

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



KUANTUM HESAPLAMA KULLANAN DERİN ÖĞRENME İLE
KARŞILIKLI GÖRÜŞMELERDE DUYGU ANALİZİ

Sedef AKSU

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Yazılım Anabilim Dalı Bilim Dalı

ŞUBAT 2024

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

KUANTUM HESAPLAMA KULLANAN DERİN ÖĞRENME İLE
KARŞILIKLI GÖRÜŞMELERDE DUYGU ANALİZİ

Tez Yazarı
Sedef AKSU

Danışman
Prof. Dr. Mehmet KARAKÖSE

ŞUBAT 2024
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Kuantum Hesaplama Kullanan Derin Öğrenme İle Karşılıklı Görüşmelerde Duygu Analizi
Yazarı:	Sedef AKSU
İlk Teslim Tarihi:	12.01.2024
Savunma Tarihi:	15.02.2024

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Mehmet KARAKÖSE Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Muhammed YILDIRIM Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Hasan YETİŞ Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Kuantum Hesaplama Kullanan Derin Öğrenme İle Karşılıklı Görüşmelerde Duygu Analizi ” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

15.02.2024

Sedef AKSU



ÖNSÖZ

Teknolojinin gelişmesiyle birlikte veri miktarı her geçen gün artmaktadır. Bu verileri işlemek, analiz etmek oldukça önemlidir. Duygu analizi, bu verileri işlemenin en popüler uygulamalardan biridir. Bu tez çalışması, klasik ve kuantum hesaplama kullanan derin öğrenme tabanlı duygu analizi yöntemleri ile kişinin duygusunu ve tutumunu sınıflandırmak ve sınıflandırma sonucuna göre ilgili kişi ve kurumlara geri besleme sağlamayı amaçlamaktadır.

Bu tez çalışması boyunca her türlü desteğini esirgemeyen, değerli vaktini ayırarak çalışmalarımda bana daima yol gösteren engin bilgi ve tecrübelerinden yararlandığım sayın danışmanım Prof. Dr. Mehmet KARAKÖSE 'ye teşekkür ederim. Ayrıca desteğiyle yanımda olan anneme, babama ve değerli eşim Faruk AKSU ' ya teşekkür ederim.

Bu tez kapsamında yapılan çalışmalar 121E439 numaralı TÜBİTAK 1001 araştırma projesi ile desteklenmiş olup, Türkiye Bilimsel Ve Teknolojik Araştırma Kurumuna teşekkür ederim.

Sedef AKSU
ELAZIĞ, 2024

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Literatür Taraması	4
1.2. Tezin Yapısı.....	12
2. KARŞILIKLI GÖRÜŞMELERDE DUYGU ANALİZİ.....	13
2.1. Önerilen Yöntem	13
2.2. Deneysel Sonuçlar	16
3. DERİN ÖĞRENME KULLANAN DUYGU ANALİZİ YAKLAŞIMI.....	19
3.1. Derin Öğrenme	19
3.2. Konvolüsyonel Sinir Ağları (CNN).....	21
3.3. Tekrarlayan Sinir Ağları	21
3.3.1 Uzun Kısa Vadeli Bellek Ağları (LSTM)	21
3.4. Sınıflandırma Ölçütleri	22
3.5. Derin Öğrenme ile Hastanelerdeki Hasta İncelemelerine Yönelik Duygu Analizi.....	24
3.5.1. Önerilen Yaklaşım.....	24
3.5.2. Deneysel Sonuçlar	26
4. KUANTUM HESAPLAMA TABANLI DUYGU ANALİZİ	31
4.1. Kuantum Hesaplama.....	31
4.1.1. Tekli Kuantum Mantık Kapıları	33
4.2. Kuantum Makine Öğrenmesi.....	35
4.2.1. Kuantum Makine Öğrenme Algoritmaları	35
4.3. Kuantum Hesaplama Tabanlı Duygu Analizi ile İlgili Çalışmalar	38
4.4. Önerilen Yaklaşım.....	41
4.5. Deneysel Sonuçlar	44
5. SONUÇLAR.....	47
KAYNAKLAR.....	49
ÖZGEÇMİŞ	

ÖZET

Kuantum Hesaplama Kullanan Derin Öğrenme İle Karşılıklı Görüşmelerde Duygu Analizi

Sedef AKSU

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Şubat 2024, Sayfa: xi + 54

Kuantum teorisi, başlangıçta mikroskobik parçacıkların hareketlerini tanımlamak için fiziksel bir teori olarak önerilmiş daha sonra kuantum benzeri özellikler sergileyen, insan bilişi ve karar verme sürecini içeren çeşitli fizik dışı alanlara uygulanmıştır. Bu alanlardan biri de duygu analizidir. Duygu Analizi, insanların bir duruma, olaya veya konuşmaya karşı duygu veya tutumlarının incelenmesini sağlayan Doğal Dil İşleme 'nin en popüler uygulamalarından biridir. Literatürdeki birçok çalışma film yorumları ve twitter verileri üzerinde çalışmaktadır. Sağlık verileri üzerinden duygu analizi gerçekleştiren çalışma yok denecek kadar azdır.

Bu tez kapsamında sağlık verileri üzerinden duygu analizi gerçekleştirmek amacıyla klasik ve kuantum hesaplama kullanan derin öğrenme tabanlı yeni yöntemler önerilmiştir. Önerilen yöntemlerden ilki LSTM derin öğrenme modeli kullanarak sağlık alanındaki karşılıklı görüşmelerden duygu analizi ile olumlu, nötr ve olumsuz olarak üç kutuplu bir sınıflandırma yapmıştır. Kullanılan bu yöntemde öncelikle model eğitime yönelik veriler metin işleme yöntemleriyle hazır hale getirildi ve LSTM derin öğrenme algoritmasıyla hazırlanan veri seti ile model eğitildi. Eğitim sonucunda başarı oranı %94 olarak hesaplandı. Elde edilen başarı oranı Literatürde incelenen çalışmalar ile karşılaştırılınca önerilen yöntemin başarı yüzdesi oldukça yüksektir. Önerilen yöntemlerden bir diğeri, hastanelerle ilgili hastaların incelemelerine yönelik duygu analizi gerçekleştirilmiştir. Hastaların tıbbi incelemeleri tıbbi yönetim departmanı için oldukça önemlidir. Hasta değerlendirmelerinin olumlu veya olumsuz olarak sınıflandırmak için dört sinir modeli geliştirildi. Öncelikle çevrimiçi alınan veriler ön işleme tabi tutuldu. Daha sonra sinirsel eğitim gerçekleştirmek amacıyla Skipgram kelime yerleştirme kullanıldı en son olarak eğitim gerçekleştirildi. Eğitim aşamalarının ardından %85 üzerinde performansla en iyi başarı puanına sahip iki model LSTM- CNN ve LSTM mimarileri oldu. Önerilen yöntemlerden sonuncusu doktor-hasta diyaloglarından oluşan metinlerin içerdiği duyguların pozitif-nötr-negatif olarak sınıflandırılması amacıyla kuantum hesaplama ve derin öğrenmede kullanılan LSTM yinelemeli sinir ağı modeli kullanılmıştır. Önerilen yöntemin başarı oranı %94,52' dir. Kuantum Hesaplama yöntemi programların işletilmesinde zaman açısından kritik rol almaktadır. Bu yüzden önerilen yöntemin diğer alandaki çalışmalar için de klasik-kuantum hibrit yönteminin öncülük edeceği düşünülmektedir.

Anahtar Kelimeler: Konuşma Tanıma, Duygu Analizi, Kuantum Hesaplama, Derin Öğrenme, e-Sağlık

ABSTRACT

Sentiment Analysis in Conversations with Deep Learning Using Quantum Computing

Sedef AKSU

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

February 2024, Pages: xi + 54

Quantum theory was originally proposed as a physical theory to describe the behaviour of microscopic particles, and was later applied to various non-physical fields that exhibit quantum-like properties, including human cognition and decision-making. One of these fields is sentiment analysis. Sentiment Analysis is one of the most popular applications of Natural Language Processing, which allows the study of people's emotions or attitudes towards a situation, event or speech. Many studies in the literature work on film reviews and twitter data. There are almost no studies that perform sentiment analysis on health data.

In this thesis, new deep learning based methods using classical and quantum computing are proposed to perform sentiment analysis on health data. The first of the proposed methods uses the LSTM deep learning model to perform a three-pole classification as positive, neutral and negative with sentiment analysis from mutual interviews in the field of health. In this method, firstly, the data for model training was prepared by text processing methods and the model was trained with the data set prepared with the LSTM deep learning algorithm. As a result of the training, the success rate was calculated as 94%. When the success rate obtained is compared with the studies examined in the literature, the success rate of the proposed method is quite high. Another one of the proposed methods is the sentiment analysis of patients' reviews about hospitals. Medical reviews of patients are very important for medical management departments. Four neural models were developed to classify patient reviews as positive or negative. Firstly, the online data were preprocessed. Then Skipgram word embedding was used to perform neural training and finally training was performed. After the training stages, LSTM-CNN and LSTM architectures were the two models with the best success score with over 85% performance. The last of the proposed methods is the LSTM recurrent neural network model used in quantum computing and deep learning to classify the emotions contained in texts consisting of doctor-patient dialogues as positive-neutral-negative. The success rate of the proposed method is 94.52%. Quantum computing method plays a critical role in the execution of programmes in terms of time. Therefore, it is thought that the proposed method will pioneer the classical-quantum hybrid method for studies in other fields

Keywords: Speech Recognition, Sentiment Analysis, Quantum Computing, Deep Learning, e-Health

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1. 1. Duygu Analizi Türleri[2].....	1
Şekil 1. 2. Duygu Analizi Teknikleri [2]	2
Şekil 1. 3. Dimitra Emmanouilidou ve arkadaşının önerdiği sistem [14].....	6
Şekil 1. 4. Maghilnan ve arkadaşlarının önerdiği sistem [18].	7
Şekil 1. 5. Taylan Şen ve arkadaşlarının önerdiği sistem [20].....	8
Şekil 1. 6. Önerilen yönteme ait blok diyagramı [22]	9
Şekil 2. 1. Metni hazır hale getirmek için gerekli çalışma adımları	14
Şekil 2. 2. Model eğitimi için gerekli adımların blok diyagramı	14
Şekil 2. 3. Önerilen modelin başarı skoru	17
Şekil 3. 1. Yapay sinir ağı ile derin öğrenme yapısı [39]	20
Şekil 3. 2. Derin öğrenme, makine öğrenmesi ve yapay zek arasındaki ilişki [40]	20
Şekil 3. 3. Makine öğrenmesi ve derin öğrenme arasındaki fark [41]	20
Şekil 3. 4. CNN mimarisi [42].....	21
Şekil 3. 5. LSTM hücre yapısı.....	22
Şekil 3. 6. Önerilen yöntemin akış diyagramı	24
Şekil 3. 7. Skipgram kelime yerleştirme yöntemi.....	25
Şekil 3. 8. Sinir Mimarileri (a:CNN, b:LSTM, c:Dense, d:CNN-LSTM)	26
Şekil 3. 9. Dense mimarinin eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir.	28
Şekil 3. 10. CNN mimarinin eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir.	29
Şekil 3. 11. LSTM mimarinin eğitim ve doğrulama kaybı (a) ve başarısı(b) gösterilmiştir.	29
Şekil 3. 12. CNN-LSTM mimariye ait eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir.....	30
Şekil 4. 1. Bloch küresi gösterimi [55].....	33
Şekil 4. 2. Klasik Sinir Ağı ve VQC [58]	35
Şekil 4. 3. X1 ve X2 değişkenlerine bağlı doğrusal destek vektör makinesi sınıflandırma örneği [77]	36
Şekil 4. 4. Kuantum hesaplamanın makine öğrenmesi yöntemlerinde kullanılması [78].....	37
Şekil 4. 5. Önerilen yöntemin blok diyagramı.....	39
Şekil 4. 6. Önerilen modelin akış diyagramı [65].....	40
Şekil 4. 7. Önerilen yöntemin akış diyagramı	41
Şekil 4. 8. Önerilen yöntemde kullanılan kuantum devre yapısı	43
Şekil 4. 9. Örnek veri seti	44
Şekil 4. 10. Önerilen yöntemin doğruluk oranı	46

Şekil 4. 11. Önerilen yöntemin kayıp değeri	46
---	----



TABLÖLAR LİSTESİ

	Sayfa
Tablo 1. 1. Kullanılan algoritma ve doğruluk oranı [23]	9
Tablo 1. 2. Literatür karşılaştırılması	11
Tablo 2. 1. Literatür taramasında incelenen çalışmaların değerlendirilmesi	16
Tablo 2. 2. Literatürdeki çalışmaların karşılaştırılması	18
Tablo 3. 1. Karışıklık Matrisi Örneği	23
Tablo 3. 2. Sinir mimarilerinin eğitim ve doğrulama başarıları	26
Tablo 3. 3. Sinir mimarilerinin performansının karşılaştırılması	27
Tablo 4. 1. Temel kuantum mantık kapıları ve matris formları	34
Tablo 4. 2. Kuantum hesaplamanın tarihsel gelişimi [54]	34
Tablo 4. 3. Derin öğrenme modelinin katmanları	42
Tablo 4. 4. Derin öğrenme modeli parametreleri	45
Tablo 5. 1. Tez Kapsamında Önerilen Yaklaşımlar	48

SİMGELER VE KISALTMALAR

Simgeler

α	: 0 değerinin olasılığı
β	: 1 değerinin olasılığı


Kısaltmalar

LSTM	:Uzun Kısa Vadeli Bellek
CNN	:Konvolüsyonel Sinir Ağı
RNN	:Tekrarlayan Sinir Ağı
MLP	:Çok Katmanlı Algılayıcı
SVM	:Destek Vektör Makineleri
LR	:Lojistik Regresyon
NB	:Naive Bayes
NLP	:Doğal Dil İşleme
Bi-LSTM	:Çift Yönlü Uzun Kısa Vadeli Bellek
TESS	:Toronto Duygusal Konuşma Seti
RAVDESS	:Duygusal Konuşma ve Şarkının Ryerson Görsel-İşitsel Veritabanı
KNN	:K-En yakın komşuluk algoritması
DP	:Doğru Pozitif
DN	:Doğru Negatif
YP	:Yanlış Pozitif
YN	:Yanlış Negatif
QkNN	:Kuantum k- En Yakın Komşuluk
QSVM	:Kuantum Destek Vektör Makinesi
VQC	:Varyasyonel Kuantum Devresi

1. GİRİŞ

İletişim teknolojilerindeki ilerlemelerin artmasıyla birlikte internet hayatımızın vazgeçilmez bir parçası olmuş ve sosyal medya araçlarının kullanımı oldukça yaygınlaşmıştır. Sosyal medya paylaşımları; güncel haberleri, bir konu hakkında duygu ve düşünceleri, hayata bakış açıları gibi birçok konu ile ilgili bilgiler içermektedir. Sosyal medyanın bu kadar bilgiyi içermesi nedeniyle duygu analizi için paha biçilmez bir kaynak olmuştur. İnternet bu kadar hayatımızdayken her şeye daha hızlı ulaşabilmek, vakit kaybı olmadan bulunduğumuz yerden istediklerimizi anında gerçekleştirmek için çevrimiçi hizmetlerden yararlanılmaktadır. Dünyayı etkisi altına alan Covid-19 uzaktan çevrimiçi hizmetlerin kullanımını daha çok arttırmış ve alışveriş, sağlık, eğitim, bankacılık gibi birçok alanda sıklıkla kullanım alanı olarak tercih edilmiştir. Özellikle tıp dünyasında erken tanı, kolaylıkla hastalara ulaşma, sıra beklemeden ön muayene kolaylığı sağlamaktadır. Ön muayene doktor- hasta ilişkilerinde önemli rol oynamakta ve birçok hastalığın erken teşhis şansını artırarak hastalıktan kurtulma şansını doğurmaktadır. Muayene sırasında doktor ve hastanın hangi duyguda olduğu da oldukça önem taşımaktadır [1]. Bu duygu yüklü konuşma veya yazışmaların sınıflandırılması için duygu analizinden yararlanılır.

Duygu Analizi, insanların bir duruma, olaya veya konuşmaya karşı duygu veya tutumlarının incelenmesidir. Doğal dil işlemenin (NLP) bir alt kümesi olan duygu analizi, insanların yazılı materyalde iletmiş duygu ve tutumunu keşfetmeyi ve çıkarmayı amaçlamaktadır. Bunu metni okuyan kişinin nasıl hissettiğini sorarak yapar. Metin verilerini değerlendirmek ve bunları metinde ifade edilen duygusal durumuna bağlı olarak olumlu, olumsuz veya tarafsız olarak sınıflandırmak için bilgisayar araçlarının ve algoritmaların kullanılmasını içerir. Fikir madenciliği olarak da bilinen duygu analizi; finans, tıp, borsacılık, alışveriş, medya gibi birçok alanda kullanılmaktadır. Duygu analizi yapılırken birkaç farklı yöntem kullanılabilir [2]. Şekil 1.1 'de duygu analizi türleri gösterilmiş olup her birinin yoğunlaşma ve kullanım alanına dair örnekler aşağıda verilmiştir.



Şekil 1. 1. Duygu Analizi Türleri[2]

Hedef Tabanlı Duygu Analizi, bir ürün veya hizmetin belirli özellikleriyle bağlantılı duygu tespit etmeyi amaçlayan bir yöntemdir. Bu özellikler fiyatlandırma, paketleme, müşteri


hizmetleri olabilir. Örnek olarak bir restorana ait incelemede servis hızı, yemeğin kalitesi, fiyatı gibi birçok özellikler duyguyu belirlemektedir.

Çok Tonlu Duygu Analizi, ifadeler ya da cümlelere duygu derecelendirmeleri verilerek metinde aktarılan duygunun ayrıntılı incelenmesini içerir. Örnek olarak bir pazar araştırması gibi yüksek düzeyde ayrıntı gerektiren uygulamalar için kullanılabilir çünkü daha ayırt edici duygular içerir.

Niyet Temelli Duygu Analizi, metindeki ifadelerin öneri mi yoksa şikayet mi olduğunu belirlemek amacıyla kullanılmaktadır ve bu amaca göre metnin duygusunu tespit etmeye odaklanır.

Duygu Denetimi, metinde iletilen mutluluk, üzüntü, korku veya öfke gibi alta yatan duyguları tanımaya yönelik bir yöntemdir. Bir topluluğun bir ürüne, hizmete veya etkinliğe verdiği tepki duygu denetimi yoluyla toplanabilir ve buda yararlı olabilir.

Bu yöntemler sözlük yaklaşımı, makine öğrenmesi yaklaşımı ve hibrit yöntemleri içerir. Sözlük tabanlı yaklaşım, önceden oluşturulan sözlüklere veya olumlu, olumsuz duygularla ilişkili terim sözlüklerine dayanmaktadır. Makine öğrenme tabanlı yaklaşımlar var olan kalıpları keşfetmek ve metinde ifade edilmek istenen duygu hakkında tahminler yapmak için etiketlenmiş metinlerden oluşan veri kümeleri üzerinde algoritmalar geliştirmeyi ve eğitmeyi içermektedir. Hibrit yöntemler ise sözlük yaklaşımı ve makine öğrenme yaklaşımını içerir ve daha gerçekçi duygu analizi üretmek için farklı yöntemler geliştirir.



Şekil 1. 2. Duygu Analizi Teknikleri [2]

Şekil 1.2’ de duygu analizi teknikleri gösterilmiş olup tekniklerin avantaj ve dezavantajları olduğunu ve teknik seçiminin uygulamanın gereksinimlerine göre seçilmesi gerektiği belirtilmiştir. Metin içerisindeki duygu aktarımını analiz yapmak için birden fazla yöntemlerle duygu analizi yapılmaktadır. Metin analizi yapılırken iki önemli değer bulunmaktadır. Bu değerlerden birincisi metinleri oluşturan sözcük tabanlı duygu analizidir. Sözlük yaklaşımı, gerçek zamanlı işlem gerektiren ve bağlama bağlı ayırt edici duyarlılık içermeyen uygulamalar için uygunken makine

öğrenme yaklaşımı ayırt edici duyguyu yakalamak için yüksek doğruluk ve esneklik gerektiren uygulamalar için uygundur. Sözcük tabanlı duygu analiz yapımını daha çok tercih edilmesinin nedeni büyük veri kaynaklarına ihtiyaç duyulmamasıdır. Oluşan kelimelerin duygu aktarımı olarak üç ölçüt bulunmaktadır bunlar; pozitif, negatif ve tarafsız (nötr) puanlandırma yapılarak analiz yapılmaktadır. Bu duygu aktarımı için kullanılan ölçütler analiz yapımında eğitim aşamasında kolaylık sağlamaktadır. Fakat Türkçe’ de sıklıkla kullanılan deyim, mecaz anlam, atasözleri gibi kullanımlar analiz yapımını zorlaştırmaktadır.

Duygu analizi üzerine yapılan çalışmalar incelendiğinde geliştirilen algoritmalar ve kütüphaneler genellikle İngilizce üzerinedir ve Türkçe başta olmak üzere farklı diller için geliştirilmesi gereken bir konudur [3]. Türkçe dilinin zengin morfolojik yapısı ve sondan eklemeli bir dil olmasından kaynaklı analizi diğer dillere göre daha zordur. Farklı dillerde birkaç anlamla ifade edilirken Türkçe’ de tek bir kelime ile ifade edilmesi mümkündür bu sebepten dolayı Türkçe veri seyrekliğini yaşamaktadır. Bu sorundan dolayı bazı temsil değerlerinde azalmalar gözlenmektedir bu azalmalar sonucunda veri kümesinde var olan veya olmayan sözcüklerin görünüşlerin aynı olması kanısına yol açmaktadır. Türkçe’nin diğer dillerden daha zor analiz yapılmasının sebeplerinden biri ise Türkçe cümlelerin içinde söz dizilimlerin dağınık şekilde olmasından kaynaklanmaktadır.

Türkçe’nin dağınık söz dizilimden dolayı cümle içindeki kelimeler arasındaki bağlantı kurulamadığı için analiz yapmak zor olmaktadır fakat İngilizce gibi yabancı dillerde cümle içindeki kelimeler arasındaki bağlantı önemli olduğu için analiz yapımı Türkçe ’ye göre daha kolaydır. Bu özelliklere bir örnekle açıklamak gerekirse metin içerisindeki cümlelerin duygusunu anlayabilmek için hedef kelimenin bir önceki kelimesine hem de bir sonraki kelimeye bakılarak yapılan analizler bu alanda yeterli değildir.

Kuantum hesaplama kuantum mekaniğini temel alarak ve kuantum üstünlüklerinden faydalanan bilgi işleme yöntemlerini kapsayan, süper pozisyon ve dolanıklık gibi kuantum kavramlarını kullanan hesaplama modelidir. Kuantum hesaplamanın kendine has özellikleri bulunmaktadır. Kullanılan temel kapılardan, algoritma geliştirmek amacıyla kurulan mantık yapısına kadar klasik dediğimiz ikili hesaplama kavramından farklılık gösterir.

Kuantum hesaplama tabanlı duygu analizi oldukça yeni bir yöntem olmak üzere bu alanda pek fazla çalışma bulunmamaktadır. Quantinuum firması kuantum doğal dil işlemede kullanılabilen ve kuantum hesaplama Lambeq arka planda DisCoCat (Distributional Compositional Categorical) kütüphanesini kullanmaktadır. DisCoCat giriş olarak verilen cümleleri dağılımlarına göre kategorize etmekte ve tensör formunda çıktı üretmektedir [4]. Oluşan tensör çıktılar ise kuantum devrede kolaylıkla işlenebilmesini sağlamaktadır [5]. Bu çalışma doktor- hasta görüşmelerinden duygu analizi ile sınıflandırma yapmayı amaçlamaktadır. Sınıflandırmanın yapılabilmesi için doktor- hasta konuşmalarından veri seti oluşturulmuş ve bu veri seti derin öğrenme ve kuantum

hesaplamasından yararlanılarak sınıflandırılma yapılacaktır. Doktor-hasta görüşmelerine ait tıbbi kayıtların ve raporların üzerinde çalışmalar yapılmasını gerektiren bir alan olup bu verilerden duygu analizinin gerçekleştirilmesine yönelik Literatürde bir çalışmanın olmadığı bir alandır. Sağlık verilerinden duygu analizi ile ilgili çalışmaların çoğu sosyal medya verilerini dikkate almaktadır. Klinik ortamda doktor-hasta görüşmelerine ait veriler, hastanın geçmişini, muayene bulgularını, tedavi planlarını ve diğer ilgili bilgilerini içeren belgelerdir. Ayrıca Sağlık çalışanlarının hastanın sağlık durumuna ilişkin düşüncelerini yansıtmaktadır. Tıp alanında bir hastanın durumuyla ilgili önemli bilgileri iletmek ve tedavinin seyrinin ne yönde olduğunu belgelemek için kullanılmaktadır [6].

1.1. Literatür Taraması

Literatürde duygu analizi, ses tanıma ve kuantum hesaplama ile ilgili çalışmalar incelendi. Bu çalışmalardan bazıları;

S. Poria ve diğerlerinin [2], önerdikleri çalışmada denizcilerin tıbbi belgeleri ile duygu analizi gerçekleştiren bir sistem önerilmiş. Önerilen yöntemde tıbbi kayıtlar, İtalyan dijital sağlık sistemlerinden toplanmış olup, 2018,2019 ve 2020 yıllarındaki tıbbi belgelerden oluşan veri seti üzerinde çalışılmış. Naive Bayes makine öğrenme yöntemi ile sınıflandırma yapılmış ve sınıflandırma olumlu, olumsuz ve tarafsız olarak belirlenmiştir. Çalışmadaki doğruluk oranı %80'olarak hesaplanmıştır.

Kanwar M. Ve diğerlerinin [8], önerdikleri çalışmada Word2Vec, GloVe, TF-IDF, BERT ve FastText gibi sözcük yerleştirme yöntemlerini bir evrişimli sinir ağına birleştiren Roman Urduca duygu analizi için derin bir öğrenme modeli olan CNN-LSTM kullanılmıştır. Modeli eğitmek için dört farklı veri seti kullanılmış olup bu veri setleri çeşitli sosyal medya uygulamalarından elde edilen olumlu, olumsuz ve nötr cümleleri içermektedir. Eğitim için verilerin %80'i test için ise % 20'si kullanılmıştır. Testler önerilen modelin başarısının iyi olduğunu göstermekte ve iyi bilinen teknikleri geride bırakarak doğruluğu %5'e kadar arttırmıştır.

Şeyma Ş.Y ve diğerlerinin [9] önerdikleri çalışmada, Türkçe metinler üzerinde duygu analizi gerçekleştirmeyi hedefleyen bir yöntem geliştirilmiştir. Önerilen Sistem iki veri kümesi üzerinde çalışmaktadır. İlki 1 milyonu aşkın tweetten oluşurken diğer veri kümesi OffensEval yarışma verilerinden oluşmaktadır. Bu çalışmada verilerin %80 ' i eğitim için ayrılırken % 20' si test için ayrılmıştır. Bu veri kümeleri derin öğrenme yöntemlerinden biri olan Uzun Kısa Vadeli Bellek (LSTM) ve Çift Yönlü Uzun Kısa Vadeli Bellek (BiLSTM) kullanılarak analiz edilmiş olup doğruluk oranı her iki yöntem için %86 ' dır.

M.C Yılmaz ve diğerlerinin [10] önerdikleri çalışmada, Twitter üzerinden Covid-19 süreci ile ilgili atılan tweetlerden oluşturulan beş veri seti ile duygu analizi gerçekleştirilmiştir. Bu veri


setlerinin analizi için bir derin öğrenme yöntemi olan Uzun Kısa Süreli Bellek (LSTM) kullanan bir sistem önerilmiştir ve önerilen sistem iki veri seti için %97 doğruluk başarısını elde etmiştir.

Sultana R. ve diğerlerinin [11] önerdikleri çalışmada, bilim ve teknolojinin ilerlemesiyle, konuşmanın görsel metin biçimini oluşturmak için otomatik konuşmadan metne dönüştürme sistemi geliştirmişler. Bu teknoloji, dinleme engelli kişilerin sesli iletişimi anlamak için alternatif bir şekilde iletişim kurmalarını ve görsel yeteneklerini kullanarak talimatları takip etmelerini sağlar. Bengalce konuşma tanıma alanındaki araştırmalar hala birincil aşamadadır. Bengalce konuşmayı metne dönüştürme alanında büyük miktarda ilerici çalışma gereklidir.

Monil Bansal ve diğerlerinin [12] önerdikleri çalışmada, sesli duygu tespit sistemi geliştirilmiştir. Bu sistem veri seti olarak üç veri seti kullanmaktadır. Bunlar şu şekildedir, Toronto Duygusal Konuşma Seti (TESS), Duygusal Konuşma ve Şarkının Ryerson Görsel-İşitsel Veritabanı (RAVDESS) ve özelleştirilmiş veri kümesidir. Her bir veri kümesi için örneklerin % 70 'i eğitim, % 20 'si test ve % 10 'u ise doğrulama için kullanılmıştır. Önerilen çalışmada K-En yakın komşuluk algoritması(KNN),Destek Vektör Makinesi (SVM),Karar Ağaçları, Çok katmanlı Algılayıcı gibi temel modellerden yararlanılmıştır. Araştırma ve deneyin sonuçları şu şekildedir. Genel doğruluk TESS ve RAVDESS için sırasıyla %99.46 ve %89.62'dir.Ayrıca, özel veri kümesi için %78,28 doğruluk sağladığı belirlenmiştir.

Abir Messaoudi ve diğerleri [13], Uçtan uca Tunus lehçesi için Derin Öğrenme tabanlı bir Otomatik Konuşma Sistemi önermişler. Tunus diliyle konuşulan kaynaklar ile TunSpeech adında bir metin-konuşma veri seti oluşturulmuştur. Arapça konuşma verileri Tunus verileriyle birleştirilmiş ve böylelikle kelime eksikliği azaltılmıştır. Otomatik konuşma tanıma sistemi, eksik cümleler, kekemelik, öksürme kahkaha gibi olumsuzluklardan etkilenmiştir. Gelecekteki çalışma olarak, BERT benzeri modeller konuşma işlemeye de uygulanabileceğinden, Tunus bağlamsal BERT tabanlı bir dil modelini oluşturmayı amaçlamaktadır [9].

Dimitra Emmanouilidou ve diğerlerinin [14] önerdiği çalışma gerçek hayattaki müşteri çağrılarından yararlanarak otomatik konuşma tanıma sisteminden elde edilen çıktılarından duygu analizi tespiti için çeşitli özellikleri ve sınıflandırıcıları araştırmaktadır. Önerilen sistem Şekil 1.3' te gösterilmiştir. Veri kümesi müşteri destek çağrılarından elde edilen 1987 seanstan oluşmaktadır. Çağrıdaki her bir ifadeden gelen sınıflandırmalar daha sonra müşterinin değerlendirmesi için birleştirilmektedir. Sınıflandırma yalnızca pozitif, nötr, negatif olarak gerçekleşmektedir. Bu çalışmadaki yaşanan zorluk sınıflandırıcıların sabit uzunlukta girdi beklerken kelime sayısının müşteriden müşteriye farklılık göstermesidir. Bunu önlemek için sınıflandırıcından önce konuşmalar üzerinden istatistiksel işlem yapılması gerekir. Çeşitli özellikler ve ağ mimarileri üzerinde yapılan analiz, derin öğrenme tabanlı sınıflandırıcının en iyi seçim olduğunu ortaya koymuştur. Yapılan deneyde hepsinden daha iyi performans gösteren aşırı öğrenme makinesi olmuştur.




Şekil 1. 3. Dimitra Emmanouilidou ve arkadaşının önerdiği sistem [14].

N. Mojumder ve diğerlerinin [15] geliştirdiği çalışmada, RNN tabanlı konuşma duygu tespit sistemi sunulmuştur. Yöntem gelen her sözcüğü, sözcüğe daha iyi bir bağlam veren konuşmacının özelliklerini dikkate alarak ele alır. Model, hem metinsel hem de çok modlu ayarlarda iki farklı veri kümesinde mevcut en son teknolojiden daha iyi performans gösterdiğini fakat ikiden fazla konuşma için gelişmeye açık olduğu belirtilmiştir.

Rohit Raj Sehgal ve diğerlerinin [16] yaptığı çalışmada, kullanıcı duygularını tanımak için çağrı merkezi ortamlarında duygu analizinin nasıl kullanılabileceğine ilişkin yaklaşımları, teknikleri ve müşterilerin Otomatik Konuşma Sisteminden memnun olup olmadığını belirlemek için duyarlılık analizinin kullanımını açıklar. Yapılan çalışmada veri kümesi olarak kullanıcı konuşmalarından elde edilen metinsel veriler veritabanının da kaydedilir ve daha sonra duygu analizi teknikleri kullanılır. Bu veritabanı aynı zamanda kullanıcı geri bildirimlerini de depolar. Yapılan çalışmada Naive Bayes Sınıflandırıcısı, Maks Entropi Sınıflandırıcı ve Yükseltilmiş Ağaçlar mimarisi kullanılmıştır. Sonuç kullanıcı ve müşteri hizmetleri yöneticisi arasındaki çağrılar üzerinden kullanıldığında, Yapay zeka ve Derin Öğrenme bilgisayar sisteminin izlemesini ve müşteri hizmetleri yöneticisinin muhtemelen dolandırıcılık veya uygunsuz davranışlarını belirlemesini sağlamaktadır. Bilgisayar sistemi yardımıyla müşteri memnuniyet düzeyinin belirlenmesi, kuruluşun iyi performans gösteren çalışanların belirlenmesini sağlayacaktır. Son olarak bu sistem, dil çeşitliliğinin sınırlı olduğu ülkelerde iyi performans gösterebileceğini ortaya koymuştur.

R. Lorenz ve diğerlerinin [17] önerdiği yöntemde, ses kodlayıcı olarak konuşmadan metne transkripsiyonu ve kod çözücü olarak metinden konuşmaya sentezini kullanmanın avantajlarını analiz etmek ve bunu standart bir PCM A-law codec bileşeniyle karşılaştırmak için, kullanıcı tarafından hata oranı ölçülmüştür. Yazıya dökülen mesajların temel gerçeğe ne kadar benzer olduğunu değerlendirilmiş olup. Sonuçlar sentezlenen ses ile gerçek ses arasında önemli bir fark göstermediğinden, konuşmadan metne kod çözücü olarak kullanmanın uygun olabileceği sonucuna varmaktadır.

Maghilnan S. ve diğerlerinin [18] önerdiği çalışmada, iki kişi arasındaki konuşmayı içeren bir ses dosyasını girdi olarak veren ve konuşmacının kimliğini tanıyarak ses dosyasını otomatik olarak metne dönüştüren bir sistem önermiştir. Önerilen sistem aşağıdaki blok diyagramında gösterilmiştir. Bu sistemde ki veri seti 4 kadın 3 erkek olmak üzere toplam 7 kişiye ait 21 ses dosyasından oluşmaktadır. Konuşmalar, senaryoya bağlı olarak konuşmacıların aynı veya farklı olması durumuna göre "Hoparlör 1" ve Hoparlör 2" olarak etiketlenmiştir. Konuşma tanıma için kullanılan araçlar Sphinx4, Bing Speech API, Google Speech API' dir. Ve kullanılan performans metriği WWR' dir. Duygu analizi için, standart duygu analizi veri kümeleri kullanılmıştır. Önerilen sistemden elde edilen sonuçlar şu şekildedir, Sistem 21 ses dosyasını içeren veri seti ile iyi çalışmaktadır. Daha büyük veri seti oluşturmak ve sistemin ölçeklendirebilirliğini artırmak amacıyla çalışmalar devam etmektedir. Önerilen sisteme ait blok diyagramı Şekil 1.4 ' te gösterilmektedir.



Şekil 1. 4. Maghilnan ve arkadaşlarının önerdiği sistem [18].

G. Dimauro ve nin [19] önerdiği çalışmada, Parkinson hastalığı (PD) olan hastalar, kasların koordinasyonunun azalması nedeniyle konuşmada güçlük çekebildiğinden bahsetmiş. Sesten metne sistemleri, konuşulan dilin bilgisayarlar ve bilgisayarlı cihazlar tarafından tanınmasını ve metne çevrilmesini sağlayan yöntemlere ve teknolojilere dayandığını açıklayarak. Çalışmada Google STT dönüşümüne dayanan çalışmayı gerçekleştirmek için PD' deki ses ve konuşma değişikliklerinin dijital değerlendirmesi için bir yazılım sistemi olan Voxtester geliştirmişler.

Taylan Şen ve diğerlerinin [20] yaptığı çalışmada, doktor-hasta iletişiminin otomatik olarak analiz edildiği bir yöntem sunmaktadır. Aşağıda önerilen sisteme ait blok şeması gösterilmiştir. Bu yöntem sağlık kurumlarında bulunan onkologlar ve kanser hastaları üzerinde uygulanmaktadır. Veri kümesi 40 onkolog ve 112 hastadan elde edilmiştir. Toplanan veriler, doktor-hasta ziyaretlerinin dökümlerini, etkileşimlerin ses kayıtlarını ve hasta anket sonuçlarını içermektedir. Analiz edilen her hasta için veriler, ziyaretin ses kaydının bir metin dökümünü ve hastanın doktorun iletişim becerisinin yönlerine ilişkin derecelendirmeleri bulunmaktadır. Konuşmada konuşulan kelimelerin toplam sayısı ve yüzdesi, konuşulan benzersiz kelimelerin çeşitliliği ve sorulan soruların sayısı kullanılan duyuşsal özellikler, doktor ve hastanın olumlu, olumsuz, nötr duygularını içerir. Duygunun genellikle ilişkili olumlu veya olumsuz duyguyu temsil ettiği anlaşılır. NLTK


doğal dil işleme araç seti ile duygu analizi için iyi bilinen VADER aracını kullanarak duygu özellikleri çıkarılmıştır. Önerilen sistemde Lojistik Regresyon ve K-En Yakın Komşu Sınıflandırıcıları ile anket yanıtları tahmin edilmiştir. Sonuç olarak doktorlar tarafından konuşulan kelimelerin sayısının iyi iletişim ile ilişkili olduğu ve belirli konuşma tarzlarını benimsemenin iletişim derecelendirmeleri ve potansiyel olarak sabırlı olma üzerinde olumlu bir etkisi olduğu tespit edilmiştir. Önerilen sisteme ait blok diyagramı Şekil 1.5 ‘ te gösterilmektedir.



Şekil 1. 5. Taylan Şen ve arkadaşlarının önerdiği sistem [20]

Jiang ve Zhang [21] önerdiği çalışmada bilgi çıkarma işlemini gerçekleştirebilmek için, girişim olgusunu bilgi çıkarma sürecine ekleyebilen ve kuantum girişiminden ilham alan bir sinir ağı eşleştirme modeli (QINM) önerdiler. Deney sonuçları, bunun kuantumdan ilham alan bilgi çıkarma modellerinden ve daha önce önerilen sinir ağı modellerinden daha üstün olduğunu göstermektedir.

Yogendra Narayan P. ve diğerlerinin [22] önerdiği çalışmada, metni ince taneli duygulara göre sınıflandırmada hangi modellerin en iyi şekilde çalıştığının tespiti yapılmak istenmiş. Go Emotions veri kümesi üzerinde makine öğrenme ve derin öğrenme modellerini değerlendirilmiş. Go- Emotions veri kümesi, her yorumun 27 duygudan en az birine karşılık geldiği Reddit yorumlarından oluşan büyük ölçekli bir veri kümesidir. Bu veri kümesi makine öğrenme yöntemleri ve derin öğrenme modellerini değerlendirmek için mikro ortalama F1 puanı kullanılmış. Önerilen modellerden CNN ve Bi-LSTM alt ağlarına sahip modelin %41,9 ile en iyi performansı verdiği ve derin öğrenme yöntemlerinin bu tür çoklu etiket sınıflandırma problemleri için makine öğrenme modellerinden önemli ölçüde daha iyi performans gösterdiğinin tespiti yapılmıştır. Önerilen yönteme ait blok diyagramı Şekil 1.6 ‘da gösterilmektedir.



Şekil 1. 6. Önerilen yönteme ait blok diyagramı [22]

Ganesh C. ve diğerleri [23] önerdikleri çalışma sağlık sektöründeki tüketicilerin temel duygu ve hislerini anlamak ve ilaç incelemelerine ilişkin duygu analizi ile sınıflandırma yapmayı amaçlıyor. Bu çalışma yaygın olarak kullanılan web sitesinden elde edilen ilaç incelemelerinden oluşan bir veri tabanını kullanmakta bu veriler güvenilir duygu sınıflandırması yapabilmek amacıyla ön işlem adımlarından geçirilmiş. Derin öğrenme ve makine öğrenme teknikleri kullanılarak sınıflandırma gerçekleştirilmiş ve bu sınıflandırmaların sonucu olumlu, olumsuz ve nötr olmak üzere üç kutupludur. Tablo 1.1 ‘ de Bu çalışmada kullanılan algoritmalar ve bu algoritmaların başarı oranları verilmiştir. İnsanların ilaç incelemeleri hakkında ne hissettiğinin tespiti için en iyi performansı gösteren model BiLSTM olmuş ve doğruluk oranı %89,3 olarak hesaplanmıştır.

Tablo 1. 1. Kullanılan algoritma ve doğruluk oranı [23]

Algoritma	Doğruluk
SVM	%81.5
Karar Ağacı	%76.79
KNN	%55.41
LSTM	%85.12
BiLSTM	%89.3

Muhamad F. ve diğerlerinin [24] önerdiği yöntemde çok sınıflı ve çok çıkışlı derin öğrenme modeli kullanarak hizmetler, insan kaynakları ve tesislere ait verileri olumlu, olumsuz, nötr ve hiçbirini olarak sınıflandırmak amaçlanmıştır. Bu yöntemde tek bir model kullanarak hem görünüş hemde duygu sınıflandırılmıştır. Sonuçlara göre BERT-LSTM modelinin %59.7 değeriyle en iyi genel F1 skorunu elde etmiştir. Ancak nötr duyguyu analiz etmekte zorlanılmış bunun sebebi olarak nötr duygu etiketlerinin eksikliğinden kaynaklı olduğu düşünülmektedir.

Meylan W. ve diğerlerinin [25] önerdiği yöntem Naive Bayes tabanlı bir duygu analizi modelidir. Naive Bayes algoritması sosyal grupları veya duygu durumlarını sınıflandırmak amacıyla kullanılır. Bu çalışma da Naive Bayes, Destek Vektör Makineleri ve En Yakın Komşular algoritmaları test edilmiş ve doğruluk değerleri sırasıyla %75, %64 ve % 73 olarak hesaplanmıştır.

Y. Ayyappa ve diğerleri [26] önerilen çalışmada BERT ve LSTM kullanılarak duygu analizi kapsayan bir hisse senedi fiyat tahmin sistemi geliştirilmiştir. Bu çalışma da geçmiş hisse senedi verilerine ve tweet duyarlılığına dayanarak hisse senedi fiyatlarını doğru bir şekilde tahmin etmek amacıyla derin öğrenme teknikleri ile duygu analizi birleştirilmiştir. Bu çalışmanın sonucuna göre BERT ve LSTM modellerinin hisse senedi fiyatlarını doğru bir şekilde tahmin ettiğini göstermektedir. BERT ve LSTM kullanılarak elde edilen başarı oranı %98.49 'dur.

Srinjoy G. Ve diğerleri [27] önerdiği çalışmada Lambeq Kuantum Doğal Dil İşleme (QNLP) araç seti kullanılarak ikili duygu sınıflandırmasının ilk uygulamasını göstermiştir. Bu uygulamanın gerçekleştirilmesi amacıyla üç sümilasyon yapılmış ve sümilasyonlardan biri olan gürültü kuantum boru hattı durumu için %83.3 doğruluk elde edilmiş olup fakat QNLP 'nin yeni bir alan olduğu ve kuantum avantajı elde edebilmek için çok fazla çalışmanın yapılması gerektiği vurgulanmıştır.

S. Li ve diğerleri [28] önerdiği çalışmada duygu analizi yöntemlerinin duygu sözcükleri arasındaki özellik etkileşimini göz ardı ettiğinden bahsetmiş ve bu sorunu çözebilmek amacıyla kuantum mekaniğini, derin öğrenmeyi ve doğal dil işleme teknolojisini birleştirmiştir. Bu çalışmada önerilen model, yoğunluk matrisini sinir ağı dil modeline uygulayan ve kuantum mekaniğini kullanan evrişimli sinir ağıdır modelidir. Modelin performansının test edilmesi amacıyla IMDB veri seti ve Weibo duyarlılık veri seti üzerinde test edilmiştir. Sonuçlara göre önerilen modelin IMDB veri seti üzerindeki başarı oranı %74.05, Weibo duyarlılık veri seti üzerindeki başarı oranı %71.45 'tir.

Fariska Z.R ve diğerleri [29] önerdikleri bu çalışmada, bir cümlelerin duygusunun kuantum doğal dil işlemede (QNLP) nasıl doğru ve verimli bir şekilde temsil edildiğini incelemekte ve önerilen dört yaklaşımdan bahsedilmektedir. Kuantum duygu sınıflandırma görevini gerçekleştirmek amacıyla öznel cümleler için uygun ve etkili bir kuantum temsili için formüle edilmiş ve olumsuz cümleler için kuantum kapılarından yararlanılmıştır. Sınıflandırmanın yapılabilmesi için restoran algılama veri kümesini SPSA, SVM ve ikisinin birleşimi kullanılarak eğitilmiştir. Deneysel sonuçlar, üçüncü yaklaşım ve SVM birleşik sınıflandırıcısıyla birlikte %81.87 doğruluğa ulaştığını göstermiştir. Tablo 1.2 ' de Literatür çalışmalarının karşılaştırılması verilmiştir.

Tablo 1. 2. Literatür karşılaştırılması

Referans	Veri Seti	Kullanılan Yöntem	Doğruluk Oranı (%)
[66]	Hintçe film incelemeleri	CNN	95
[67]	1) Stanford Twitter Duygu Testi Veri Seti 2) SemEval2014 Veri Seti 3) Stanford Twitter Sentiment Gold (STSGd) veri seti 4) Duyarlılık Değerlendirme Veri Seti 5)Sentiment Strength Twitter Veri Seti	Glove-DCNN	87.62
[68]	Urduca bloglar ve haber siteleri	LSTM BiLSTM CNN CLSTM	75.8
[69]	Twitter Verileri	KNN CNN	95
[70]	Film incelemeleri	SVM	87.6
[71]	Twitter Verileri	Bi-LSTM	81.33
[72]	Twitter Verileri	CNN+LSTM	59
[73]	Twitter Verileri	BERT	85.4
[74]	IMDB Dizi Yorumları	BERT+LSTM	93
[75]	Steam Oyun Yorumları	Bi-LSTM+CRF	95.2
[76]	Politika Haberleri	CNN+LSTM	70.46

1.2. Tezin Yapısı

Sağlık alanında sağlık verileri üzerinden kuantum hesaplama kullanan derin öğrenme tabanlı duygu analizi gerçekleştirmek amacıyla yapılan tez çalışması giriş bölümü dahil beş bölümden oluşmaktadır. Bölümlerin kapsamı aşağıda detaylı olarak verilmiştir.

Giriş bölümünde, Tez kapsamında çalışılan konudan ve karşılaşılan zorluklardan bahsedilmiş ve ilgili konuya yönelik Literatürde bulunan çalışmalar ve bu çalışmaların karşılaştırması verilmiştir.

İkinci bölümde, duygu analizi hakkında bilgilendirme yapılmış ve Karşılıklı Görüşmelerde Duygu Analizi yönteminden bahsedilmiştir. Önerilen çalışmanın test sonuçları değerlendirilmiştir.

Üçüncü bölümde, derin öğrenme hakkında detaylı bilgilendirme yapılmış ve derin öğrenme tabanlı duygu analizi yönteminden bahsedilmiş ilgili çalışmanın deneysel sonuçları ve başarısı değerlendirilmiştir.

Dördüncü bölümde, kuantum hesaplamanın tanımı yapılmış, Literatürde kuantum hesaplama tabanlı duygu analizi ilgili çalışmalardan bahsedilmiş ve önerilen yöntem, deneysel sonuçlara yer verilmiştir.

Beşinci bölümde tezin yapılma amacı, tez kapsamında önerilen yöntemlerin ve elde edilen sonuçların genel değerlendirmesine yer verilmiştir


2. KARŞILIKLI GÖRÜŞMELERDE DUYGU ANALİZİ

Duygu analizi, belirlenmiş bir konu hakkında kişilerin görüşlerinin, tutumlarının, yaklaşımlarının veya duygularının yazdıkları metinleri inceleyerek belirlenmeye çalışılmasıdır. Sağlık verileri üzerinde duygu analizi, tıbbi kayıtlardan ve doktor-hasta raporlarından duygu analizi ile sınıflandırma yapmaktır. Bu duygu analizinin gerçekleştirilmesi için derin öğrenme yöntemi olan Uzun Kısa Vadeli Bellek (LSTM) kullanılmıştır. LSTM modeli uzun metinleri işlemede oldukça başarılı bir derin öğrenme algoritmasıdır. Literatür incelendiğinde sağlık alanında çalışmalar mevcut ancak diğer alanlara göre daha az çalışmanın yapıldığı görülmüştür. Yapılan araştırmaların çoğunun sosyal medyadaki yorumlar üzerine olduğu görülmektedir. Bu çalışma, sağlık alanındaki tıbbi kayıtları ve doktor- hasta raporlarını duygu analizi ile sınıflandırarak sağlık alanına katkı sağlamayı amaçlamaktadır.

Tezin bu bölümünde sağlık alanındaki mevcut veriler üzerinde duygu analizi ile sınıflandırma yönteminden bahsedilmiş ve duygu analizi ile ilgili incelenen derin öğrenme tabanlı yöntemler ile karşılaştırma yapılmıştır.


2.1. Önerilen Yöntem

Bu çalışmada, sağlık alanındaki tıbbi kayıtlar ve metinler duygu analizi ile sınıflandırılmıştır. Model eğitimi için LSTM derin öğrenme modeli kullanıldı. Duygu analizinin gerçekleştirilmesinde ilk olarak metin işleme adımları gerçekleştirilir. Metindeki tüm kelimeler küçük harfe dönüştürülür, cümleler kelimelere bölünür ve kelime sıklığına göre tam sayı dizisine atılır. Bu işlemler yapıldıktan sonra işlenmiş metin elde edilir. Daha sonra üç iterasyondan oluşan LSTM model eğitime geçilir. Bu yinelemeler gerçekleşirken her yinelemedeki öğrenme oranı ve hata oranları çıktı olarak görülmektedir. Model eğitimi için verilerin %80'i eğitim ,%20' si test için kullanılmıştır. Eğitimi tamamlandıktan sonra modelin her seferinde eğitilmemesi için kaydedilir. Metinsel veriler modelin işleyebileceği formatta değildir. Bu verilerin sinir ağının anlayabileceği dijital formata dönüştürme gerekir. “Keras” kütüphanesinde bulunan fonksiyonlar bu dönüşümü sağlar. “Keras” içerisindeki “Tokenizer” sınıfı verilen cümlelerdeki kelimeleri çıkarmaktadır. Bu sınıfı kullanarak tüm kelimeler arasında en sık kullanılan kelimeye odaklanılır. Bu işlem modelin iş yükünü de azaltacaktır. Model eğitimi bittikten sonra girdi olarak sağlık alanında tıbbi kayıt veya rapor metni verilir ve o da metnin olumlu, olumsuz ya da tarafsız olduğuna dair bir çıktı üretir. Program bu sonucu üretirken aynı zamanda cümlelerin olumlu olumsuz yüzdesini de çıktı olarak üretir. Böylece verilen cümlelerin ne kadar olumlu ya da olumsuz olduğu öğrenilebilecektir. Şekil 2.1 ‘ de metni hazır hale getirmek için gerekli çalışma adımları verilmiştir. Bu adımları uyguladıktan sonra işlenen metin hazır hale gelmektedir.



Şekil 2. 1. Metni hazır hale getirmek için gerekli çalışma adımları

Metin hazır hale geldikten sonra modeli eğitmek gerekir. Model eğitimi için LSTM derin öğrenme modeli kullanıldı. LSTM, uzun vadeli bağımlılıkları öğrenebilen bir derin öğrenme algoritmasıdır. LSTM modeli, özyinelemeli ağ yapısında olmayan girdi, çıktı ve unutma katmanlarına sahiptir [30]. LSTM ‘ de bulunan unutma katmanı ağ üzerindeki verilerin unutulup unutulmayacağına karar vermektedir [31]. Bu çalışmada kullanılan modelin parametreleri; giriş katmanı, ikinci katman (LSTM) çıkış katmanı ve diğer katmanlardan oluşmaktadır. Giriş katmanındaki düğüm sayısı 128, dikkate alınması gereken kelime sayısı 25000, bırakma oranı 0,2’dir. İkinci katmanda (LSTM çıkışı) düğüm sayısı 128, bırakma oranı 0,2 ve bırakma ağırlığı 0,2dir. Çıkış katmanında düğüm sayısı 2, hata optimizasyonu, hata hesaplama kayıp fonksiyonu ve değerlendirme kriteri doğruluk değerleri bulunmaktadır. Diğer katman dediğimiz katmanda yineleme sayısı Epok 3’ve verilerin %80’i eğitim için %20’si test olarak belirlenmiştir. Katmanlardaki değerler verildikten sonra model eğitime geçildi Eğitim için işlenmiş metin alınır ardından test ve eğitim verileri ayrılır. LSTM katmanlı derin öğrenme modeli oluşturularak model eğitime başlanır, model sonucu elde edilir ve model kaydedilip sonlandırılır. Şekil 2.2 ‘ de model eğitimi için gerekli adımların blok diyagramı verilmiştir.



Şekil 2. 2. Model eğitimi için gerekli adımların blok diyagramı

Literatürde duygu analizi ile ilgili yapılan çalışmalar incelendiğinde sağlık alanına katkıda bulunacak çalışma görülmektedir. İncelenen çalışmalardan bazıları;

Sakarya ilinin belediye hizmetlerine yönelik atılan tweetlerden duygu analizi ile sınıflandırma yapılarak halkın yapılan çalışmalara karşı tutumları incelenmek istenmiş. Veri kümesinin %80'i eğitim %20 'si test için kullanılmıştır. Duygu analizi Turkish Bert yöntemi ile gerçekleştirilmiştir. Uygulamada makine öğrenme algoritmaları kullanılmıştır. Bunlar; Naive Bayes, Karar Ağacı, Rastgele Orman, Gradyan Arttırma' dır. En başarılı makine öğrenme algoritması Naive Bayes olduğu için bu yöntem seçilmiştir. Naive Bayes algoritmasının doğruluk oranının %90-%92 sonucuna ulaşılmıştır [7].

Çevrimiçi bir kitap sitesindeki kullanıcı yorumlarının duygu analizi ile sınıflandırılma yönteminde ilk olarak veriler çekilmiş daha sonra gerekli ön işlemler yapıldıktan sonra duygu sınıflandırılması yapılarak çıkan sonuçlar karşılaştırılmıştır. Veri setinin %90'ı eğitim %10 'u ise test için ayrılmış. Yorumların sınıflandırma sonucu pozitif veya negatiftir. Duygu sınıflandırılması Çok Katmanlı Algılayıcı (MLP) ile gerçekleştirilmiş olup veri seti Python kullanılarak ön işlemlerden geçirilmiştir. İşlenen veri seti RapidMiner'a aktarılarak Naive Bayes(NB), Destek Vektör Makineleri(SVM),Lojistik Regresyon(LR) algoritmaları kullanılarak test edilmiştir [24]. MLP, %89 başarı puanı ile en iyi sınıflandırmayı yapan algoritma oldu. Algoritmaların performans puanının %77,57 ile %89 arasında olduğu görülmektedir. Başarılarına göre sıralanırsa MLP, LR, DVM ve NB 'dir. MLP hem pozitif hem de negatif sınıflar için yüksek başarı sağlasa da olumsuz yorumları en iyi sınıflandıran algoritma olmuştur. LR algoritması MLP algoritmasına yakın sonuçlar vermiştir. SVM olumlu yorumlar için iyi olsa da olumsuz yorumların sınıflandırılmasında diğer algoritmaların gerisinde kalmıştır. NB algoritması diğer algoritmalarından farklı olarak olumsuz yorumların sınıflandırılmasında başarılı olmuştur fakat genel sınıflandırma başarısı diğer algoritmaların altında kalmıştır [32].

Sözlük tabanlı yöntemi ile Türkçe metinlerden duygu analizi gerçekleştirilmek amacıyla İngilizce ve Türkçe kelimelerin yer aldığı Afinn, Bing, Nrc ve Sentitürk sözlükleri bir araya getirilmiştir. Bir araya getirilen sözlükler değerlendirme yoluyla duygu analizindeki kutuplaşmaların belirlenmesi amaçlanmaktadır. Sistemin görevi kendisine sunulan metni oluşturan kelimeleri analiz etmek ve o metinde yer alan en baskın duyguya göre sınıflandırma yapmaktır. Duygu sınıflandırması yapmak için yöntem1 ve yöntem2 olmak üzere iki yöntem geliştirilmiştir. Bu yöntemler üç farklı veri setinde test edilmiştir. Yöntem2 tüm veri kümelerinde daha iyi sonuçlar vermiş olup % 88,57 ile en iyi sonuç 1. veri setinde elde edilmiştir. Genel başarı oranı %74,85 ile %88,57 arasında değişmektedir [33].

Twitter'daki finansal tweetlerin LSTM derin öğrenme algoritması ile duygu analizinin gerçekleştirildiği çalışmada ilk olarak veri seti oluşturulmuş ve veriler model eğitim için ayrılmıştır. Verilerin işlenebilmesi için pandas kütüphanesi, model eğitim için ise keras kütüphanesi

kullanılmıştır. Tweetlerin duyarlılık analizi ve EUR/USD kurlarının zamana dayalı veri seti oluşturulmuş ve kullanılmıştır. Veri seti hazırlandıktan sonra eğitim ve test için LSTM derin öğrenme modeli kullanılmıştır. Bu çalışma sonucunda LSTM ile %94,58 başarı oranı elde edilmiştir. Çalışma Twitter gibi sosyal medya platformlarındaki yorumlara duyarlılık analizi yapılarak yüksek oranda EUR/USD kapanış değeri tahmini yapılabilmektedir [31].

Literatür taramasında incelenen derin öğrenme ve sözlük tabanlı çalışmalardan bazıları Tablo 2.1 ' sunulmaktadır. Bu çalışmaların çoğu finans, sosyal medya yorumları, çevrimiçi alışveriş gibi alanlarda duygu analizi yapıldığı görülmektedir. İncelenen çalışmalar sonucunda en iyi başarı skorunu veren yöntemin LSTM derin öğrenme modeli olduğu görülmektedir.


Tablo 2. 1. Literatür taramasında incelenen çalışmaların değerlendirilmesi

Referans Numarası	Veri Seti	Uygulanan Yöntem Algoritma	Doğruluk Skoru
[7]	Belediye hizmet yorumları	Turkish Bert	%90-%92
[32]	Çevrimiçi kitap yorumları	MLP, LR, SVM, NB	%77,57-%89
[33]	Afınn,Bing,Sentitürk Sözlükleri	Sözlük tabanlı yöntem	%74,85-%88,57
[31]	Tweetlerin duyarlılık analizi ve EUR/USD oranları	LSTM	%94,58
[35]	Konuşma ve şarkı içeren ses dosyaları RAVDESS ve bununla birlikte TESS	CO-LSTM	%86,7
[34]	İlaç koleksiyonu	Bi-LSTM	%82-%90

2.2. Deneysel Sonuçlar

Duygu analizi sistemleri, canlıların yüzlerinden, seslerinden veya yazılarından duyguları analiz etmeyi ve tahmin etmeyi amaçlamaktadır. Duygu analizi ile ilgili çalışmaların çoğu sosyal medya platformlarındaki yorumlar üzerinden yapılmakta ve sağlık alanındaki tıbbi kayıtlar ve raporlara yönelik çalışma bulunmamaktadır. Bu çalışmada sağlık alanındaki tıbbi verilerden duygu analizi ile sınıflandırma yapma amacıyla LSTM derin öğrenme modeli kullanılarak bir yöntem geliştirildi. Bu yöntemde kullanılan veri seti 3649 adet örnek veriden oluşmakta ve ID numarası ve ait olduğu sınıfı içermektedir. Geliştirilen LSTM derin öğrenme modelinde, her kelimeye karşılık gelen 128 uzunluğunda bir vektör oluşturulur. Matris kelime sayısı ve yerleştirme boyutu olacaktır, yani 25 x 128 uzunluğundadır. Çıkış katmanı görsel olarak görüntülenirken yoğun katman kullanılır. Katmanlar oluşturulduktan sonra model eğitime geçilmiştir. Eğitim için işlenmiş metin

alınır, eğitim ve test verilerine ayrılır daha sonra LSTM katmanlı derin öğrenme modeli oluşturulur, eğitime başlatılır en son olarak model sonucu alınır ve kaydedilir. Eğitilen model sonucunda önerilen yöntemin başarı oranı %94 olduğu görülmüştür. Şekil 2.3 'te başarı oranına ait grafik yer almaktadır.



Şekil 2. 3. Önerilen modelin başarı skoru

Bu çalışma sağlık alanındaki tıbbi kayıt ve raporlar açısından oldukça önemlidir. Rapor içeriğinin olumlu, olumsuz veya tarafsız olduğunu bilmek tıbbi belgelerin ayrıştırılmasını sağlayacak ve hastanın duygusunu, tutumunu ne yönde olduğunu tespiti ile tedavi sürecini hızlandıracaktır. Elde edilen başarı skoru oldukça iyidir. Bu başarı skoru incelenen makale ve çalışmalar ile karşılaştırıldığında önerilen modelin oldukça iyi olduğu görülmektedir. İncelenen Literatür taramasında en iyi başarı skorunu veren yöntemin çok küçük bir yüzde ile önerilen modelden daha iyi sonuç verdiği görülmektedir. Tablo 2.2 'de Literatürde duygu analizi için yapılmış olan çalışmaların karşılaştırılması yer almaktadır. Sonuç olarak önerilen yöntemde sağlık alanındaki mevcut veriler duygu analizi ile olumlu, olumsuz ve nötr olmak üzere üç kutuplu olarak sınıflandırılmıştır. Duygu analizi LSTM derin öğrenme modeli kullanılarak gerçekleştirilmiş olup başarı oranı %94 'tür. Bu çalışma elde ettiği başarı skoruyla ve sağlık alanındaki veriler üzerinde duygu analizi gerçekleştirdiği için Literatüre katkı sağlamıştır.

Tablo 2. 2. Literatürdeki çalışmaların karşılaştırılması

Referans Numarası	Veri Seti	Uygulanan Yöntem	Sınıflandırma	Doğruluk Skoru
		Algoritma		
[34]	İlaç koleksiyonu	Bi-LSTM	Pozitif, Negatif	%82-%90
[35]	RAVDESS ve TESS	CNN-LSTM	Mutlu Kızgın Şaşırmış Üzgün Nötr, Korkulu, Sakin	%86,7
[7]	Belediye hizmet yorumları	Bert	Pozitif, Negatif	%90-%92
[32]	Çevrimiçi kitap yorumları	MLP, LR, SVM, NB	Pozitif, Negatif	%77,57-%89
[33]	Afınn,Bing,Sentitürk Sözlükleri	Sözlük yöntem	tabanlı Pozitif, Negatif	%74,85-%88,57
[31]	Tweetlerin duyarlılık analizi ve EUR/USD oranları	LSTM	Pozitif, Nötr, Negatif	%94,58
[30]	RAVDESS	CNN	Mutlu, Kızgın, Şaşırmış, Üzgün, Nötr, Korkulu, Sakin	%82
[36]	Arapça SA	Bert	Pozitif, Negatif	%76
Önerilen yöntem	Sosyal medya, sağlık metinleri	LSTM	Pozitif, Negatif, Nötr	%94

3. DERİN ÖĞRENME KULLANAN DUYGU ANALİZİ YAKLAŞIMI




Çalışma mantığı olarak insan beynini örnek olarak tasarlanan yapay sinir ağları, insan beyninin öğrenme işlevlerinin hiçbir yardım almadan bilgisayar tarafından otonom olarak gerçekleştirilebilen sistemlerdir. Yapay sinir ağının oluşturulma amacı bilgiyi insan gibi analiz etmek ve bu bilgiyi kullanabilmektir. Yapay sinir ağlarının temeli olarak kabul edilen ilk çalışma Warren tarafından 1943 yılında ortaya atılmıştır. İlk defa insan beynine benzeyen bir yapı oluşturan Warren araştırmaları sonucunda tek bir sinir hücresinin problem çözümü için yeterli olmadığını ve daha kullanışlı olabilmesi için birden fazla sinir hücresinin birlikte kullanılması gerektiği sonucuna ulaşmıştır [37].

Yapay zekânın kullanılmaya başlandığı ilk yıllarda mantık problemlerini çözmede gayet yeterli olsa da daha karmaşık olan yüz tanıma doğal dil işleme gibi karmaşık problemlerin çözümünde oldukça eksik kalmıştır. Bu sorunlara binaen yapay zekânın alt dalları olan makine öğrenimi ve derin öğrenme gibi yöntemler geliştirilmiştir [38]. Derin öğrenme birçok alanda kullanılmaktadır bu alanlardan bir tanesi doğal dil işlemenin alt dallarından biri olan duygu analizidir. Metin veya ses verileri üzerinden derin öğrenme algoritmaları kullanılarak duygu analizi gerçekleştirilmekte ve elde edilen sonuçlardan bilgi çıkarımı yapılmaktadır. Eğitim ve test sonuçları derin öğrenme algoritmalarının kullanımının yüksek doğrulukta sonuçlar verdiğini göstermektedir.

Tezin bu bölümünde ilk olarak derin öğrenmenin tanımı, kullanım alanı ve ne tür modeller içerdiğinden bahsedilmiştir. Daha sonra derin öğrenme tabanlı duygu analizi yaklaşımından bahsedilmiştir.


3.1. Derin Öğrenme

Derin öğrenme, yapay sinir ağlarını kullanan bir makine öğrenmesi yöntemidir. Derin öğrenme 1943 yılında Warren McCulloch ve Walter Pitts'in matematik ve sinir bilimini birleştirerek algoritma ve hesaplamalara dayandırarak oluşturmuştur. Derin öğrenme insan beyninin bir veriyi öğrenme sürecini matematiksel olarak anlamlı ve bir bütün şeklinde ifade edilmesine dayanır. Makine öğrenmesinden farkı ise derin öğrenmede sisteme eğitilmiş bir veri girişi yapılmaması ve yapay sinir ağı yapısında gizli katmanların bulunmasıdır [37]. Şekil 3.1.' de Yapay sinir ağı ile derin öğrenmenin yapısı gösterilmektedir [39]. Şekil 3.2 ' de yapay zeka, derin öğrenme ve makine öğrenmesi arasındaki ilişki gösterilmektedir [40]. Şekil 3.3 ' te makine öğrenmesi ve derin öğrenmenin arasındaki fark gösterilmiştir [41].



3.2. Konvolüsyonel Sinir Ağları (CNN)

Konvolüsyonel sinir ağları, bir girdideki görüntüleri algılayıp nesneleri birbirinden ayıran ve sınıflandıran derin öğrenme algoritmalarındandır. Şekil 3.4 ' te konvolüsyonel sinir ağı mimarisi gösterilmiştir [42]. Nesne tanıma, görüntü işleme, bilgisayarla görme, yüz ve ses tanıma, doğal dil işleme gibi çeşitli alanlarda kullanılmaktadır. Konvolüsyonel sinir ağları, manuel olarak özellik oluşturmak yerine, daha sonra sınıflandırma için kullanılabilecek bir özellik hiyerarşisini otomatik olarak öğrenmek için kullanılır. Bunu yaparken, giriş görüntüsünü öğrenilen filtrelerle yinelemeli olarak konvüle ederek bir özellik hiyerarşisi oluşturur. Hiyerarşik yöntem sayesinde üst katmanlar, bozulmadan etkilenmeyen ve daha karmaşık özellikler öğrenebilir.



Şekil 3. 4. CNN mimarisi [42]


3.3. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları, yapay sinir ağında düğümler arasındaki bağlantının bir döngü oluşturulmasıdır. RNN'ler tekrarlayıcı sinir ağları olduğu için her dizinin çıktısı bir önceki hesaplamaya bağlıdır. RNN Sıralı verileri veya zaman serisi verilerini kullanan bir derin öğrenme algoritmasıdır. Bu algoritma, dil çevirisi, doğal dil işleme, konuşma tanıma ve resim yazısı ekleme gibi sıralı veya zamansal problemler için yaygın olarak kullanılmaktadır. Yinelenen sinir ağları da , ileri beslemeli ve CNN gibi öğrenmek için eğitim verilerini kullanır. Önceki girdilerden bilgi almak için hafızalarını kullanırlar. Geleneksel derin sinir ağları girdi ve çıktıları birbirinden bağımsızdır . Tekrarlayan sinir ağı geleneksel derin sinir ağlarından farklı olarak çıktı önceki öğelerden etkilenir. RNN'ler tekrarlayıcı sinir ağları olduğu için her dizinin çıktısı bir önceki hesaplamaya bağlıdır. Diğer ayırt edici özelliklerinden biride, ağı her katmanında parametleri paylaşmasıdır.

3.3.1 Uzun Kısa Vadeli Bellek Ağları (LSTM)

LSTM, derin öğrenme alanında kullanan bir tekrarlayan sinir ağı modelidir ve bu fikir 1997 yılında Hochreiter ve Schmidhuber tarafından sunulmuştur. Bilgiyi uzun süre hafızada tutan LSTM uzun süreli bağımlılık sorununu çözmek için tasarlanmıştır. Genel bir LSTM ağı zaman verilerine

bakarak verilere sınıflandırmak ve tahminler yapmak için verimlidir. LSTM 'lerin hafıza birimlerini hücreler denilmekte ve bunlar bir önceki durum ve o anki girişi girdi olarak alırlar. Bu hücreler hangi verinin tutulup, hangisinin silineceğine karar verirler. Bundan sonraki aşaması eldeki verileri birleştirmektir. Bu yöntemin çok kullanılmış olduğu yapılan çalışmalarda kanıtlanmıştır. Şekil 3.5 ' te LSTM hücresinin yapısı gösterilmiştir [43].



Şekil 3. 5. LSTM hücre yapısı

LSTM mimarisi genel olarak öncelikle giriş kapısı, çıkış kapısı, bellek hücresi ve unutma kapısı olmak üzere dört bileşenden oluşur. Bu katmanlar aşağıda kısaca açıklanmaktadır:

Bellek Hücresi: Belirli hücrelerin silinmesini sağlayan belirli bir zaman periyodunu ve durum eklemenin her değerini saklayabilen hücredir.

Giriş Kapısı: Dahili hücre durumuna yazılan girdinin boyutunu düzenler.

Çıkış Kapısı: Burada mevcut olandan hangi çıktının, yani gizli durumun üretileceğini belirler.

Unutma Kapısı: Önceki çıkışın unutulacağı miktarı belirler

3.4. Sınıflandırma Ölçütleri

Sınıflandırma modellerinin yapmış olduğu tahminlerin performansını değerlendirmek için çeşitli sınıflandırma ölçütleri kullanılmaktadır. Bu ölçütler n sınıf sayısı için nxn boyutundaki karışıklık matrisindeki değerlerden hesaplanır ve doğruluk, kesinlik, duyarlılık ve F1–skor sıklıkla kullanılan sınıflandırma ölçütlerindedir. Karışıklık matrisi örneği Tablo 3.1' de verilmiştir.

Tablo 3. 1. Karışıklık Matrisi Örneği

Pozitif	Negatif	Tahmin Sınıf
DP	YN	Pozitif
YP	DN	Negatif

Karışıklık matrisinde, DP doğru tahmin edilen Pozitif sayısını, DN doğru tahmin edilen Negatif sayısını, YP yanlış tahmin edilen Pozitif sayısını ve YN yanlış tahmin edilen Negatif sayısını göstermekte ve ölçütler bu değerler kullanılarak hesaplanmaktadır.

Doğruluk (Accuracy), denklem (3.1) ' de verilen doğruluk ölçütü, doğru pozitif ve doğru negatif örnek sayısının (DP+DN) tüm örnek sayısına (DP+DN+YP+YN) oranı ile hesaplanır ve sınıflandırmanın genel başarısını gösterir

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.1)$$

Kesinlik (Precision), denklem (3.2) ' de verilen kesinlik ölçütü, doğru pozitif örnek sayısının (DP), doğru pozitif ile yanlış pozitif örnek sayısının toplamına (DP+YP) oranı ile hesaplanır. Doğru tahmin edilen değerlerin gerçekte kaçının doğru olduğunu gösterir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.2)$$

Duyarlılık (Recall), denklem (3.3)' de verilen duyarlılık ölçütü, Doğru pozitif örnek sayısının (DP) doğru pozitif ile yanlış negatif (YN) örnek sayısı toplamına (DP+YN) oranı ile hesaplanır. Doğru tahmin edilmesi gereken örneklerin kaçının doğru tahmin edildiğini gösterir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.3)$$

F1-skor (F1-score), denklem (3.4) ' de verilen f1 ölçütü duyarlılık ile kesinliğin harmonik ortalaması ile hesaplanır.


$$f1\text{skor} = \frac{2*\text{duyarlılık}*\text{kesinlik}}{\text{duyarlılık}+\text{kesinlik}} \quad (3.4)$$

3.5. Derin Öğrenme ile Hastanelerdeki Hasta İncelemelerine Yönelik Duygu Analizi

Duygu analizi, metin veya konuşmanın duygusunu, tutumunu keşfetmeyi amaçlayan doğal dil işleme (NLP) uygulamasıdır. Duygu analizi birçok alanda kullanılmış ve oldukça başarılı sonuçlar elde edilmiştir. Bu alanlardan bir tanesi de Sağlık sektörüdür. Sağlık çalışanlarının, hastaların tıbbi incelemeleri yönetim departmanı için önemlidir. Dolayısıyla bu incelemelerin değerlendirilmesi de yöneticiler için oldukça önemli bir geri bildirim sağlamaktadır.

3.5.1. Önerilen Yaklaşım


Bu çalışma, hastaların hastane incelemelerine ait tıbbi belgeler üzerinden duygu analizi gerçekleştiren sinir mimarisi geliştirilmiştir. Veri kümesi olarak İngiliz hükümetinin açık veri platformundan elde edildi [44]. Bu veri kümesi hastanelere ilişkin olumlu ve olumsuz hasta değerlendirmelerini içermektedir ve veri setinde 13772 satır bulunmaktadır. İlk olarak metin verileri üzerinde ön işleme adımları gerçekleştirilmesi gerekir. Daha sonra önceden işlenmiş verilerden skipgram sözcük yerleştirme yöntemi uygulanır. Son olarak verileri eğitim için farklı sinir mimarilerine gönderilir ve model metinleri olumlu ya da olumsuz olarak sınıflandırır. Şekil 3.6 'da önerilen yönteme ait blok diyagram gösterilmiştir.



Şekil 3. 6. Önerilen yöntemin akış diyagramı


- A. Ön İşleme: Bu adımda metin verilerinin ilk olarak küçük harf dönüşümü gerçekleştirilir. Daha sonra metin verilerindeki tüm noktalama işaretleri kaldırılır. Noktalama işareti kaldırıldıktan sonra durdurma verileri kaldırılır. Son olarak kısaltmalar orijinal hallerine dönüştürülür.

B. Skipgram Kelime Gömmelerin Elde Edilmesi: Skipgram kelime yerleřtirmenin elde edilmesi denetimsiz öğrenme yöntemidir ve bunun için bir sinir ağı kullanılmaktadır. Bu sinir ağlarının giriři tek sıcak kodlanmış kelimeyken çıkıřı ise giriř penceresiyle aynı kelimedeki bulunan kelimelerdir. Gömmeler, bu girdi kelimeyle istenilen çıktıyı elde etmek için sinir ağı tarafından optimize edilen ağırlıklardır. Şekil 3.7 ‘de kelime gömme yönteminin blok diyagramı verilmiřtir.



Şekil 3. 7. Skipgram kelime yerleřtirme yöntemi

C. Sinir ağı Oluřturma ve Eđitimi: : Dört farklı sinir ağı oluřturuldu ve eđitildi. İlk sinir ağı yoğun ve tamamen bađlantılı bir sinir ağıdır. İkinci sinir ağı CNN ve yoğun sinir ağıdır. Üçüncüsü ise LSTM ve yoğun sinir ağıdır. Dördüncü sinir ağı LSTM, CNN ve yoğun sinir ağıdır. Şekil 3.8 ‘de kullanılan sinir mimarilerinin yapısı gösterilmektedir.



Şekil 3. 8. Sinir Mimarileri (a:CNN, b:LSTM, c:Dense, d:CNN-LSTM)

3.5.2. Deneysel Sonuçlar

Hastanedeki hastaların incelemelerini içeren raporlar, hizmeti alan kişilerin Bu çalışmada daha önce de belirtildiği gibi CNN, LSTM ve Dense katmanlarından oluşan dört farklı sinir ağı eğitildi. İngiliz hükümetinin açık veri platformundan elde edilen hastanelere ilişkin değerlendirmelerden oluşturulan veri seti 13772 satırdan oluşmakta ve hastane yöneticilerine de tavsiyeler bulunmaktadır. Bu verilerin %88 ‘i eğitim, %2 ‘si test, %10’u ise doğrulama için ayrılmıştır. Veriler işlenmeden önce bir kısıtlanma kullanıldı bu kısıtlamaya göre incelenen metinlerdeki kelime sayısının 5 ile 50 arasında olması gerekir. Tablo 3.2 ‘ de sinir mimarilerinin eğitim ve doğrulama başarıları gösterilmiştir.

Tablo 3. 2. Sinir mimarilerinin eğitim ve doğrulama başarıları


Model	Eğitim Kaybı	Eğitim Başarısı	Doğrulama Kaybı	Doğrulama Başarısı
Dense	0.3279	0,8466	0.8459	0,774
CNN	0.2565	0.8934	0.3492	0.8475
LSTM	0.2178	0.9057	0.2980	0.8796
CNN-LSTM	0.2410	0.8966	0.2746	0.8947

Bu çalışmada oluşturulan modellerin performansını değerlendirmek için denklem (3.1), (3.2) ve (3.4) kullanılarak kesinlik, duyarlılık ve f1- skor ölçümleri hesaplanmıştır. Her mimariye


ait elde edilen hesaplama sonuçları Tablo 3.3’ te verilmiştir. Şekil 3.9 ‘ da Dense mimarinin eğitim, doğrulama doğruluğu ve kaybına ait grafik gösterilmektedir. Şekil 3.10 ‘ da CNN mimarisinin eğitim, doğrulama doğruluğu ve kaybına ait grafik gösterilmektedir. Şekil 3.11 ‘ de LSTM mimarisinin eğitim, doğrulama doğruluğu ve kaybına ait grafik gösterilmektedir. Şekil 3.12 ‘ de CNN-LSTM mimarisinin eğitim, doğrulama doğruluğu ve kaybına ait grafik gösterilmektedir. Sonuç olarak bu çalışmada hastanedeki hastaların değerlendirmeleri için bir duygu analizi yöntemi geliştirildi. Yorumları olumlu ve olumsuz olarak sınıflandıran 4 farklı sinir ağı modeli oluşturuldu. Bu modellerin transfer öğrenimi gerçekleştirmek amacıyla Skipgram kelime yerleştirmeleri eğitildi. Oluşturulan sinir mimarilerinden %89’ un üzerinde performansa sahip LSTM- CNN mimarisiyken en kötü performansı ise yoğun mimarili sinir ağı(%53,91)gösterdi.

Tablo 3. 3. Sinir mimarilerinin performansının karşılaştırılması

Model	Kesinlik(%)	Duyarlılık(%)	F1-Skor (%)
Dense	56.84	52.17	53.91
CNN	84.21	82.47	83.17
LSTM	89.47	87.62	87.42
CNN-LSTM	99.52	88.99	89.51




(a)




(b)

Şekil 3. 9. Dense mimarinin eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir.




(a)




(b)

Şekil 3. 10. CNN mimarinin eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir.




(a)




(b)

Şekil 3. 11. LSTM mimarinin eğitim ve doğrulama kaybı (a) ve başarısı(b) gösterilmiştir.



(a)



(b)

Şekil 3. 12. CNN-LSTM mimariye ait eğitim ve doğrulama kaybı (a) ve başarısı (b) gösterilmiştir

4. KUANTUM HESAPLAMA TABANLI DUYGU ANALİZİ

Kuantum hesaplama kuantum mekaniğini temel alarak ve kuantum üstünlüklerinden faydalanan bilgi işleme yöntemlerini kapsayan bir çalışma alanıdır. Bu amaçla süper iletken devreleri, fotonik, iyon tuzağı, optik ve kuantum tavlama tekniklerini kullanan bilgisayarlar geliştirilmiştir. Yarı iletken teknolojisini kullanan klasik bilgisayarlar oldukça güçlüdür. Teknolojinin gelişmesiyle yapay zeka, makine öğrenmesi ve derin öğrenme gibi alanların yaygın şekilde kullanılmaya başlaması sonucu bu alanlar için klasik bilgisayarların kullanımı fazla zaman ve yüksek enerji maliyetine yol açmaktadır.

Kuantum hesaplamanın duygu analizine uygulanabilmesi birçok sektör için önem arz etmektedir. Bu sayede klasik bilgisayarlar ile yapılan ve uzun zaman ve enerji maliyetine sahip olan işlemler kuantum hesaplama ile kolayca yapılabilir. Kuantum hesaplama ile zaman ve enerji maliyetinin minimuma indirilebiliyor olması diğer birçok alanda da kuantum hesaplama yönteminin kullanılmasına sebep olmuştur. Literatürde birçok yöntemle duygu analizi çalışması bulunmaktadır fakat kuantum hesaplama ile çalışabilen duygu analizi ile ilgili çalışmalar pek mevcut değildir. Kuantum hesaplamanın avantajları, klasik duygu analizi yöntemi ile birleştirilip hibrit bir yapı oluşturulmuştur.

Günümüzdeki yapay zeka, makine öğrenmesi, derin öğrenme ile NLP, görüntü işleme, bilgisayar görmesi ve veri sınıflandırma gibi yöntemlerin kuantum hesaplama ile veya hibrit olarak kullanılmasının büyük avantajlar sağlayacağı göz önündedir [45]. Bu çalışmada doktor-hasta diyaloglarından duygu analizi yapılarak hastaların memnuniyeti, tanı-teşhisin doğru ve hızlı bir şekilde tamamlanabilmesi amacıyla kuantum hesaplama ve derin öğrenmenin kullanıldığı hibrit bir yöntemle başvurulmuştur. Kullanılan yöntem ile kuantum üstünlüklerini derin öğrenme mimarisi ile birlikte kullanılarak daha verimli bir yapı oluşturulmuştur.

Tezin bu bölümünde ilk olarak kuantum hesaplamanın tanımı ve yapısından bahsedilmiştir. Ardından Literatürde kuantum hesaplama ile duygu analizi gerçekleştirilen çalışmalara yer verilmiş ve karşılaştırma yapılmıştır. En son olarak kuantum hesaplama tabanlı duygu analizi yaklaşımından bahsedilmiş ve deneysel sonuçlarına yer verilmiştir.

4.1. Kuantum Hesaplama


Kuantum mekaniğini temel alan kuantum hesaplamanın temelleri 1980'lerin başında Richard Feynman tarafından atılmıştır. En büyük avantajı paralel olarak çok hızlı çalışıyor olmasıdır. Kuantum mekaniğinin üstünlükleri olan kuantum dolanıklığı ve süperpozisyonu da barındırır. Süper bilgisayarın dahi uzun yıllarda çözebileceği problemleri birkaç dakikada çözebilmesi büyük ilgi uyandırmaktadır. Süper iletken, fotonik, iyon ve tavlama gibi farklı

altyapılara sahip kuantum bilgisayar modelleri mevcuttur [46]. Günümüzde de klasik bilgisayarlar için Moore yasasının sınırlarına ulaşılmasıyla kuantum hesaplama daha da önem kazanmaya başlamıştır. Kuantum hesaplama makine öğrenmesi, optimizasyon ve kriptografi gibi alanlarda sıkça kullanılmaya başlanmıştır. Kuantum hesaplamada en dikkat çeken algoritmalar Shor ve Grover algoritmalarıdır [47]. Bu algoritmalar kuantum hesaplamanın üstünlüğü kullanarak çok hızlı bir şekilde veriseti içerisinde arama yapabilmekte ve verilen sayının faktöriyelini hesaplayabilmektedir. Kuantum algoritmaları programlanması amacıyla Qiskit, Ocean, Q#, QuTiP, Pennylane ve Cirq gibi simulatörler kullanılmaktadır [48]. Bunların haricinde fiziksel kuantum bilgisayarların araştırmacılar tarafından kullanılabilmesi amacıyla kuantum bilgisayar üreticileri bulut sistemler ile erişim hizmeti de vermektedir. Bulut altyapısını sağlayan firmalardan önde gelenleri IBM, Google ve Microsoft'tur.

Klasik bilgisayarlarda veriler 0 ve 1'lerden oluşan bitler ile ifade edilmektedir. Kuantum bilgisayarlarda ise veriler superpozisyon halinde hem 0 hemde 1 durumunu kapsayacak şekilde işlenir [49]. Bu durum kuantum mekaniğinin en temel özelliğidir. Kuantum bilgisayarların gücü kübit sayısı ile sınırlıdır. Günümüzde ise maksimum kapasite olarak IBM firmasının üretmiş olduğu IBM Osprey modeli 433 kübitişlem kapasitesine sahiptir [50]. Kuantum bilgisayar ile 2^n adet durum ifade edilebilmektedir. IBM Osprey ile 2^{433} durum ifade edilebilmektedir.

Klasik bilgisayarlarda işlenebilen veriler doğrudan kuantum bilgisayarlarda işlenememektedir. Bunun için klasik verilerin kuantum verilere dönüştürülmesi gerekmektedir. Klasik verinin kuantum verilerini dönüştürülmesi amacıyla baz, genlik, açısız, IQP ve Hamiltonian Ansatz gibi kullanılan yöntemler vardır [51-52]. Bu uygulamadaki veriler genlik kodlama ile yöntemi ile dönüştürülmüştür. Bu sayede verilerin kuantum hesaplama temsili matematiksel, geometrik ve tensor olarak gerçekleştirilebilecektir. Kuantum bitlerini geometrik olarak temsil etmek amacıyla Bloch küresi ve matematiksel olarak temsil etmek amacıyla Dirac(bra-ket $\langle | \rangle$) notasyonu kullanılır [53]. Dirac notasyonunda kübitler $|0\rangle$ ve $|1\rangle$ şeklinde ifade edilir. Denklem 4.1'deki c , 0 değerinin olasılığını ve β ise 1 değerinin olasılığını temsil etmektedir. Bu olasılıkların karelerinin toplamı $|\alpha|^2 + |\beta|^2 = 1$ olmalıdır [54]. Bloch küresi ile kübitlerin gösteriminin örneği Şekil 4.1 'te mevcuttur [55]. Bloch küresi gösteriminde ise X,Y ve Z den oluşmak üzere üç eksen vardır. Vektörel olarak ifade edilen kübitlerin değerlerine bu eksenler üzerinde döndürme işlemleri uygulanarak kübitlerin reel, imajiner ve açısız değerleri temsil edilir.

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (4.1)$$



Şekil 4. 1. Bloch küresi gösterimi [55]

4.1.1. Tekli Kuantum Mantık Kapıları

Kuantum hesaplamada da klasik bilgisayarlardaki mantık kapıları gibi kuantum mantık kapıları bulunmaktadır. Bu kapılar ile kubitlerin değerlerine vektörel işlemler uygulanarak durumları değiştirilebilir. Bu temel kapılar Tablo 4.1 'de verilmiştir. Kapıların matematiksel karşılıkları olarak matris formları da verilmiştir. Bu kapıların gerçekleştirdiği işlemler aşağıdaki gibidir.

Pauli X Kapısı X ekseninde döndürme işlemi yapar. NOT kapısı olarak da bilinen bu kapıyı giriş olarak aldığı kubit değeri tersine çevirerek çıkış olarak verir. Tek giriş ve tek çıkıştan oluşmaktadır. $|0\rangle$ durumundan $|1\rangle$ durumuna geçişi sağlar.

Pauli Y Kapısı Pauli X kapısı gibi tek giriş ve tek çıkıştan oluşan bu kapı, Y ekseninde π derece kadar döndürme işlemi yapar.





Pauli Z Kapısı Pauli X ve Y kapısı gibi tek giriş ve tek çıkıştan oluşur ve Z ekseninde π derece kadar döndürme işlemi yapar.

Hadamard Kapısı Tek giriş ve tek çıkıştan oluşmakta olup giriş olarak aldığı kubit X ve Z ekseninde döndürme işlemi yaparak süperpozisyon durumuna getirmektedir.

Swap Kapısı Giriş olarak iki kubit değeri alır ve kubitlerin değerlerini birbirini ile değiştirir. Çıkış olarak değiştirilmiş iki değeri geri verir. $|10\rangle$ durumundan $|01\rangle$ durumuna geçişi sağlamaktadır.

CNOT Kapısı Giriş olarak aldığı iki kubitte ilkinin değeri 1 ise ikinci kubitin değerini tersine çevirmektedir. Eğer ilk kubitin değeri 0 ise ikinci kubitte işlem yapılmaz.

Tablo 4. 1. Temel kuantum mantık kapıları ve matris formları

Kapı Adı	Kapı Sembolü	Matris Formu
Pauli X		$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$
Pauli Y		$\begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$
Pauli Z		$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$
Hadamard		$\frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$
Swap (2 kubit)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$
CNOT (2 kubit)		$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$

Kuantum hesaplamanın başlangıcı 1981 yılında Richard Feynman'ın kuantum mekaniğinin hesaplama amacıyla kullanılabileceğini öne sürmesiyle başlamıştır. Tablo 4.2' de kuantum hesaplamanın tarihsel gelişimi verilmiştir [54].


Tablo 4. 2. Kuantum hesaplamanın tarihsel gelişimi [54]

Tarih	Gerçekleşen Gelişim
1981	Richard Feynman Kuantum hesaplamanın avantajlarına dikkat çekiyor
1994	Peter Shor kuantum hesaplama ile asal çarpanlara ayırma algoritması geliştirdi
1996	Lov Grover kuantum hesaplama ile arama algoritması geliştirdi
2001	Peter Shor kuantum teorisini baz alan çeşitli algoritmalar yürüttü
2007	D-Wave kuantum hesaplama ile Sudoku bulmacalarını çözebileceğini duyurdu
2009	Yale ilk 2 kubitlik süperiletken çipini geliştirdi
2011	D-Wave kuantum bilgisayarını ilk defa ticari kullanıma sundu
2016	Peter Shor algoritmasının verimliliği artırıldı
2019	Transistörler ve yarıiletkenler kullanılarak kuantum devresini bas alan algoritmalar çalıştırıldı IBM 53 kubitlik kuantum bilgisayarını geliştirdi
2020	Kuantum uygulamaların prototiplenmesi ve sunulması

	Kuantum bilgisayarların basitçe nasıl programlanabileceği açıklandı
2021	Kuantum uygulamalar 100 kat daha hızlı çalıştırıldı Hata azaltmaları ve Hata düzeltmelerinde iyileştirmeler yapıldı Çin iletişim için kuantum ağlarını kullanmaya başladı
2022	Devre çeşitliliğini artırmak için dinamik devreler kullanılmaya başlandı IBM 433 kubitlik kuantum bilgisayarı geliştirdi
2023	Bulut altyapısı ile kuantum uygulamalar çalıştırılmaya başlandı

4.2. Kuantum Makine Öğrenmesi

Kuantum hesaplamayı kullanarak yapılan makine öğrenmesi uygulamalarına verilen genel isimdir. QML uygulamalarında varyasyonel kuantum devreler (VQC) kullanılmaktadır. Varyasyonel kuantum devreler, sinir ağlarındaki gibi ağırlıklar gibi, parametreler almaktadır [56]. Literatürde parametrelili kuantum devre ve kuantum sinir ağı olarak da bilinmektedir. VQC'ler klasik bir bilgisayar tarafından optimize edilen parametrelere sahip kuantum-klasik hibrit bir yaklaşımdır [57]. Klasik bir sinir ağı ile VQC'nin yapısı Şekil 4.2 ' de verilmiştir.




Şekil 4. 2. Klasik Sinir Ağı ve VQC [58]

4.2.1. Kuantum Makine Öğrenme Algoritmaları

- A. Kuantum K-En Yakın Komşu: KNN algoritmasının çalışma mantığı iki veri noktası arasındaki mesafe olan Öklid mesafesine dayalı olarak verileri sınıflandırmaktır. Veri kümesini çeşitli farklı sınıflara ayırır, test için yeni bir değer girildiğinde algoritma girilen yeni değere en yakın K değerlerini seçer. Veri kümesine girilen satır sayısının karaköku K değerini vermektedir. Algoritma, en yakın k değer arasından veriye en yakın maksimum k nokta sayısını bularak yeni verinin hangi sınıfa en çok benzediğine karar verecektir. Klasik bilgisayarda bu algoritma her yeni girilen veri için hesaplama yapması gerektiğinden oldukça fazla bellek ve zaman alır. Kuantum hesaplama kullanılırsa [60]. Kuantum algoritmalar için kolaylık sağlayan hamming mesafesi, iki bitin farklı olduğu bit konumlarının sayısı kullanır. Kuantum K-En Yakın Komşu algoritması (QKNN) verileri

depolamak için kubitler kullanır. Bu da knn algoritmasının çözülmesini sağlar ve kubitlerin dolaşık durumda olmasıyla algoritmanın karmaşıklığını büyük miktarda azaltabilir. Kubitler süperpozisyon durumuna getirildiğinde, aynı anda farklı durumlarda olabilirler, bu da hesaplama süresinden tasarruf etmeyi sağlar ve ayrıca daha az kubit olduğunda algoritma daha verimli hale gelir.

B. Kuantum Destek Vektör Makinesi: Kuantum Destek vektör makinesi, hesaplama görevlerini yerine getirmek amacıyla bir kuantum kurallı kullanan Destek Vektör Makinenin kuantum versiyonudur. DVM sınıflandırma ve regresyon için kullanılan verileri analiz eden modellerle ilişkili olan ancak esas olarak sınıflandırma problemleri için kullanılan denetimli öğrenme modelidir [63]. Destek vektör makineleri, bir veri kümesinin veri noktalarını alır daha sonra farklı sınıfları/grupları en iyi ve en doğru biçimde ayıran ve bir çizgi olan hiper düzlemi çıkarmaktadır. “Klasik verileri kuantum durumlarına dönüştürmek ve ardından kuantum durumlarını kullanarak çekirdek matrisi oluşturmak için kuantum özellik haritaları kullanılmaktadır. Şekil 4.3 ‘ te destek vektör makinesi sınıflandırma örneği verilmiştir.




Şekil 4.3. X1 ve X2 değişkenlerine bağlı doğrusal destek vektör makinesi sınıflandırma örneği [77]

C. Kuantum Rastgele Orman: Rastgele orman algoritmasının çalışma mantığı birden fazla karar ağacı oluşturma ve bunları birleştirerek hassasiyeti artırarak bireysel karar ağaçlarından daha doğru sonuç verme mantığına dayanmaktadır. Rastgele orman, ön yükleme, ortalama oylama, bootstrapping gibi çeşitli yöntemler kullanır. Rastgele orman algoritmasının kuantum versiyonu yapılandırılmamış bir arama problemini kuadratik olarak hızlandırabilen Groverin arama kuantum algoritmasına dayanan kuantum genlik amplifikasyon algoritmasını kullanır. Kuantum rastgele orman algoritması, her ağaçta bir girdi nesnesini paralel olarak test etmeyi sağlar.

D. Kuantum Karar Ağacı: Sınıflandırma ve regresyon için kullanılan karar ağaçları, popüler veri madenciliği ve denetimli makine öğrenimi algoritmasıdır. Ağacın her bir düğümü veri kümesinin bağımsız değişkenleri olan özellikleri temsil ettiği, ağacın dalının bir kararı temsil ettiği ve yaprak düğümleri ise ağacın son düğümlerini temsil ettiği ters çevrilmiş bir ağaçtır [61]. Karar ağacı sınıflandırıcısı, analitik olarak veya uzmanlardan edinilen nesneler hakkında gözlemler içeren bir eğitim veri kümesinden öğrenir. Karar ağacında, düğümlerin olasılıklarını hesaplayarak ağaçta aşağı doğru inilir. Ancak karmaşık veri kümelerinde bu görev klasik bilgisayarlar için hem sıkıcı hem de zaman alıcıdır, diğer yandan vektör biçiminde temsil edilen kubitleri kullanan kuantum karar ağacı kullanılırsa kubitlerin dolaşması, kolayca iletişim kurması ve tersine çevrilebilirliği daha hızlı olmasından dolayı hesaplama işlemi çok daha hızlı olacaktır.


E. Kuantum Lojistik Regresyon: Lojistik Regresyon, makine öğreniminde esas olarak sınıflandırma problemlerini çözmek için kullanılır. Çıktı ya bölünecek ya da kategorilere ayrılacaktır. Lojistik regresyonda, bağımsız ve bağımlı değişkenler arasında eğim olan bir ilişki bulunur. Doğrusal regresyonda eğim düz çizgi değil 's' şeklindedir. Bu şekil 0' dan 1' e doğru hareket eder bu da verilerin bir gruba ait olup olmadığını gösterir. Ağır hesaplamaları çözmek için kuantum kullanmak daha az zaman karmaşıklığı yaratır [62]. Kuantum Bilgisayarlar doğrusal regresyon modelinin hesaplama verimliliğini artırır. Şekil 4.4 te kuantum uyarlamalı, hibrit kuantum ve kuantum algoritmalar verilmiştir.



Şekil 4. 4. Kuantum hesaplamanın makine öğrenmesi yöntemlerinde kullanılması [78]

4.3. Kuantum Hesaplama Tabanlı Duygu Analizi ile İlgili Çalışmalar

Ses tanımda en önemli sorunlardan biri cinsiyet tanımlamadır. Tanıma teknikleri aşırı uyum sorunlardan muzdariptir. Bu aşırı uyum sorununun üstesinden gelebilmek amacıyla Riddhi Mandal ve Pragati Bhat yeni bir yaklaşım önermiştir [63]. Önerilen çalışmanın temel amacı, kuantum hesaplama kullanarak konuşmacının erkek mi yoksa kadın mı olduğunu belirlemektir. Ses veri setinden cinsiyetin belirlenmesi, perde, medyan, frekans vb özelliklere sahip olması kuantum yapay zeka kullanılarak mümkün olabilir. Önerilen sistem, konuşmacının cinsiyetini mümkün olan maksimum verimlilik ve doğrulukla tespit etmek için Kuantum K-en yakın komşular (Q-kNN), Kuantum Rasgele Orman, Kuantum Lojistik Regresyon, Kuantum Karar Ağacı ve Kuantum Destek Vektör Makinesi (QSVM) gibi tüm kuantum yapay zeka algoritmaları arasında en iyi algoritmayı bulmak için kullanılır. Bu çalışmadaki veri kümesi, 21 öznitelik ve kaggle.com'dan toplanan yaklaşık 3164 ses örneğinden oluşmaktadır. Bu verilerin %80'i eğitim %20'si test için ayrılmıştır. Kuantum makine öğrenme algoritmaları eğitim veri kümesinde eğitilir. Doğruluk, kesinlik F1-skor gibi değerlendirme metriklerini hesaplamak için test veri kümesi kullanılır [63]. Önerilen sistemin akış diyagramı şekil 4.5 'te verilmiştir. Sonuç olarak bu çalışma sesin cinsiyeti doğru ve verimli şekilde sınıflandırmaya çalışmaktadır. Model makine öğrenme algoritmalarını kuantum hesaplama ile birleştirerek hesaplama gücünü arttırmıştır. Q-kNN, Kuantum Rastgele Orman, Kuantum Lojistik Regresyon, Kuantum Karar Ağacı, QSVM konuşmacı tanımak için kullanılan algoritmalar. İyi performansa sahip modeller, sesi geniş bir yelpazede sınıflandırarak ses tabanlı cinsiyet tanıma sistemlerinin kullanılmasını ve geliştirilmesini sağlar. Kuantum alanında makine öğrenme algoritmaları çalışma aşamasındadır.




Şekil 4. 5. Önerilen yöntemin blok diyagramı

Yaochen Liu vd. [64], incelediği çalışma yakın zamanda geliştirilen kuantum- bilişsel ilham verici duygu analizi modellerinin arka planını, mevcut durumunu, ana sonuçlarını ve bulguları hakkında kapsamlı bir araştırma sunmaktadır. Bu çalışma öncelikle teorik düzeyde kuantum olasılığı ve kuantum bilişiminden bahsetmektedir ve bunların duygu analizini modellemekte klasik teorilere göre avantajları analiz edilmektedir. Daha sonra kuantum teorisinden yararlanan yeni modellerden bahsedilmekte ve duygu analizinde yaşanan problemlere nasıl yaklaşıldığına odaklanmaktadır. Tablo gelebilir. Sonuç olarak bu çalışma kuantum teorisi kullanan duygu analizi çalışmalarının nispeten iyi sonuçlar verdiğini ve duygu analizi uygulamalarında yaşanan belirsizlik, bağlamssalık ve çok modluluk sorunlarının üstesinden gelme konusunda iyi olduğunu göstermiştir. İncelen bu çalışmada, elde edilen iyi sonuçlara rağmen bazı yönlerde halen eksiklik olduğu vurgulanmış ve gelecekteki araştırma yönlerinden bahsedilmiştir.

Dünyada yaşanan olaylar finansal piyasaların davranışlarını, risk belirlemeyi, politika etkinliğini ve daha fazlasını önemli ölçüde etkilemektedir. Dijital kanallar üzerinden raporlanan bu olaylar Doğal dil işleme ve makine öğrenimi araçları için işlenmeye uygundur. Kuantum Haber Manşetlerin Duygu Analizcisi, NISQ(Gürültülü Orta Ölçekli Kuantum) cihazlarında Doğal dil


işleme ve makine öğrenimine hibrit bir klasik- kuantum hesaplama yaklaşımı uygulamaktadır. Bu çalışmada Covid-19 salgınıyla ilgili haber başlıklarını kullanarak bu haberleri olumlu, olumsuz, nötr ve karışık olmak üzere dört sınıfa ayırmak istenmiştir. Kamuoyunu anlamanın yararlı bir yolu olan duygu analizi, kuruluşların Covid-19 gibi hastalıkların yol almasına yardımcı olur. Olumsuz duygular artan korku ve kaygıyı dolayısıyla düşük harcamayı ima ederken, olumlu duygular tüketicilerin aşırı harcama yaptığı ve dolayısıyla ekonomiyi yönlendirdiği düşünülür. İncelenen bu makalede geleneksel duygu analizi yöntemlerini QBoost algoritmalarıyla karşılaştırmak amacıyla kuantum teorisi kullanılmaktadır. Bu çalışmada web’ de herkese açık serbest metinlerden oluşan iki veri seti kullanılmış ve denetimsiz olarak eğitilmiştir. İlk veri seti 2000 haber başlığı içerirken ikinci veri seti 4000 haber başlığı içermektedir. Veriler iki klasik makine öğrenme yöntemi olan AdaBoost ve Karar Ağacı ile kuantum teorisi kullanan algoritmayla karşılaştırılmıştır.. Cümleleri sabit uzunluklara eşlemek için BERT modeli kullanılmıştır. Öncelikle giriş metni ön işlem adımlarından geçirilerek bir sonuç elde edilir. Ön işlemden geçen cümleler kelime yerleştirmelerine dönüştürülüp Bert-serving- client kullanılarak D-Wave kuantum bilgisayarına yüklenir. D-Wave kuantum bilgisayar, eğitim hatalarını ve zayıf sınıflandırıcıların sayısını en aza indirmeye çalışan bir öğrenme sürecindeki ağırlıkları optimize etmek için kullanılır [65]. QBoost sınıflandırıcısı kullanılarak kuantum açısından optimize edilmiş bir model oluşturulur. Şekil 4.6’ da modelin blok diyagramı verilmiştir. Sonuç olarak bu çalışmadaki deneysel sonuç şu şekildedir; Klasik model olan AdaBoost ve Karar Ağacın elde ettiği başarı skoru 0,78 ile 1 arasında değişirken, QBosst ve QBoostLt gibi kuantum modelinde başarı skoru 0,85 ile 1 arasında değişmektedir



Şekil 4. 6. Önerilen modelin akış diyagramı [65]

4.4. Önerilen Yaklaşım

Bu çalışma doktor- hasta görüşmelerinden oluşan metinlerin içerdiği duyguların pozitif-nötr negatif olarak sınıflandırılmasını amaçlamaktadır. Sınıflandırmanın yapılabilmesi için doktor-hasta konuşmalarından veri seti oluşturulmuş ve bu veri seti derin öğrenme ve kuantum hesaplamasından yararlanılarak sınıflandırılmıştır. Bu görüşmelerdeki duygunun ve tutumun sınıflandırılabilmesi için dört aşamalı bir model önerilmiştir. Bu aşamalar sırası ile; ön işleme aşaması, derin öğrenme aşaması, kuantum hesaplama aşaması ve son işleme aşamasıdır. Uygulamanın gerçekleştirilmesinde Python programlama dili, PennyLane kuantum hesaplama kütüphanesi, Tensorflow makine öğrenmesi kütüphanesinden yararlanılmıştır. Kullanılan yöntemin blok diyagramı Şekil 4.7 ' de görülmektedir.



Şekil 4. 7. Önerilen yöntemin akış diyagramı

Ön işleme aşaması, önerilen modelin başarısını yükseltmek amacıyla verisetinin standartlaştırılması ve gürültüden arındırılması işlemidir. Bu yüzden veri seti olabildiğince ideal hale getirilmelidir. Ön işleme aşaması kendi içinde üç bölüme ayrılır. Bunlar sırası ile; küçük harf dönüşümü, özel karakter ve noktalama işaretlerinin kaldırılması ve tokenizasyon bölümleridir.

Küçük harf dönüşümü: Makine dilinde büyük harf ve küçük harf farklı karakterleri temsil etmektedir. Dolayısıyla eğitim sırasında aynı karakteri sembolize eden harfler farklı karakterler olarak işlenecektir. Bu durumun önünde geçmek amacıyla veri setine küçük harf dönüşümü uygulanır. Böylece

harfler arası kombinasyonların sayısı azalacağından veri seti küçültülmüş ve fazlalıklarından arındırılmış olur.

Özel karakterlerin ve noktalama işaretlerinin kaldırılması: Veri seti içinde bulunan fazlalıklardan bir diğeri ise noktalama işaretleri ve özel karakterlerdir. Özel karakterlerin ve noktalama işaretlerinin kaldırılmasındaki temel amaç veri setinin arındırılması ve boyutunun küçültülmesidir. Temizlenen karakterler ile veri setindeki gürültü azaltılır ve işleme sırasında eşleşme kolaylığı sağlar.

Tokanization: Bu işlem veri setinde yer alan metin verilerini kelimelere bölme işlemi olarak adlandırılır. Tokanization işleminin uygulanma sebebi metinlerde işleme kolaylığının sağlanmasıdır. Bu işlem sonrasında metinler işlenebilir alt birimlere ayrılmış olur. metinlerden elde edilen alt birimlerin işleme sırasında kullanılması öğrenme kolaylığı sağlar ve başarı oranını artırır. Aynı zamanda metin verileri alt birimlere ayırmak, veri setini tekrarlayan ifadelerden de arındırdığından dolayı veri setini fazlalıklarından arındırmış olur ve modelin kullanabileceği bir kelime dağarcığı oluşturur.

Ön işlem aşamalarının tamamlanmasından sonra metinler, duygu etiketleri ve konuşmacı etiketleri ile LSTM sinir ağı modeline giriş olarak verilir ve modelin eğitilmesi sağlanır. Modelden elde edilen çıktılar Kuantum Hesaplama yönteminde kullanılabilmesi amacıyla kuantum encoding yöntemlerinden biri olan AngleEncoding ile klasik veriden kuantum veriye dönüştürülmesi gerçekleştirilir. Kuantum formatına dönüştürülen veri Kuantum Devreye giriş olarak verilir. Verilerin kuantum devrede işlenmesi ile tensor veri yapısı temelli kuantum örnekler, durumlar ve olasılıklar elde edilir. Oluşan bu çıktıların yorumlanabilmesi için tensor verileri postprocessing adımından geçirilir. Bu adımda kuantum vektörleri olarak alınan veriler decode edilerek klasik veri olarak yorumlanabilir yapıya dönüştürülür. Oluşan çıktı ile ilgili metnin içerdiği duygunun pozitif-nötr-negatif olarak sınıflandırılması ve konuşmacısının da doktor veya hasta olarak sınıflandırılması sağlanmış olur.

Ön işlemde geçirilen verisini eğitmek amacıyla oluşturulan derin öğrenme modeli, (7) giriş boyutuna sahip Embedding katmanı, (7,128) giriş boyutuna sahip LSTM katmanı, (256) giriş boyutlu %30 parametrelili dropout katmanı ve (256) giriş boyutuna sahip Dense katmanından oluşmaktadır. Dense katmanından softmax aktivasyon fonksiyonu ile (3) boyutlu çıkış elde edilmektedir. Derin öğrenme modelinin katmanları, çıkış boyutları ve parametre sayıları Tablo 4.3 'te verilmiştir.

Tablo 4. 3. Derin öğrenme modelinin katmanları

Katman	Çıkış Boyutları	Parametreler
Embedding	(None,7,128)	128000
LSTM	(None,256)	394240
Dropout	(None,256)	0
Dense	(None,3)	771


Kuantum hesaplama devresi yinelemeli sinir ağı modelinin çıktısını giriş verisi olarak kullanır. Bu verinin kuantum devresinde kullanılabilmesi için öncelikle klasik verinin kuantum veriye dönüştürülmesi gereklidir. Derin öğrenme modelinden alınan çıktılar kübit durumlarını oluşturmak amacıyla açısız kodlama yöntemi kullanılmıştır. En sık kullanılan kodlama yöntemleri aşağıdaki gibidir:

Basis Encoding: Klasik verinin kuantum durumlarına kodlanabilmesinde kullanılabilecek en kolay yöntemdir. Kodlanmış olan durum klasik 0 ve 1 bitleri gibi $|0\rangle$ ve $|1\rangle$ kübit durumları ile ifade edilir.

Amplitude Encoding: Klasik verinin uygulanacak dalga fonksiyonu aracılığıyla genlik olarak kuantum durumuna dönüştürülmesi işlemidir.

Angle Encoding: Tek bir kübit rotasyon kapıları aracılığıyla verilen açı parametresiyle döndürülerek gerçekleştirilen yöntemdir.

Oluşturulan kuantum durumları kuantum devresinin girişine verilir. Kullanılan kuantum devresi 5 kübitlik girişe sahiptir. Bunlardan en değerlikli 3 kübit pozitif, nötr ve negatif olmak üzere duyuları temsil etmek için kullanılmaktadır. En değersiz 2 kübit ise doktor ve hasta olmak üzere konuşmacıyı temsil etmek amacıyla kullanılmıştır. Oluşturulan kübit durumları rotasyon kapıları ile dolanıklaştırılmıştır. Yapılan dolanıklaştırma işlemlerinden sonra kuantum devresinin çıktıları Pauli Z kapısı aracılığıyla ölçülmüştür. Önerilen yöntemde kullanılan kuantum devresi yapısı Şekil 4.8 'de görülmektedir.



Şekil 4. 8. Önerilen yöntemde kullanılan kuantum devre yapısı

Kuantum devresinin çıktılarının Pauli Z kapısı ile ölçümünden elde edilen tensör değerleri son işlem aşamasına verilmiştir. Son işlem aşamasında kuantum devresinden alınan tensörler işlenerek verilen kübit durumlarından konuşmacı ve konuşmacının duygusunun tahmini yapılmış olur.

4.5. Deneysel Sonuçlar

Önerilen yöntemdeki derin öğrenme modelin eğitiminde metin, metnin içerdiği duygu ve metnin konuşmacısını belirten etiketlenmiş veri seti kullanılmıştır. Veri setinde duyguların temsilinde negatif:1, nötr:2 ve pozitif:3 olacak şekilde işaretlenmiştir. Konuşmacının temsilinde ise hasta:0 ve doktor:1 olarak işaretlenmiştir. Veri seti Doktor-Hasta diyaloglarını içeren röportajlar, metinler, videolar ve TV programları temel alınarak manuel olarak oluşturulmuştur. Oluşturulan bu veri setinin örnek bir bölümü Şekil 4.9 'da verilmiştir.

Text	Sentiment	Speaker
yeme bozukluğunuz var mı?	2	1
iştahsızlığınız var mı?	2	1
derimde kaşıntı var.	1	0
derimde soyulmalar oluştu.	1	0
derim kaşıntılardan dolayı tahriş oldu.	1	0
beyninizde bir kitle tespit edildi.	1	1
aort damarınızda tıkanıklık tespit edildi.	1	1
aort damarınızdaki tıkanıklık ameliyata gerek kalmadan açıldı.	3	1
alerjik reaksiyonlarınızı ölçmek için testler yapılacak.	2	1
birden fazla bitki türüne alerjiniz var.	1	1
sahip olduğunuz alerjiler ilaç ile tedavi edilebilir.	3	1
burkulmalar için krem kullanmanız iyi gelebilir.	2	1
ayak dokularım zedelendiğinden yürüyemiyorum.	1	0
bel fıtığım yüzünden yürümekte zorluk çekiyorum.	1	0
sık sık yüzdüğüm için bel ağrılarım hafifledi.	3	0
düzenli yürüyüşler sayesinde nefes alışım rahatladı.	3	0
tedaviye başlamak için çok geç kaldınız.	1	1

Şekil 4. 9. Örnek veri seti

Bu metinler ön işlem aşamasından geçirilmiş kelimeleri içeren tokenlar oluşturulmuştur. Daha sonra maksimum kelime uzunluğuna sahip cümle temel alınarak tokenize edilen tüm cümlelere padding işlemi uygulanmıştır. Padding işleminden sonra sinir ağında işlenmek üzere metinler vektörize edilmiştir. Oluşturulan tek boyutlu vektör sinir ağı modelinde giriş verisi olarak kullanılmıştır.


Önerilen yöntem Python programlama dili kullanılarak programlanmıştır. Makine öğrenmesi ve derin öğrenme yöntemlerinde sıkça kullanılan Tensorflow kütüphanesi ile kullanılan derin öğrenme mimarisi oluşturulmuştur. Kuantum programlama bölümünü gerçekleştirmek için Pennylane kütüphanesi kullanılmıştır. Yapılan çalışmalar bulut ortamında Google Colab Platformu üzerinde gerçekleştirilmiştir. İlgili veriseti önce derin öğrenme ile eğitime tabii tutulmuş daha sonrasında

kuantum hesaplama ile sınıflandırılması gerçekleştirilmiştir. Oluşturulan derin öğrenme modeli Tablo 4.4 teki parametreler kullanılarak eğitim gerçekleştirilmiştir.


Tablo 4. 4. Derin öğrenme modeli parametreleri

Parametre adı	Parametre Değeri
Epoch	20
Batch Size	32
Learning Rate	0,0001
Activation Function	Softmax

Önerilen yöntem kullanılarak yapılan eğitimde ilgili veri seti ve parametreler kullanılmasıyla %92.59 başarı oranı elde edilmiştir. Önerilen yöntem ile elde edilen başarı oranı ve kaybı değerlerinin epok sayısına göre değişimi sırasıyla Şekil 4. 10 ve Şekil 4. 11’ de verilmiştir. Sonuç olarak kuantum hesaplama kullanan derin öğrenme uygulamaları yeni ve gelişmeye açık bir alandır. Kuantum bilgisayarlar zaman ve enerji maliyeti açısından büyük tasarruflar sağlamaktadır ve klasik bilgisayarların çok uzun yıllarda dahi çözemeyeceği problemlere çözüm üretilmeye çalışılmaktadır. Önerilen yöntem ile kuantum bilgisayarlar ile klasik duygu analizi yöntemlerinden daha hızlı ve başarılı sonuçlar elde edilmiştir. Elde edilen başarı sonucu ile diğer alandaki çalışmalar için de klasik kuantum hibrit yönteminin öncülük edeceği düşünülmektedir.



Şekil 4. 10. Önerilen yöntemin doğruluk oranı



Şekil 4. 11. Önerilen yöntemin kayıp değeri

5. SONUÇLAR

Duygu analizi, özellikle yazarın belirli bir konuya yönelik duygusunun ve tutumunun olumlu, olumsuz veya tarafsız olup olmadığını belirlemek amacıyla bir metin parçasında ifade edilen görüşlerin sayısal olarak tanımlanması ve sınıflandırılmasını sağlar. Bu çalışma, derin öğrenme ve kuantum hesaplama kullanan derin öğrenme modeli kullanarak sağlık verilerinden duygu analizi gerçekleştirmek ve elde edilen verilere göre bilgi çıkarımı yapmaktır. Sağlık verilerinden duygu analizi ile ilgili çalışmaların çoğu sosyal medya verilerini dikkate almaktadır. Tıbbi terimler içeren doktor-hasta görüşmelerine ait ses dosyalarını metine dönüştürmek üzerinde çalışmalar yapılmasını gerektiren bir alandır. Klinik ortamda doktor-hasta görüşmelerine ait veriler, hastanın geçmişini, muayene bulgularını, tedavi planlarını ve diğer ilgili bilgilerini içeren önemli belgelerdir. Bu belgelerden duygu analizinin gerçekleştirilmesine yönelik Literatürde bir çalışma bulunmamaktadır. Bu nedenle bu çalışmanın sonucunda elde edilen sonuçlar Literatüre katkı sağlayacaktır.

Bu tez kapsamında sağlık verilerinden duygu analizi gerçekleştirmek için derin öğrenme ve kuantum hesaplama kullanan derin öğrenme tabanlı yöntemlere yer verilmiştir. Önerilen yöntemlerde kullanılan derin öğrenme modeli LSTM 'dir. LSTM modeli uzun metinleri işlemede oldukça başarılı bir derin öğrenme algoritmasıdır. Bu tez çalışmasında öncelikle ilgili alanda incelenen Literatür çalışmalarına yer verilmiştir. Daha sonra önerilen yöntemlerden bahsedilmiştir.

Önerilen yöntemlerden ilki karşılıklı görüşmelerde duygu analizinin tespiti için bir çalışmadır. Bu çalışma sağlık alanındaki tıbbi kayıt ve raporlar açısından oldukça önemlidir, o raporun içeriğinin olumlu, olumsuz veya tarafsız olduğunu bilmek bu belgelerin ayrıştırılması ve hasta tedavisine yönelik süreci hızlandıracaktır. Duygu analizi çalışması yapılırken derin öğrenme modeli ile lstm gerçekleştirilmiştir. Bu model eğitim sonucunda başarı puanı %94 oldu. Bu çalışma, duygu analizi alanında elde edilen doğruluk puanı ile Literatüre güzel bir katkı sağlamıştır. Çalışma, sağlık alanında duygu analizi yaptığı için sağlık alanındaki tıbbi kayıt ve raporların incelenmesine büyük katkı sağlayacaktır. Sağlık sektörüne böylesine bir katkı sağlayarak ve Literatürdeki mevcut çalışmaları karşılaştırarak elde edilen bu sonuç, önerilen algoritmanın diğer iyi bilinen sınıflandırıcılarla karşılaştırıldığında etkinliğini ikna edici bir şekilde kanıtlamaktadır.

Önerilen yöntemlerden ikincisi ve farklı bir yaklaşım olan Derin Öğrenme Tabanlı Duygu Analizi Yaklaşımıdır. Bu yöntemde, hastaların hastane değerlendirmeleri üzerine bir duygu analizi yöntemi önerilmektedir. Hastaların tıbbi incelemelerini içeren ve yorumları olumlu ve olumsuz olarak sınıflandıran 4 farklı sinir ağı mimarisi geliştirildi. Transfer öğrenimini sinir ağı mimarilerine uygulamak için Skipgram kelime yerleştirmelerini eğittik. Bir LSTM-CNN mimarisi bu sınıflandırmayı %89'un üzerinde bir başarı elde etmiştir. En kötü performansı ise Yoğun mimarili sinir ağı (%53,91) göstermiştir.

Son olarak bu çalışmada klasik bilgisayarlardan çok daha hızlı hesaplama gücüne sahip kuantum bilgisayarlar ile klasik yöntem kullanarak duygu analizi gerçekleştirmek amacıyla bir yöntem önerilmiştir. Önerilen yöntem ile klasik duygu analizi yöntemlerinden daha hızlı ve başarılı sonuçlar elde edeceği öngörülmektedir. Duygu analizinin gerçekleştirilmesi amacıyla kuantum hesaplama ve derin öğrenmede kullanılan LSTM yinelemeli sinir ağı modeli kullanılmıştır. Uygulamada kullanılacak veriler doktor-hasta dialoglarını içeren video, röportajlar, tv programları ve metinsel kaynaklar kullanılarak manuel oluşturulmuştur. Bu veriler ile derin öğrenme modeli eğitilmiş ve modelin çıktıları kuantum hesaplama ile sınıflandırmada kullanılmıştır. Yapılan sınıflandırma sonucu %92.59 başarı oranına ulaşılmıştır. Bu sonuçlar ile klasik derin öğrenme yöntemleri ve kuantum hesaplamanın birlikte kullanıldığı hibrit yöntemlerin yaygın bir şekilde kullanılmaya başlanacağı öngörülmektedir. Tablo 5.1 'de önerilen yöntemlerin bulunduğu bölümler, önerilen yöntemlerin isimleri ve kullanılan modeller ve yöntem değerlendirmeleri verilmiştir.

Tablo 5. 1. Tez Kapsamında Önerilen Yaklaşımlar

Bölüm	Yöntem Adı	Kullanılan Algoritma	Değerlendirme
Bölüm-2	Karşılıklı Görüşmelerde Duygu Analizi	LSTM	Doğruluk: %94
Bölüm-3	Derin Öğrenme Tabanlı Duygu Analizi	DENSE	Doğruluk: %77.4
		CNN	%84.75
		LSTM	%87.96
		CNN-LSTM	%89.47
Bölüm-4	Kuantum Hesaplama Tabanlı Duygu Analizi	LSTM	Doğruluk: %92.59

KAYNAKLAR

- [1] E. Uca, K. Şahin, S. Yilmazer, S. Demirel, H. Kizilhan and M. Karaköse, (2022). "LSTM Based Sentiment Analysis on Conversations in Health," 2022 International Conference on Data Analytics for Business and -Industry (ICDABI), Sakhir, Bahrain, pp. 336-340, doi: 10.1109/ICDABI56818.2022.10041481.
- [2] C. Dwivedi and J. Rao, (2023). "Multilingual Sentiment Analysis for Detecting Mental Health Problems using a Hybrid algorithm combining RNN and Bi-LSTM," 2023 7th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), Kirtipur, Nepal, pp. 527-534, doi: 10.1109/I-SMAC58438.2023.10290688.
- [3] S. Tokcaer, (2021) "Türkçe Metinlerde Duygu Analizi" . Yaşar Üniversitesi E-Dergisi 16 (2021): 1514-1534 <https://dergipark.org.tr/tr/pub/jyasar/issue/64642/928843>.
- [4] Y. Chen, Y. Pan, S. Member, and D. Dong, (2023). "Quantum Language Model With Entanglement Embedding for Question Answering," IEEE Trans. Cybern., vol. 53, no. 6, doi: 10.1109/TCYB.2021.3131252.
- [5] R. Lorenz, A. Pearson, K. Meichanetzidis, D. Kartsaklis, and B. Coecke, (Feb. 2021). "QNLP in Practice: Running Compositional Models of Meaning on a Quantum Computer," J. Artif. Intell. Res., vol. 76, pp. 1305–1342, doi: 10.1613/jair.1.14329.
- [6] K. Denecke, D. Reichenpfader, (2023) "Sentiment analysis of clinical narratives: A scoping review." J Biomed Inform. 2023 Apr;140:104336. doi: 10.1016/j.jbi.2023.104336. Epub 2023 Mar 22. PMID: 369584611-11
- [7] F. N. Uyaroğlu Akdeniz, H. İ. Cebeci, (2021) "Belediye Hizmetlerin Değerlendirilmesinde Duygu Analizi Yaklaşımı: Sakarya İli Örneği". Journal of Intelligent Systems: Theory and Applications 4 (2021): 127- 135
- [8] L. Khan, A. Amjad, K.M. Afaq, H.T. Chang, (2022) "Deep Sentiment Analysis Using CNN-LSTM Architecture of English and Roman Urdu Text Shared in Social Media." Appl. Sci. 2022, 12, 2694. <https://doi.org/10.3390/app12052694>
- [9] Ş. Şahiner Yılmaz, & I. Ozer, & H. Gökçen, (2021). "Türkçe Metinlerde Derin Öğrenme Yöntemleri Kullanılarak Duygu Analizi."
- [10] M. C. Yılmaz ve Z. Orman , (Ara. 2021). "LSTM Derin Öğrenme Yaklaşımı ile Covid-19 Pandemi Sürecinde Twitter Verilerinden Duygu Analizi", Acta Infologica, c. 5, sayı. 2, ss. 359-372, doi:10.26650/acin.947747
- [11] R. Sultana and R. Palit, (2014). "A survey on Bengali speech-to-text recognition techniques," 2014 9th International Forum on Strategic Technology (IFOST), pp. 26-29, doi: 10.1109/IFOST.2014.6991064.
- [12] M. Bansal, S. Yadav and D. K. Vishwakarma, (2021). "A Language-Independent Speech Sentiment Analysis Using Prosodic Features," 2021 5th International Conference on Computing Methodologies and Communication (ICCMC), pp. 1210-1216, doi: 10.1109/ICCMC51019.2021.9418357.

- [13] A. Messaoudi, H. Haddad, C. Fourati, M.B.H. Hmida, A.B.E. Mabrouk, M. Graiet, (2021). "Tunisian Dialectal End-to-end Speech Recognition based on DeepSpeech", *Procedia Computer Science*, Volume 189, Pages 183-190, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2021.05.082>.
- [14] I. Tashev, & D. Emmanouilidou, (2020) "Sentiment Detection from Speech Recognition Output." *Engineering Sciences*. 2020, LVII. 10.7546/EngSci.LVII.20.02.01.
- [15] N. Majumder, S. Poria, D. Hazarika, R. Mihalcea, A. Gelbukh, & E. Cambria, (2019, July). Dialoguernn: An attentive rnn for emotion detection in conversations. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 33, No. 01, pp. 6818-6825).
- [16] R. R. Sehgal, S. Agarwal and G. Raj, (2018). "Interactive Voice Response using Sentiment Analysis in Automatic Speech Recognition Systems," 2018 International Conference on Advances in Computing and Communication Engineering (ICACCE), pp. 213-218, doi: 10.1109/ICACCE.2018.8441741.
- [17] R. Lorenz, A. Pearson, K. Meichanetzidis, D. Kartsaklis, and B. Coecke, (Feb. 2021). "QNLP in Practice: Running Compositional Models of Meaning on a Quantum Computer," *J. Artif. Intell. Res.*, vol. 76, pp. 1305–1342, , doi: 10.1613/jair.1.14329.
- [18] S. Maghilnan and M. R. Kumar, (2017). "Sentiment analysis on speaker specific speech data," 2017 International Conference on Intelligent Computing and Control (I2C2), pp. 1-5, doi: 10.1109/I2C2.2017.8321795.
- [19] G. Dimauro, V. Di Nicola, V. Bevilacqua, D. Caivano and F. Girardi, (2017) . "Assessment of Speech Intelligibility in Parkinson's Disease Using a Speech-To-Text System" in *IEEE Access*, vol.5, pp. 22199-22208, doi:10.1109/ACCESS.2017.2762475.
- [20] T. Sen, M. R. Ali, M. E. Hoque, R. Epstein and P. Duberstein, (2017). "Modeling doctor-patient communication with affective text analysis," 2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII), pp. 170-177, doi: 10.1109/ACII.2017.8273596.
- [21] Y.Jiang, P. Zhang, H. Gao, D. Song, (2020). A quantum interference inspired neural matching model for ad-hoc retrieval. In *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, Xi'an, China, 25–30 July 2020; pp. 19–28
- [22] Y. N. Prajapati, S. Yadav, S. Sharma, U. K. Patel and S. Tomar, (2023). "Analysis of Underlying Emotions in Textual Data Using Sentiment Analysis Which Classifies Text In to Positive, Negative or Neutral Sentiments," 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), Delhi, India, pp. 1-6, doi: 10.1109/ICCCNT56998.2023.10307310.
- [23] C. Ganesh, R. Arulpriya, V. Keerthana, D. Kiruthika and M. Subasri, (2023). "Deep Learning Based Sentiment Analysis on Drug Reviews," 2023 IEEE 2nd International Conference on Industrial Electronics: Developments & Applications (ICIDeA), Imphal, India, pp. 401-406, doi: 10.1109/ICIDeA59866.2023.10295255
- [24] M. Fahmi, F. Yudanto, N. Nazhifah, Y. Sari and Afiahayati, (2023). "Deep Learning Approach for Aspect-Based Sentiment Analysis on Indonesian Hospitals Reviews," 2023 Eighth International Conference on Informatics and Computing (ICIC), Manado, Indonesia, pp. 1-6, doi:10.1109/ICIC60109.2023.10381908.

- [25] M.Wongkar, and A. Angdresey, (2019, October). Sentiment analysis using Naive Bayes Algorithm of the data crawler: Twitter. In 2019 Fourth International Conference on Informatics and Computing (ICIC) (pp. 1-5). IEEE.
- [26] Y. Ayyappa, B. V. Kumar, S. P. Priya, S. Akhila, T. P. Vardhan Reddy and S. M. Goush, (2023). "Forecasting Equity Prices using LSTM and BERT with Sentiment Analysis," 2023 International Conference on Inventive Computation Technologies (ICICT), Lalitpur, Nepal, pp. 643-648, doi: 10.1109/ICICT57646.2023.10134443.
- [27] S. Ganguly, S. N. Morapakula and L. M. P. Coronado, (2022) "Quantum Natural Language Processing Based Sentiment Analysis Using Lambeq Toolkit," 2022 Second International Conference on Power, Control and Computing Technologies (ICPC2T), Raipur, India, pp. 1-6, doi: 10.1109/ICPC2T53885.2022.9776836.
- [28] S. Li and Y. Hou, (2022)"Quantum-Inspired Model Based on Convolutional Neural Network for Sentiment Analysis," 2021 4th International Conference on Artificial Intelligence and Big Data (ICAIBD), Chengdu, China, pp. 347-351, doi: 10.1109/ICAIBD51990.2021.9459058
- [29] F. Z. Ruskanda et al. (2022). "Quantum Representation for Sentiment Classification," 2022 IEEE International Conference on Quantum Computing and Engineering (QCE), Broomfield, CO, USA, pp. 67-78, doi: 10.1109/QCE53715.2022.00025.
- [30] P. Singh, G. Saha, and M. Sahidullah, (May,2021). "Deep scattering network for speech emotion recognition."
- [31] H. Yusufoglu, H. Aydın ve A. Cetinkaya , (Ara. 2021). "Twitter Üzerindeki Finansal Tweetlerin LSTM Sinir Ağı Algoritması ile Duygu Analizi", Veri Bilimi, c. 4, sayı. 3, ss. 28-43.
- [32] S. Tuzcu, (Haz. 2020)"Çevrimiçi Kullanıcı Yorumlarının Duygu Analizi ile Sınıflandırılması", Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, c. 1, sayı. 2, ss. 1-5.
- [33] Ö. Demir, A. İ. Baban Chawai, , B. Doğan, (2019) "Türkçe Metinlerde Sözlük Tabanlı Yaklaşımla Duygu Analizi Ve Görselleştirme" . International Periodical of Recent Technologies in Applied Engineering 1 (2019): 58-66
- [34] C. Colón-Ruiz and I. Segura-Bedmar. (2020)"Comparing deep learning architectures for sentiment analysis on drug reviews." Journal of Biomedical Informatics 110 (2020): 103539.
- [35] Ö. F. Öztürk ve E. Pashaei , (Eyl. 2021) "Konuşmalardaki duygunun evrimsel LSTM modeli ile tespiti", Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, c. 12, sayı. 4, ss. 581-589, doi:10.24012/dumf.1001914
- [36] I. A. Farha, W. Magdy, (2021)"A comparative study of effective approaches for arabic sentiment analysis". Information Processing & Management, 58(2), 102438.
- [37] A. B. Uzun, A. Özer, & B. Diri. (2022) Haberler Üzerinden Ülkeler Arası İlişkilerin Analizi. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 11(1), 106-118
- [38] B. Ay Karakuş, (2018). Derin Öğrenme Ve Büyük Veri Yaklaşımları İle Metin Analizi. Elazığ: Fırat Üniversitesi Doktora Tezi.
- [39] Mc. ai, Machine Learning: Broad Approaches, <https://mc.ai/machine-learningbroad-approaches/>, 24 Eylül 2018
- [40] Chollet, F. (2021). Deep learning with Python. Simon and Schuster.

- [41] Codeutsava, (Kasım 2018) Deep Learning vs Machine Learning Comparison, <https://codeutsava.in/blog/40>, 1.
- [42] Convolutuinal neural networks(cnn) explanation and implementation part-1, link: [https://nitiapanwar.github.io/Convolutional-neural-networks\(CNN\)-explanation-and-implementation-part-1/](https://nitiapanwar.github.io/Convolutional-neural-networks(CNN)-explanation-and-implementation-part-1/)
- [43] Modern Yinelemeli Sinir Ağları, link: https://tr.d2l.ai/chapter_recurrent-modern/index.html
- [44] Dataset, Open Data Platform of English Government, link: <https://www.data.gov.uk/dataset/73740ffe->
- [45] S. Pandey, J. Basisth, T. Sachan, N. Kumari, and P. Pakray, (2023) “Quantum machine learning for natural language processing application,” *Physica A*, vol. 627, p. 129123, doi: 10.1016/j.physa.2023.129123.
- [46] A. Mavi, (2019). “Kuantum Hesaplamaya Teorik ve Uygulamalı Giriş,”
- [47] A. B. de Avila, R. H. S. Reiser, M. L. Pilla, and A. C. Yamin, (2020). “State-of-the-art quantum computing simulators: Features, optimizations, and improvements for D-GM,” *Neurocomputing*, vol. 393, pp. 223–233, doi: 10.1016/j.neucom.2019.01.118.
- [48] M. Yenilmez, N. F. Bar, and M. Karaköse, (2023). “A seq2seq based approach for generation of quantum circuits using deep learning,” *Elazig*, pp. 1–7.
- [49] L. Aggarwal, S. Sachdeva, P. Goswami, L. Aggarwal, S. Sachdeva, and P. Goswami, (2023). “Quantum healthcare computing using precision based granular approach,” *Appl. Soft Comput.*, vol. 144, p. 110458, doi: 10.1016/j.asoc.2023.110458.
- [50] S. Li, K. Dan Nguyen, Z. Clare, and Y. Feng, (2023). “Single-Qubit Gates Matter for Optimising Quantum Circuit Depth in Qubit Mapping”, doi: 10.1109/ICCAD57390.2023.10323863.
- [51] Y. Chen, Y. Pan, S. Member, and D. Dong, “Quantum Language Model With Entanglement Embedding for Question Answering,” *IEEE Trans. Cybern.*, vol. 53, no. 6, 2023, doi: 10.1109/TCYB.2021.3131252.
- [52] R. Lorenz, A. Pearson, K. Meichanetzidis, D. Kartsaklis, and B. Coecke, (Feb. 2021). “QNLP in Practice: Running Compositional Models of Meaning on a Quantum Computer,” *J. Artif. Intell. Res.*, vol. 76, pp. 1305–1342, doi: 10.1613/jair.1.14329.
- [53] H. Yetiş and M. Karaköse, (2021). “Makine Öğrenmesi Yöntemlerinde Yüksek Başarım için Kuantum Bilgisayar ve Hesaplamanın Kullanımı,” *Türkiye Bilişim Vakfı Bilgi. Bilim. ve Mühendisliği Derg.*, vol. 14, no. 1, pp. 47–56, , doi: 10.54525/tbbmd.845472.
- [54] S. Pandey, N. J. Basisth, T. Sachan, N. Kumari, and P. Pakray, (2023). “Quantum machine learning for natural language processing application,” *Phys. A Stat. Mech. its Appl.*, vol. 627, p. 129123, doi: 10.1016/j.physa.2023.129123.
- [55] F. Jazaeri, A. Beckers, A. Tajalli, and J.-M. Sallese, (Aug. 2019). “A Review on Quantum Computing: Qubits, Cryogenic Electronics and Cryogenic MOSFET Physics,” [Online]. Available: <http://arxiv.org/abs/1908.02656>
- [56] N. Y. Bar, H. Yetis, and M. Karakose. (August 2023). An efficient and scalable variational quantum circuits approach for deep reinforcement learning. *Quantum Information Processing*, 22(8),.

- [57] N. Y. Bar, H. Yetis, and M. Karakose. (February 2023). A quantumclassical hybrid classifier using multi-encoding method for images. In 2023 27th International Conference on Information Technology (IT). IEEE,
- [58] Y. Kwak, W. J. Yun, J. P. Kim, H. Cho, J. Park, M. Choi, S. Jung, and J. Kim. (June 2023). Quantum distributed deep learning architectures: Models, discussions, and applications. *ICT Express*, 9(3):486–491,
- [59] L. Aggarwal, S. Sachdeva, P. Goswami, L. Aggarwal, S. Sachdeva, and P. Goswami, (2023). “Quantum healthcare computing using precision based granular approach,” *Appl. Soft Comput.*, vol. 144, p. 110458, doi: 10.1016/j.asoc.2023.110458.
- [60] Y. Ruan, X. Xue, H. Liu, J. Tan, X Li, (2017). “Quantum Algorithm for K-Nearest Neighbors Classification Based on the Metric of Hamming Distance” DOI 10.1007/s10773-017-3514-4
- [61] S. L. Braunstein. (2013) “Quantum decision tree classifier.”
- [62] K. Li, H. Dai, F. Jing, M.Gao, B.Xue, P.Wang and M.Zhang, (2021). “Quantum Algorithms for Solving Linear Regression Equation” doi:10.1088/1742-6596/1738/1/012063].
- [63] R. Mandal & P. Bhat, (2021). An Advance Approach toward Sentiment Analysis using Quantum AI.
- [64] Y. Liu, & Q. Li, & B. Wang, & Y. Zhang, & D. Song, (2023). A Survey of Quantum-Cognitively Inspired Sentiment Analysis Models.
- [65] Quantum News Headlines Sentiment Analyze, *Quantum_News_Sentiment_Analyzer* Whitepaper (mphasis.com)
- [66] S. Rani, & P. Kumar, (2018). Deep Learning Based Sentiment Analysis Using C onvolution Neural Network. *Arabian Journal for Science and Engineering*. 44. 10.1007/s13369-018-3500-z.
- [67] Z. Jianqiang, & G. Xiaolin, (2018). Deep Convolution Neural Networks for Twitter Sentiment Analysis. *IEEE Access*. PP. 1-1. 10.1109/ACCESS.2017.2776930.
- [68] U. Naqvi, A. Majid and S. A. Abbas (2021). "UTSA: Urdu Text Sentiment Analysis Using Deep Learning Methods," in *IEEE Access*, vol. 9, pp. 114085-114094, doi: 10.1109/ACCESS.2021.3104308.
- [69] Razzaq et al.(2019). "Text sentiment analysis using frequency-based vigorous features," in *China Communications*, vol. 16, no. 12, pp. 145-153, Dec. 2019, doi: 10.23919/JCC.2019.12.011.
- [70] P. Koncz and J. Paralic, (2011) ."An approach to feature selection for sentiment analysis," *2011 15th IEEE International Conference on Intelligent Engineering Systems*, Poprad, Slovakia, pp. 357-362, doi: 10.1109/INES.2011.5954773.
- [71] V.Pandya, A. Somthankar, S. S Shrivastava, and M. Patil. (2021). Twitter sentiment analysis using machine learning and deep learning techniques. In 2021 2nd International Conference on Communication, Computing and Industry 4.0 (C2I4). IEEE, December 2021
- [72] D. Goularas and S. Kamis. (August 2019). Evaluation of deep learning techniques in sentiment analysis from twitter data. In 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML). IEEE.
- [73] K. Dhola and M. Saradva. (January 2021). A comparative evaluation of traditional machine learning and deep learning classification techniques for sentiment analysis. In 2021 11th International Conference on Cloud Computing, Data Science Engineering (Confluence). IEEE.

- [74] Y. E. Rizk and W. M. Asal. (October 2021).Sentiment analysis using machine learning and deep learning models on movies reviews. In 2021 3rd Novel Intelligent and Leading Emerging Sciences Conference (NILES). IEEE.
- [75] J. A. M. Fadhlurrahman, N. A. Herawati, H. R.Widya Aulya, I. Puspasari, and N. P. Utama. (October 2023). Sentiment analysis of game reviews on steam using bert, bilstm, and crf. In 2023 International Conference on Electrical Engineering and Informatics (ICEEI). IEEE.
- [76] E. Tuah and F. Z. Ruskanda.(October 2023.) Sentiment analysis of political party news on the online news portal detik.com using lstm and cnn. In 2023 International Conference on Electrical Engineering and Informatics (ICEEI). IEEE.
- [77] A. Kirchner & C. S. Signorino. (2018). Using support vector machines for survey research. Survey Practice, 11(1).
- [78] J. Adcock, E. Allen, M. Day, S. Frick, J. Hinchliff, M. Johnson, S. Morley-Short, S. Pallister, A. Price, ve S. Stanisic, (2015). Advances in quantum machine learning, arXiv preprint arXiv:1512.02900v1.

ÖZGEÇMİŞ

Sedef AKSU

[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]
[REDACTED]	[REDACTED]

AKADEMİK FAALİYETLER

Projeler:

1. Optimum Kuantum Hesaplama Modellerinin Otomatik Üretilmesi İçin Derin Öğrenme Tabanlı Bir Yöntem (2022-...)