a). Örnek BT görüntüleri. (b) Akciğer maskeleri. (c) İlgili akciğer bölgesi.

4. Tüm görüntülerin yoğunluk piksel değerleri  $[0,255]$ 'ten  $[0,1]$  yoğunluk aralığına min-maks normalleştirme ile normalize edilir:

$$\hat{x} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

burada  $\hat{x}$  yeni piksel yoğunluğu,  $x_{min}$  ve  $x_{max}$ , girdi görüntüsünün minimum ve maksimum yoğunluk değerleridir.

5. Çalışmada özellik çıkarıcı olarak Imagenet veri kümesi (Deng, 2009) üzerinde önceden eğitilmiş VGG16 evrişimli sinir ağı (Simonyan, 2014) kullanılmıştır. Bu ağdan tamamen bağlı katman kaldırılıp ağın geri kalan kısmı önceden eğitilmiş ağırlık parametreleri ile kullanılmıştır. Ağın son katmanında ortalama havuzlama (avg pooling) katmanı kullanılmıştır ve 512 boyutlu özellik vektörü elde edilmiştir. Ardından 512 boyutlu özellik vektörü temel bileşen analizi (PCA) (Abdi, 2010) kullanılarak 2 boyutlu özellik vektörüne indirgenmiştir. Şekil 16'da VGG16 mimarisi verilmiştir.



Şekil 16. VGG16 ağ mimarisi (Simonyan, 2014; Wikimedia, 2021).


#### 6. Daha sonra İki boyutlu özellik vektörü

$$z = \frac{(x-\mu)}{\sigma} \quad (3.2)$$

ile ortalamayı kaldırarak ve varyansa ölçeklendirerek özellikler standartlaştırıldı. Burada  $\mu$  eğitim örneklerinin ortalamasıdır ve  $\sigma$  eğitim örneklerinin standart sapmasıdır.

#### 3.1.2. Kuantum Çekirdek Metot

Schuld ve ark. tarafından klasik veri için özellik uzayları olarak kuantum Hilbert uzayının kullanılmasını önererek ve özellik eşlemesi ile çekirdek yöntemi ve kuantum hesaplama arasındaki bağlantıyı kurmuştur. Sınıflandırma problemi için önerdikleri iki yaklaşım bulunmaktadır. İlk yaklaşımda kuantum bilgisayarı kullanılarak, klasik olarak hesaplanması zor olan bir çekirdeği hesaplamak için kuantum durumlarının iç çarpımı tahmin edilmeye çalışılmaktadır. Bir çekirdek, girdi uzayında bir mesafe ölçüsüne karşılık gelmektedir. Makine öğreniminde çekirdek yöntemleri fikri, verileri daha yüksek boyutlu bir özellik uzayına gömerek analiz edilmesini daha kolay hale getirilir (Schuld 2019; Huang, 2021). Birçok durumda daha iyi veya en azından eşit derecede iyi sonuçlar elde edilebilmektedir (Havlicek, 2019; Liu, 2021). Bu çalışmada kullanılan 2 kubitlik kuantum çekirdek devresi Şekil 17’de verilmiştir.



Şekil 17. Kuantum çekirdek devresi.


Bir kuantum özellik uzayına kodlama işlemi

$$x \rightarrow |\vartheta(x)\rangle, |\vartheta(x)\rangle = U(X)|0^n\rangle \quad (3.3)$$

ile temsil edilir. Her bir  $K(x_i, x_j)$  çekirdek girişi,  $|0^n\rangle$  kubitleri üzerinde  $U^\dagger(x_j)U(x_i)$  devresi çalıştırılarak bir kuantum bilgisayar kullanılarak elde edilir ve ardından  $|0^n\rangle$  çıkışının frekansını sayarak  $|\langle 0^n | U^\dagger(x_j)U(x_i) | 0^n \rangle|^2$ 'i tahmin eder. Bu devrede  $U$  operatörü  $Rx$  döndürme kapılarından oluşmaktadır. Böylece 2 boyutlu özellik vektörünün bileşenleri  $Rx$  döndürme kapılarının açılarına gömülerek kuantum özellik uzayına kodlanmıştır. Ardından hesaplanan çekirdek, destek vektör makinesi algoritmasına beslenmiştir.

Kuantum sinir ağı modelinde ise verileri Hilbert uzayında analiz etmek için varyasyonel kuantum devresi kullanılmaktadır. Bu yöntem, kuantum ve klasik işlemcinin aynı anda kullanıldığı bir geriye yayılım döngüsü içinde gerçekleşmektedir. Genel amaç, bir hedef veya maliyet fonksiyonunu optimize etmektir. Bu yöntemi kullanan ve potansiyel kuantum faydaları için araştırılan bir başka alanı da kuantum sinir ağlarının geliştirilmesidir. Kuantum sinir ağları, tipik olarak klasik sinir ağlarını kuantum varyasyonel devreleriyle birleştirilmesidir. Verileri parametrelendirilmiş kuantum katmanlarında değerlendiren ve bir sonraki klasik sinir ağı katmanına ileten yapılar oluşturabilir. Bir sinir ağının ağırlıklarının eğitilmesiyle aynı şekilde, girdi verilerini değerlendirmek için kullanılan kuantum algoritmaları, esasen kuantum devresinin parametrelerini güncelleyerek yinelemeli olarak ayarlayabilir. Ardından, makine öğrenmesinde olduğu gibi, algoritma hedefe yeterince yakın bir cevaba yakınsayana kadar bu döngü tekrarlanır. Bu çalışmada kullanılan kuantum sinir ağı modelinde ki kuantum devresinde, ilk olarak tüm kubitler başlangıç durumunda  $|0\rangle$  ile

başlatılır. Ardından, Hadamard (H) kapılarından oluşan süperpozisyon katmanı kullanılır ve tüm kubitler süperpozisyon durumuna getirilir. Daha sonra,  $R_y(\alpha)$  döndürme kapılarından oluşan veri gömme katmanı ile özellik vektörünün iki özelliği  $R_y(\alpha)$  döndürme kapılarının  $\alpha$  açılara gömülerek özellik eşleme gerçekleştirilir. Kullanılan kuantum kapıları için (Michael, 2002)'ye başvurulabilir. Ardından eğitilebilir parametrelerin bulunduğu varyasyonel katman eklenir ve son olarak beklenen değer için ölçüm gerçekleştirilir. Elde edilen ölçüm sonuçları ReLu aktivasyon fonksiyonundan geçirilerek çıktı katmanına beslenir ve ardından tahmin sonucu elde edilir. Bu çalışmada kullanılan kuantum sinir ağı modeli Şekil 18'de verilmiştir.



Şekil 18. Kuantum sinir ağı modeli.

### 3.1.3. Kuantum Simülatörler

Bu bölümde çalışmamızda kullanılan Pennylane simülatörü ve bazı kuantum simülatörlerin kullanımlarına yer verilmiştir.

**Pennylane:** Kuantum bilgisayarlarda programlamayı sağlayan Python kütüphanesidir. Devrelerin gradyanlarını hesaplamak ve değerlendirmek gibi kuantum hesaplamaları yönetmeleri en önemli özelliklerindedir. Google Cirq ve IBM Qiskit gibi kuantum hesaplama simülatörlerine erişim olanağı sağlar. TensorFlow, Autograd, Pytorch, JAX gibi makine öğrenimi güçlü kitaplıklara erişimiyle hibrit optimizasyonu sağlar. Bu çalışmada da Pennylane simülatörleri kullanılmıştır (Bergholm,2020 vd.; Pennylane, 2021).

**Qiskit:** IBM Quantum Experience tarafından yazılım geliştirmek için kurulmuş bulut kuantum bilişim hizmetidir. (Magee, 2018; Hemsoth, 2018)

Kuantum bilgisayarlara devreler ve algoritmalarla çalışmayı sağlayan yazılım geliştirme kiti olarak tanımlanabilir. IBM Quantum Experience üzerinden kuantum

aygıtlarla veya klasik bilgisayarlardaki simülatörlerde çalıştırılan araçlarla kuantum programı oluşturup işleyebilir. Herhangi bir kuantum donanımı için kullanılabilen evrensel kuantum hesaplama sağlar. (IBM,2019)

**Cirq:** Bir Python kütüphanesi olan Cirq Google tarafından geliştirilmiştir ve kuantum algoritmalarını geliştirmeyi ve değiştirmeyi orta ölçekli gürültülü kuantum bilgisayarlar için tasarlanmıştır. Klasik bir bilgisayarla simülatör kullanarak kuantum programların yürütülmesini sağlar. (Cirq, 2020).

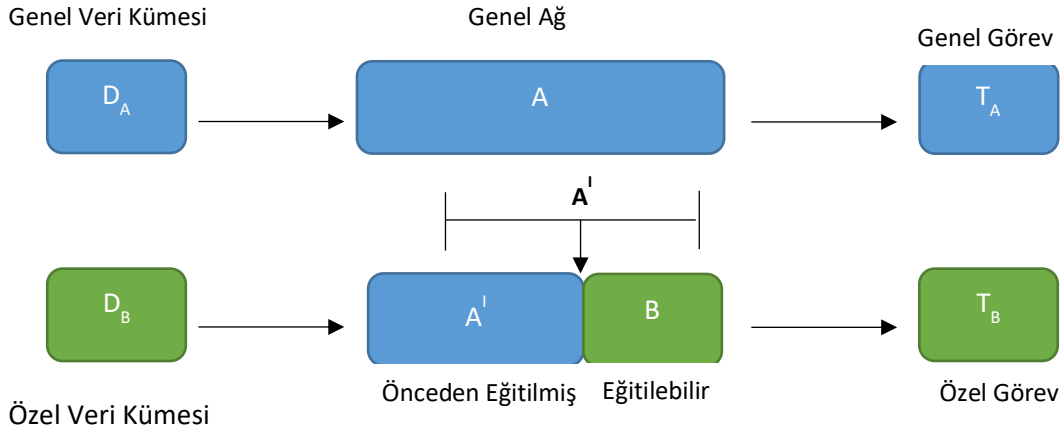
### 3.1.4. Kuantum Transfer Öğrenme

Kuantum transfer öğrenme yapay sinir ağlarını kullanarak az miktarda verinin olduğu problemleri çözmeye yarayan tekniktir. Belirli bir problemi çözmeyi başarmış eğitilmiş bir yapay sinir ağı, benzer veya farklı başka problemleri çözmek için de tekrar aynı yapay sinir ağı kullanılabilir. Önceden eğitilmiş derin sinir ağında, tam bağlı katman ağdan ayrılır. Özellik çıkarıcı olarak kullanılan bu ağın sonuna yeni bir ağ eklenir. Eklenen yeni ağ benzer ya da farklı problemi çözmek için yeniden eğitilir. (Mari, vd., 2020). Aktarımlı öğrenme şeması Şekil 19'da verilmiştir.

Bu çalışmada ResNet18 evrişimli sinir ağı kullanılmıştır. ResNet18, herhangi bir 224 x 224 boyutlu görüntüyü 512 boyutlu bir özellik vektörüne artık ağ yapısını kullanarak indirgeyebilir.

4 kubitlik bir varyasyonel kuantum devresiyle sınıflandırma yapabilmek için ResNet ağıyla elde edilen veri temsili, 4 nöronlu klasik sinir ağı katmanını 4 boyuta indirgemıştır. 4 boyutlu bir vektör olan varyasyonel kuantum devresinin çıktısı, problemimize göre 4 boyutlu vektör 2 klasik nörondan oluşan bir çıktı katmanıyla 2 boyuta indirilerek sınıflandırma gerçekleştirilmiştir.





Şekil 19. Aktarımlı Öğrenme Şeması (Mari, vd., 2020).

### 3.1.5. Eğitim Prosedürü

Klasik makine öğreniminde veri setinin %70-75'i sisteme öğretmek ve %20-25 ise test için kullanılırken, bizim çalışmamızda iki veri setinden toplam 461'i normal akciğer dokusu ve 729'u lezyonlu BT görüntüleri için kuantum çekirdek metot ve kuantum sinir ağı modelleriyle hibrit makine öğrenimi yapılarak sonuçlar karşılaştırılmıştır.

## DÖRDÜNCÜ BÖLÜM

### ARAŞTIRMA BULGULARI

Bu çalışmada gerçekleştirilen hibrit kuantum-klasik makine öğrenmesi modellerinden kuantum çekirdek ve kuantum sinir ağı modelinin performansı, doğruluk (*ing. accuracy*), kesinlik (*ing. precision*), duyarlılık (*ing. sensitivity*), özgüllük (*ing. specificity*) ve F1-puanı (*ing. F1-score*) metrikleriyle ölçülmüştür. Sınıflandırma modelinin performansını açıklamak için kullanılan karışıklık matrisi (*ing. confusion matrix*), gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatiflerden (FN) oluşur. TP, doğru tahmin edilen pozitif örnek sayısı olarak tanımlanır, FP yanlış tahmin edilen örnek sayısıdır, TN doğru tahmin edilen negatif örnek sayısıdır, FN yanlış tahmin edilen negatif örnek sayısıdır. Bu bağlamda doğruluk, kesinlik, duyarlılık özgüllük ve F1-skoru aşağıdaki şekilde tanımlanır (Acar 2021, vb.):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

$$Precision = \frac{TP}{TP + FP} \quad (4.2)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (4.3)$$

$$Specificity = \frac{TN}{TN + FN} \quad (4.4)$$

$$F1 - Score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity} \quad (4.5)$$

Her iki modelde de kuantum devresi Pennylane kuantum hesaplama simülatörü (Scholkopf, 1997) üzerinde yürütülmüştür. Kuantum sinir ağının eğitiminde optimizasyon algoritması olarak Adam stokastik gradyan (Kingma, 2014) algoritması kullanılmıştır. Başlangıçta 0.01 gibi büyük bir öğrenme oranı ile başlandı ve 3 eğitim periyodu için

validasyon hatasında azalma olmadığından dinamik olarak 0.1 faktörü ile düşürüldü ve minimum öğrenme oranı 0.00001 olarak ayarlandı. Eğitim periyot sayısı (epoch) 40 olarak alınmış ve hata fonksiyonu olarak binary cross entropy fonksiyonu kullanılmıştır. Ayrıca kuantum çekirdek ve kuantum sinir ağı modelleri her bir veri kümesi üzerinde 5-Fold çapraz doğrulama ile eğitilmiştir. Geri kalan veri kümesi üzerinde her fold için ayrı ayrı test edilmiştir. Elde edilen sonuçların ortalama değerleri karşılaştırmalı olarak Tablo 1’de verilmiştir.

*Tablo 1*

*Veri kümeleri üzerindeki 5-Fold için ortalama performans sonuçları.*

Methot	Dataset	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)	F1-Score (%)
Kuantum Çekirdek	Dataset1 (Training)	94,8	97,5	94,3	95,0	95,3
	Dataset2 (Test)	85,9	85,6	87,0	79,5	88
Kuantum Sinir Ağı	Dataset1 (Training)	98,3	1,0	96,6	1,0	98,1
	Dataset2 (Test)	70,8	76,3	74,4	65,9	74,2
Kuantum Çekirdek	Dataset1 (Test)	93,4	93,7	94,3	92,3	94,1
	Dataset2 (Training)	87,4	86,4	92,4	80,4	89,3
Kuantum Sinir Ağı	Dataset1 (Test)	87,3	89,1	89,1	85,0	88,9
	Dataset2 (Training)	88,1	89,4	91,3	82,9	89,9

Bu çalışmada gerçekleştirilen iki farklı hibrit kuantum-klasik makine öğrenmesi yöntemi iki farklı veri kümesi üzerinde eğitilerek ve test edilerek karşılaştırılmıştır. Veri kümesi 1 üzerinde eğitim sonucunda (veri sayısının az olduğu durum) her iki yöntem de performans sonuçları açısından birbirine yakın sonuç vermişlerdir. Ancak 2. veri kümesi üzerinde gerçekleştirilen test sonuçlarına göre kuantum çekirdek yönteminin daha yüksek sonuç verdiği görülmektedir. Veri kümesi 2 üzerinde eğitim sonucunda (veri sayısının çok olduğu durum) her iki yöntem yine birbirine göre yakın sonuç verdiği gözlemlenmiştir.

Ancak veri kümesi 1 üzerinde gerçekleştirilen test sonuçlarına göre kuantum çekirdek yönteminin performans kriterleri açısından daha yüksek sonuç verdiği gözlemlenmiştir. Buradan her iki veri kümesi üzerindeki sonuçlara göre kuantum çekirdek yönteminin daha iyi genelleme yaptığı sonucu çıkartılabilir.



## BEŞİNCİ BÖLÜM

### SONUÇ VE ÖNERİLER

Klasik bilgisayarlarda yapılmakta zorlanılan ya da çok vakit alan işlemleri son zamanların en üstün teknolojilerinden olan, IBM'in de bulut üzerinden hesaplamaya açtığı kuantum bilgisayarlarda, kuantum simülasyonlarla, hibrit (klasik-kuantum) modellerle olan hesaplamalarla daha az kaynak ve vakitle yapılabileceği görülmektedir. Çalışmamızda kullanılan hibrit modelde kullanılan iki metodun karşılaştırılmasıyla da görülmüştür ki klasik yöntemle göre kuantum performans üstünlüğü sağlanmıştır. Bu yüzden hibrit makine öğrenmesi süresi olarak verimsiz olmasına rağmen bizim kullandığımız tıp alanındaki kullanımının dışında birçok alanda umut vaat ettiği görülmektedir.

## KAYNAKÇA

- Abdi, H., & Williams, L. J. (2010). "Principal component analysis". Wileyinterdisciplinary reviews: computational statistics, 2(4), 433-459.
- Acar E. & Yılmaz I., (2021). "COVID-19 detection on IBM quantum computer with classical-quantum transferlearning". Turkish Journal of Electrical Engineering and Computer Sciences, 29 (1), 46-61.
- Acar E., Şahin, E., & Yılmaz I. (2021). "Improving effectiveness of different deep learning-based models for detecting COVID-19 from computed tomography (CT) images". Neural Computing and Applications, 33(24), 17589-17609.
- Alpaydın E., (2004). "Introduction To Machine Learning". MIT press. 197-229.
- Alpaydin, E., (2010). "Introduction to machine learning". MIT press. Massachusetts.
- Alyasriy, Hamdala and AL-Huseiny, Muayed , (2021). " The IQ-OTHNCCD lung cancer dataset" , Mendeley Data, V2, doi:10.17632/bhmdr45bh2.2.
- Arı A., Hanbay D. (2019). "Tumor detection in MR images of regional convolutional neural networks". Journal of the Faculty of Engineering and Architecture of Gazi University 34:3 1395-1408
- Arunachalam S and Ronald de W. (2017). "Guest column: A survey of quantum learning theory". *ACM SIGACT News* 48 41–67.
- Azad, R., Asadi-Aghbolaghi, M., Fathy, M. and Escalera, S. (2019). "Bi-directional ConvLSTM U-Net with densley connected convolutions". 2019 In Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops, 27-28 October 2019, Seoul, South Korea. 406-415
- Beer, K., Bondarenko D., Farrelly T., Oshore, J., Salzmänn, R. And Wolf R. (2020). "Training deep quantum neural networks". *Nat. Commun.*, vol. 11, no. 1, pp. 808.

- Benedetti, M., Lloyd, E., Sack, S. and Fiorentini, M. (2019). "Parameterized quantum circuits as machine learning models". *Quantum Science and Technology*, 4 (4), 043001.
- Bennett, C. H., Brassard, G., Crépeau, C., Jozsa, R., Peres, A. and Wootters, W. K. (1993). "Teleporting an unknown quantum state via dual classical and Einstein-Podolsky-Rosen channels". *Physical review letters*, 70 (13), 1895-1899.
- Bergholm, V., Izaac, J., Schuld, M., Gogolin, C., Alam, M. S. vd. (2018). "PennyLane: Automatic differentiation of hybrid quantum-classical computations". *arXiv preprint arXiv:1811.04968*.
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N. and Lloyd, S. (2017). "Quantum machine learning". *Nature*, 549 (7671), 195-202.
- Buffoni, L. and Caruso, F. (2021). "New trends in quantum machine learning". *Europhysics Letters*, 132 (6), 1-7.
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S. vd. (2021). "Variational quantum algorithms". *Nature Reviews Physics*, 3, 622-644.
- Ciliberto C., Herbster M, Ialongo A D., Pontil M., Rocchetto A., Severini S. and Wossnig L., 2018. "Quantum machine learning: a classical perspective *Proc*". *R. Soc. A* 474 20170551
- Ciliberto C, Rocchetto A, Rudi A and Wossnig L. (2020). "Fast quantum learning with statistical guarantees". *arXiv*: 2001.10477
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. and Fei-Fei, L. (2009). "Imagenet: A large scale hierarchical image database". *IEEE conference on computer vision and pattern recognition*, 20-25 June 2009, Miami, USA. 248-255.
- Dey A., (2016). "Machine Learning Algorithms". A Review. Department of CSE, IJCSIT, Vol. 7(3),1174-1179.

- Durmuş, İ.F. Tas B. (2018). “Evaluation of Electron Density and Hounsfield Unit Values for 4DCT, Normal CT and BreathHold CT in Lung SBRT Plan” *Acta Oncologica turcica* 51(3): (2018) 382-389
- extraction using iterated graph cuts. *ACM transactions on graphics*, 23 (3), 309-314. *for data scientists*. O'Reilly Media: USA.
- Garbin, C., Zhu, X. and Marques, O. (2020). “Dropout vs. batch normalization: an empirical study of their impact to deep learning”. *Multimedia Tools and Applications*, 79, 12777-12815.
- Gisin, N. (2014). “Quantum chance: nonlocality, teleportation and other quantum marvels”. Springer: Switzerland.
- Grover, L. K. (1996). “A fast quantum mechanical algorithm for database search”, In *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*, 22-24 May 1996, Philadelphia, USA. 212-219.
- Gyongyosi, L. and Imre, S. (2019). “A survey on quantum computing technology”. *Computer Science Review*, 31, 51-71.
- Harrington, P. (2012). “Machine learning in action”. Manning Publications Co: Shelter Island.
- Havlicek V., Corcoles A.D., Temme K., Harrow A.W., Kandala A., Chow J.M. & Gambetta J.M. (2019). “Supervised learning with quantum enhanced feature spaces”. *Nature*, 567 (7747), 209-212.
- Hemsoth, Nicole (Ağustos 7, 2018). “*Qiskit Developments Key to IBM Quantum Engagement*”. *The Next Platform*. Retrieved 11 December 2018.
- Hidary, J. D. (2019). “*Quantum computing: an applied approach*”. Springer: Switzerland.
- Hu, J.; Niu, H.; Carrasco, J.; Lennox, B.; Arvin, F., (2020). “Deep Reinforcement Learning



ile Bilinmeyen Ortamlarda Voronoi Tabanlı Çok Robotlu Otonom Keşif”. Araç Teknolojisinde IEEE İşlemleri.

IBM Quantum (2020, 15 Mayıs). Erişim adresi: <https://quantum-computing.ibm.com>.

*IBM Research Blog, 2019-11-05 "Qiskit - Write once, target multiple architectures". 2019-11-05.*

Kingma, D. P. and Ba, J. (2014). “Adam: A method for stochastic optimization”. arXiv preprint arXiv:1412.6980

Liu, J., Lim, K. H., Wood, K. L., Huang, W., Guo, C. and Huang, H. L. (2021). “Hybrid quantum-classical convolutional neural networks”. *Science China Physics, Mechanics & Astronomy*, 64 (9), 1-8.

Liu Y., Arunachalam S.& Temme K. (2021). “A rigorous and robust quantum speed-up in supervised machine learning”. *Nature Physics*, 17(9). 101

Lloyd S, Mohseni M. and Rebentrost P. (2014). “Quantum principal component analysis”. *Nat. Phys.* 10 631–3.

*Magee, Tamim (Aralık 11 2018). "What is Qiskit, IBM's open source quantum computing framework". Computerworld UK. Retrieved 11 Dece.*

Mari, A., Bromley, T. R., Izaac, J., Schuld, M. and Killoran, N. (2020). “Transfer learning in hybrid classical-quantum neural networks”. *Quantum*, 4, 340.

Marinescu, D. C. (2011). “*Classical and quantum information*”. Academic Press.

Meyer D., (2018). “Support Vector Machines: The Interface”. To libsvm In Package. 8p.

Morimae T., Takeuchi Y., Nishimura H. (2017). “Merlin-Arthur with efficient quantum Merlin and quantum supremacy for the second level of the Fourier hierarchy”. The open journal for quantum science, arXiv:1711.10605v3

Müller, A. C. and Guido, S. (2016). “Introduction to machine learning with Python: a guide

- for data scientists”. O'Reilly Media: USA.
- Nielsen, M. A. and Chuang, I. (2002). “Quantum computation and quantum information”. Cambridge University Press: New York.
- Oluyide O.M., Tapamo J.R., Viriri S., (2018). “Automatic lung segmentation based on Graph Cut using a distance- constrained energy”. *IET Computer Vision*: 12(5): 609-615. Doi: 10.1049/iet-cvi.2017.0226.
- Perdomo-Ortiz A, Benedetti M, Realpe-Gómez J. and Biswas R. (2018). “Opportunities and challenges for quantum-assisted machine learning in near-term quantum computers”. *Quantum Sci. Technol.* 3 030502.
- Petersen J.P., (2010). “K-Means”. Retrived December 27, (2018). From: K-Means — PyPR v0.1rc3 documentation (sourceforge.net)
- Phillipson, F. (2020). “Quantum machine learning: benefits and practical examples”, Conference: International Workshop on QuANtum SoftWare Engineering & pRogramming, 2020, Talavera, Spain. 51-56.
- Powell, J. R. (2008). “The quantum limit to Moore's law”. *Proceedings of the IEEE*, 96 (8), 1247-1248
- Preskill, J. (2018). “Quantum computing in the NISQ era and beyond”. *Quantum*, 2, 79.
- Qiskit (2021, 11 Mayıs) Erişim adresi: <https://qiskit.org/textbook/ch-states/single-qubit-gates.html>
- Rother, C., Kolmogorov, V. and Blake, A. (2004). “GrabCut interactive foreground extraction using iterated graph cuts”. *ACM transactions on graphics*, 23 (3), 309-314.
- Scholkopf, B., Sung, K. K., Burges, C. J., Girosi, F., Niyogi, P., Poggio, T., & Vapnik, V. (1997). “Comparing support vector machines with Gaussian kernels to radial basis function classifiers”. *IEEE transactions on Signal Processing*, 45(11), 2758-2765.

- Schuld, M. and Killoran, N. (2019). "Quantum machine learning in feature Hilbert spaces". Physical review letters, 122 (4), 040504.
- Schuld, M. and Petruccione, F. (2018). "Supervised learning with quantum computers". Springer: Berlin.
- Schuld, M., Sinayskiy, I. and Petruccione, F. (2015). "An introduction to quantum machine learning". Contemporary Physics, 56 (2), 172-185.
- Shalf, J. (2020). "The future of computing beyond Moore's law". Philosophical Transactions of the Royal Society A, 378 (2166), 20190061.
- Shor, P. W. (1994). "Algorithms for quantum computation: discrete logarithms and factoring". In Proceedings 35th annual symposium on foundations of computer science, 20- 22 November, Santa Fe, USA. 124-134
- Simonyan, K., & Zisserman, A. (2014). "Very deep convolutional networks for large-scale image recognition". arXiv preprint arXiv:1409.1556.
- Sutor, R. S. (2019). "*Dancing with Qubits: How quantum computing works and how it can change the world*". Packt Publishing Ltd: Birmingham.
- Yetiş, H., Karaköse, M.(2021). "Makine Öğrenmesi Yöntemlerinde Yüksek Başarımlar için Kuantum Bilgisayar ve Hesaplamanın Kullanımı". 14(1), 47-56.
- Wikimedia (2021,21October) Erişim adresi:  
<https://commons.wikimedia.org/wiki/File:VGG16.png>.
- Zhang, Y. and Ni, Q. (2020). "Recent advances in quantum machine learning". Quantum Engineering, 2 (1), e34.
- Zhu, N., Zhang, D., Wang, W., Li, X., Yang, B. vd. (2020). "A novel coronavirus from patients with pneumonia in China". 2019 New England journal of medicine, 382, 727-733.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

İsim SOYİSİM :  
Doğum Yeri :  
Doğum Tarihi :

### EĞİTİM DURUMU

Lisans Öğrenimi :  
Yüksek Lisans Öğrenimi :  
Bildiği Yabancı Diller :

### İŞ DENEYİMİ

Çalıştığı Kurumlar ve Yıl:

### İLETİŞİM

E-posta Adresi :  
ORCID :