



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

YAPAY ZEKA İLE BİREYLERDE OTİZM TESPİTİ

Buşra SABAK

Tez Danışmanı
Prof.Dr. SERHAT ÖZEKES

İSTANBUL-2023

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

YAPAY ZEKA İLE BİREYLERDE OTİZM TESPİTİ

Buşra SABAK

Tez Danışmanı
Prof.Dr. SERHAT ÖZEKES

İSTANBUL-2023

ÖZET

YAPAY ZEKA İLE BİREYLERDE OTİZM TESPİTİ

Otizmli bireyler hem sözlü hem de sözlü olmayan sosyal becerilerde eksiklikler, tekrarlanan davranışlar ve iletişim sorunları ile mücadele eder. Otizm genetik olarak kabul edilse de, bireylerin davranış özellikleri ve yüz özellikleri üzerinde test edilmesi sırasında doğru tanı oranları ortaya çıkarılabilir. Farklı yüz deformasyonları, araştırmacıların bireyin sadece bir görüntüsünü analiz ederek bireyin hastalığa sahip olup olmadığını belirlenmesine olanak sağlayabilir.

Bu çalışmanın amacı yapay zeka tespitinde, yüz özellikleri üzerinden bireylerin otizmli olup olmadığını tahmin etmek, belirli ve tekrarlanan davranış özellikleri hakkında sorular sorarak her iki sonucu değerlendirmek, otizmli bireylerin tanılama aşamasında görev yapan uzmanlara veri sunmaktır.

Bu araştırmada *Python* programlama dili kullanılarak *Google CoLab* üzerinden kodlama oluşturulacaktır. Otizmli bireylerin davranış özellikleri hakkında tespit ve değerlendirme yapabilmek için otizm olasılığı olan bireylerin fotoğraflarından elde edilecek veriler ve DSM-V Otizm Spektrum Bozuklukları Tanı Ölçütlerine ilişkin sonuçlar kullanılmıştır. Otizmli bireyler üzerine gerçekleştirilen bilimsel yapay zeka çalışmaları hakkında tutarlı taramalar gerçekleştirilmiş ve birincil ve ikincil kaynaklardan faydalanılmıştır. Bahse konu tez çalışmasının temelini Kaggle isimli platformda düzenlenen veri seti oluşturmaktadır. Halihazırda oluşturulmuş verilerde otizmli bireylerin internette yer alan fotoğrafları derlenmiştir. Bununla birlikte, çalışmanın kod altyapısını ve tutarlılığını tespit edebilmek için birkaç adet örneklem üzerinde çalışma gerçekleştirilmiştir.

Çalışmada kullanılan CNN ile en yüksek doğruluk oranı %98.75 elde edilmiştir. Model eğitiminde CNN’de başarıyı yakalamıştır. DSM-V tanı kriterleri ile sorulan soruların sonucunda ise elde edilen “Evet” sorusunun yanıtı ise % 99.99 yüzdesi ile 12-24 ay yaş aralığında teşhisi konulan otizmli bireyin fotoğrafı ile modele otizmli mi değil mi sorusu sorulduğunda otizmli sınıfında olduğunu bilerek modeli doğrulamıştır.

Anahtar Kelimeler: Makine Öğrenimi, DSM-V, Otizmde Tanı, Yapay Zeka

ABSTRACT

DETECTION OF AUTISM AMONG INDIVIDUALS BY ARTIFICIAL INTELLIGENCE ANALYSIS AND METHODS

People with autism often grapple with limitations in both spoken and unspoken social abilities, repeated behaviors, and difficulties in communication. Although autism is believed to be genetically linked, the most precise diagnosis is accomplished by observing behavioral aspects and facial characteristics of the individual. Specific facial anomalies aid scientists in identifying if a person has autism by examining a single photograph.

As the aim of this research employ artificial intelligence to recognize whether individuals are autistic or not, based on their facial features. The study will also evaluate distinct and repeated behaviors by questioning, and offer relevant data to professionals involved in diagnosing autism. The methodology for this study will involve coding using Python on Google's Colab platform. The data, sourced from images of individuals who likely have autism and the diagnostic criteria of Autism Spectrum Disorder as per DSM-V, will be crucial in detecting and assessing the behavioral traits of autistic individuals.

The research will review artificial intelligence studies focused on autism systematically, drawing from both primary and secondary sources. This project is fundamentally based on a dataset organized on Kaggle, composed of collected internet photos of individuals with autism. Furthermore, the study will include a preliminary assessment of a few samples to evaluate the code structure and the study's overall coherence.

The study achieved a high accuracy of 98.75% Convolutional Neural Network (CNN) model. In the training phase of the model, an achievement was realized with the CNN. Upon asking questions based on the DSM-V diagnostic criteria, the "Yes" response was validated with 99.99% certainty. This validation was performed by introducing the model to a photograph of an autistic person, who had been diagnosed between 12-24 months of age, and then ascertaining whether the individual was autistic.

Keywords: Machine Learning, DSM-V, Autism, Artificial Intelligence, Autism Diagnosis

TEŐEKKÖR

Bu alıőmada bana yŖn gŖsteren ve ıőık tutan saygıdeęer Prof.Dr. Serhat Ŗzekes hocam ve Ŗniversitemizin tŖm bŖlŖm hocalarına teőekkŖr ederim.

Aynı zamanda tŖm sŖre boyunca destek ve emeklerini esirgemeyen Oktay Sabak, Tuncay Sabak ve Temmuz Yięit Bezmez'e teőekkŖrlerimi sunmaktan mutluluk duyuyorum.



En iten saygılarımla,

Buőra SABAK

BEYAN FORMU

Bu alıřmadaki tm belge, fotoğraf ve bilgileri akademik kurallara uyacak řekilde elde ettiđimi, yazılı ve grsel olmak zere btn bilgileri sonuları ile birlikte bilimsel etik kurallara uygun sunduđumu, alıřmadaki veriler zerinde herhangi bir tahrifat yapmadıđımı, atıfta bulunurken bilimsel normlar erevesinde kaldıđımı, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, tarafımdan retildiđini ve řkdar niversitesi Fen Bilimleri Enstits Tez Yazım Kılavuzu dikkate alınarak yazıldıđını beyan ederim.

28.07.2023

Buřra Sabak

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
BEYAN FORMU.....	iv
İÇİNDEKİLER.....	v
TABLOLAR DİZİNİ.....	vii
ŞEKİLLER DİZİNİ.....	viii
SİMGELER VE KISALTMALAR DİZİNİ.....	ix
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	3
2.1. Yapay Zeka Nedir?.....	3
2.2. Yapay Zeka Tarihçesi.....	4
2.3 Otizm Nedir?.....	5
2.4. Otizm Tarihçesi.....	7
2.5. Yapay Zeka ve Otizm	7
2.6. DSM-V ile Otizm Spektrum Bozukluğu (OSB) Tanı Ölçütleri.....	8
2.7. Derin Öğrenme Modelleri.....	10
2.7.1. Convolutional Neural Network (CNN)	10
2.7.1.1. CNN Katmanları.....	11
2.7.1.2. VGG16	12
2.7.1.3. EfficientNetB0.....	13
2.8. Değerlendirme Ölçekleri	14
3. GEREÇ VE YÖNTEM	11
3.1.Araştırmanın Tipi.....	11
3.2. Araştırmanın Modeli.....	11

3.3. Araştırmanın Evren ve Örneklemi.....	11
3.4. Veri Toplama Araçları.....	11
3.4.1. Veri Kaynağı.....	12
3.4.2. Anket.....	12
3.4.3. Doküman İncelemesi.....	12
3.5. Verilerin Analizi.....	12
3.5.1. Kodlama Verileri.....	12
3.5.2. Veri Setinin Özellikleri.....	13
3.6. Araştırmada kullanılan Modeller ve Sonuçları.....	19
3.6.1. CNN.....	19
3.6.2. EfficientNetB0.....	20
3.6.3. VGG-16.....	20
3.6.4. Resnet50.....	21
4. BULGULAR.....	23
4.1. Kodlama.....	24
4.1.1. Gerçek Zamanlı Sonuçların Değerlendirilmesi.....	35
5. TARTIŞMA.....	43
6. SONUÇ VE ÖNERİLER.....	44
KAYNAKLAR.....	45
EKLER.....	51
Ek 1. Kodlar, Gerçek Zamanlı Fotoğraflar ve Yanıt Formu.....	51
Ek 2. Özgeçmiş.....	52

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 1: Modellerin Karşılaştırılma Tablosu	24
Tablo 2: Gerçek Zamanlı Sonuçların Tablosu.....	33
Tablo 3: Benzer Veri Kümesi Kullanan Çalışmaların Değerlendirilmesi.....	40



ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1: Bazı Önemli Alanlarda YZ Uygulamalarının Genel Bir Görünümü)	
.....	8
Şekil 2: CNN Mimarisinin Katmanları Alzubaidi ve ark., 2021).....	11
Şekil 3: VGG-16 Katmanları (Keçeli ve Kaya, 2018).....	13
Şekil 4: EfficientNetB3 Mimarisi (Batool ve Byun, 2023).....	14
Şekil 5: CNN Mimarisi.....	19
Şekil 6: VGG-16 F1 Score.....	21
Şekil 7: İterasyon Sayısı 5 iken.....	21
Şekil 8: İterasyon Sayısı 350 iken.....	21
Şekil 9: Veri setindeki etiketli verilerin çekilmesi.....	23
Şekil 10: CNN Model Sonucu.....	25
Şekil 11: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (1) Bireyin Tahminlemesi..	25
Şekil 12: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (2) Bireyin Tahminlemesi..	26
Şekil 13: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (3) Bireyin Tahminlemesi..	26
Şekil 14: EfficientNetB0 Model Sonucu	27
Şekil 15: EfficientNetB0 Grafik Sonuçları	28
Şekil 16: EfficientNetB0 Hata Matrisi.....	28
Şekil 17: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizmli (1) Bireyin Tahminlemesi.....	29
Şekil 18: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizmli (2) Bireyin Tahminlemesi.....	29
Şekil 19: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizmli (3) Bireyin Tahminlemesi.....	30
Şekil 20: VGG16 Modeli Sonucu	30

Şekil 21: VGG16 Modeli Doğruluk Grafiği.....	31
Şekil 22: VGG16 Model Doğruluk Grafiği (2).....	31
Şekil 23: Epoch Değerine Göre VGG16 Model Grağinin Değişimi.....	32
Şekil 24: VGG16 Modeli ile Tanı Ölçütlerine Göre Otizmli(1) Bireyin Tahminlemesi	32
Şekil 25: VGG16 Modeli ile Tanı Ölçütlerine Göre Otizmli(2) Bireyin Tahminlemesi	33
Şekil 26: ResNet50 Modeli Sonucu.....	33
Şekil 27: ResNet50 Modeli Doğruluk Grafiği.....	34



SİMGELER VE KISALTMALAR DİZİNİ

APA: Amerikan Psikoloji Birliği

CNN: Evrişimli Sinir Ağları

DL: Derin Öğrenme

DSM-V: Zihinsel Bozuklukların Tanısal ve İstatistiksel El Kitabı

EfficientNetB0: CNN Mimarisi

ML: Makine Öğrenmesi

OSB: Otizm Spektrum Bozukluğu

ResNet: CNN Mimarisi

VGG16: CNN Mimarisi

YSA: Yapay Sinir Ağları

YZ: Yapay Zeka

1. GİRİŞ

Teknoloji her geçen gün daha hayatımızı kolaylaştırmak adına gelişmektedir. Bu gelişmeler ışığında hızla büyüyen yazılım sektöründe ise yapay zeka uygulamaları kullanım alanında çözüm önerilerini sunarak yeni teknolojilerin arasında yerini almıştır.

Yapay zeka, çeşitli sebeplerden kaynaklanan öğrenme zorluğu yaşayan bireylerin de hayatını kolaylaştıracak imkanlar tanıyabilmekte, aynı zamanda bireyin kişisel performansını etkileyebilecek bazı zorluklar konusunda da kişiselleştirilmiş öğrenme çözümleri üretebilmektedir. Bireylerin öğrenme hızını, yöntemini ve ihtiyaçlarını belirleme konusunda yardımcı olabilmektedir. Aynı zamanda, dikkat bozuklukları ve hiperaktivite gibi belirli handikapların etkisini de zayıflatarak bireylerin öğrenme deneyimini kolaylaştırmaktadır. Yapay zeka, hastalıkların teşhisi ve analizi konusunda da önemli bir araç olarak kullanılmaya başlanmıştır. Tıbbi görüntüleme verilerini analiz etme, algoritmaları, görüntülerdeki karmaşık örüntüleri tanımlama ve teşhis için önemli olan detayları belirginleştirme, genetik bilgilerin analizi gibi amaçlarla da kullanılmaktadır.

Nörogelişimsel bozuklukların tespit ve analizi de yapay zekanın başlıca çalışma alanlarından biri olarak son yıllarda önem kazanmaktadır. Nitekim, beyin görüntüleme teknolojileri, manyetik rezonans görüntüleme (MRI) ve fonksiyonel MRI (fMRI) ile birleştirilerek kullanılabilmektedir. DeepMind, IBM Watson Health, Stanford University Artificial Intelligence Lab (SAIL), Microsoft Healthcare, Montreal Institute for Learning Algorithms (MILA), Allen Institute for AI, Broad Institute, Element AI gibi kurum ve kuruluşlar nörogelişimsel bozuklukların yapay zekayla tespit ve teşhisi koymada çözüm yolu olmak için küresel öncü platformlar olarak öne çıkmaktadır.

Yapay zeka, tüm bireylerde olduğu gibi son yıllarda Otizm Spektrum Bozukluğu (OSB) olan bireylerin hayatında da kritik bir öneme sahip olduğu düşünülmektedir. Özellikle Otizm Spektrum Bozukluğu olduğu tespit edilmiş bireylerde yapay zeka kullanımına ilişkin ilgi giderek artmakta ve araştırmaların sayısı ve çeşitliliği artmaya devam etmektedir. Otizmle ilişkilendirilen beyin alanlarına ve bu alanların işlevlerinden, erken yoğun davranışsal müdahalelerin önemi ve otizmi olan çocukların sosyal ve bilişsel gelişimine kadar oldukça geniş bir yelpazede çalışmalar yürütülmektedir.

Erken tanı ve müdahale, genetik faktörler ve nörolojik farklılıklar gibi alanlarda yapılan çalışmalar son yıllarda büyük önem kazanmış ve otizmlili bireylerin hayatlarını kolaylaştırma bağlamında önemli aşama kaydetmiştir. Özellikle erken tanı ve müdahalenin bireylerin gelişimsel sonuçları üzerinde büyük etkisi olduğu ortaya koyulabilir. Erken müdahale, bireyin sosyal ve bilişsel gelişimini sekteye uğramadan gelişmesine yardımcı olabilir. Bu bağlamda, makine öğrenmesinin kullanımının yaygınlaşması, makine öğrenmesi (ML) ve OSB arasındaki ilişkinin artırılması da alana önemli katkılar sunmaktadır. Erken teşhis çalışmalarında aktif rol oynayan ML, otizm belirtilerini ve bu belirtilerin çeşitliliğini analiz etmek ve otizmlili bireyler için etkili tedavi stratejileri geliştirmek, biyolojik ve genetik veri analizi, dil ve sosyal etkileşim analizi amaçları doğrultusunda da kullanılabilir.

Bu çalışmanın en önemli amaçlarından biri sağlık alanında yapılan doğru tanılamaların hızlandırılması için yapay zekayı kullanarak alandaki çalışmalara katkı sunmaktır. Bu doğrultuda tezin ana konusu olan “Yapay Zeka ve Otizm Tespiti” için otizmlili bireylerin yüz özellikleri üzerinden bireylerin otizmlili olup olmadığını tahmin etmek üzere yapay zeka modellerini kullanırken bu modellerin tutarlılığını da değerlendirmek üzere DSM-V Otizm Spektrum Bozuklukları Tanı Ölçütleri ile belirli ve tekrarlanan davranış özellikleri hakkında 10 soru sorulmuş ve bu 10 soruya verilen cevaplar dikkate alınarak sonuçlar değerlendirilmiştir. Bu şekilde, otizm tespiti kesinleşmiş bireyler ile yapay zeka modellerinin verdiği tutarlı sonuçlar otizmlili bireylerin tanılama aşamasında görev yapan uzmanlara veri sunma konusunda yardımcı olabilir. Emare sayısı fazla olan ve normalden yüksek emareler ortaya koyan olguların DSM-V’e göre OSB teşhisini karşılık gelme olanağının artması bahse konu olmuştur (Kaba ve Soykan Aysev, 2019). Buna bağlı olarak DSM-V Otizm Spektrum Bozuklukları Tanı Ölçütleri olarak nitelendirilen tekrarlayan kompulsyonlar ve obsesyonlarla karakterize edilen zihinsel bozuklukların sonuçlarını ele alıp otizmlili bireylerin yüz özellikleri üzerinden bireylerin otizmlili olup olmadığı konusunda tutarlı taramalar ile yapay zeka modelleri geliştirilerek ayrı ayrı sonuçlar değerlendirilmiştir. Çalışma Python programlama dili kullanılarak Google CoLab üzerinden kodlama oluşturulmuştur. DSM-V sorularını otizmlili bireylerin yakınlarına ulaştırmak için çalışmada verilerin paylaşımı için izin alınarak Google Formlar ile oluşturulmuştur.

2. GENEL BİLGİLER

2.1. Yapay Zeka Nedir?

Yapay zeka, bilgisayar sistemlerine insan benzeri zekayı taklit etme yeteneği kazandırmayı amaçlayan bir disiplindir (Russell ve Norvig, 2016). Bishop'a (2016) göre ise öğrenme süreçlerini ve deneyimleri modelleyerek insanların yapma yeteneklerini taklit etmek için çalışır. McKinsey, Nisan 2023 yayınladığı raporda ise yapay zekayı bir makinenin genellikle insan zihniyle ilişkilendirdiğimiz bilişsel işlevleri yerine getirme yeteneği olarak tanımlamaktadır.

Derin öğrenme gibi teknikleri kullanarak bilgisayarların karmaşık veri ve problemleri işleyebilmesi ve kararlar alabilmesi için geliştirilen yöntemlerden faydalanılmaktadır (Goodfellow, Bengio ve Courville, 2016). Yapay Zeka teknikleri arasında Computer Vision (Bilgisayarlı Görme), Support Vector Machine (Destek Vektör Makinesi), Genetic Algorithms (Genetik Algoritmalar), Expert Systems (Uzman Sistemler), Speech Recognition (Konuşma Tanıma), Fuzzy Logic (Bulanık Mantık), Simulated Annealing (Tavlama Benzetimi), ANN: Artificial Neural Networks (Yapay Sinir Ağları), Hibrid (Karma), Kaotik Modelleme ve Robotik bulunmaktadır. Bununla birlikte, yapay zeka yöntemleri arasında ise makine öğrenmesi ve derin öğrenme olmak üzere iki temel alan bulunmaktadır. Yapay zeka alanı, makine öğrenimiyle bilgisayarların verileri analiz etme ve örüntüleri tanıma kapasitesini arttırırken, doğal dil işleme, insan dilini anlama ve üretme yeteneğini geliştirmeyi hedeflemektedir.

Yapay zeka disiplini, makine öğrenimi, doğal dil işleme, uzman sistemler, robotik ve veri analitiği gibi birçok alt alanı içermektedir. Yapay zeka, bilgisayarların karmaşık veri ve problemleri işleyebilmesi, öğrenebilmesi ve kararlar alabilmesi için geliştirilen yöntemler ve algoritmalar kullanmaktadır. Bu alanda kullanılan yaklaşımlar, büyük veri setlerini analiz etmek, tahminlerde bulunmak ve karmaşık problemleri çözmek için tasarlanmıştır. Yapay zeka alanı, günümüzde her sektörün ihtiyaç duyduğu bir alana dönüşmüştür. Nitekim küresel denetim şirketi PwC, yapay zekanın 2030'da küresel ekonomiye 15,7 trilyon dolar katkıda bulunmasını beklemektedir. Küresel işgücü yapısını ve dağılımını kökten değiştirmektedir. Bu sebeple yapay zeka, kanun koyucuların dahi alanına girmeye başlamıştır. Haziran ayında Avrupa Parlamentosu'nda görüşülen yapay zeka yasası, güvenli ve şeffaf bir küresel standart belirlenmesi için Midjourney ve ChatGPT gibi büyük modellere önemli yükümlülükler getirmektedir. Yapay zeka kavramı artık sıradan

vatandařtan küresel řirketlere ve devletlere kadar hayatın her alanını dönüřtüren bir teknolojidir. Bu bağlamda, etik ve regölasyon meseleleri, yapay zekanın sosyal ve ekonomik yönleriyle birlikte 21. yüzyılın en öneli konuları arasında yerini alması kuvvetle muhtemeldir. İnsanların bilgiyi entegre etme yetisini, verileri nasıl analiz ettiğini ve karar verme eylemini kolaylařtırmak için elde edilen içgöröleri yeniden düşünmesini saęlayan geniş kapsamlı bir araç olmuřtur. Statista verilerine 2023 itibarıyla küresel yapay zeka pazarının büyüklüğü 142,3 milyar dolar deęerindedir. Yapay zeka son 20 yılda gösterdięi gelişimle birçok sektörün yanı sıra e-ticaret sektöründe de hızlı bir dönüřüm başlatmış olup, piyasalar üzerindeki etkisini her geęen gün artırmaktadır. Örneğın, yapay zekâdan en çok etkilenecek sektörlerden birisi de e-ticaret olarak belirtilmektedir. Yapılan araştırma sonuçlarına göre 2025 yılında dünya genelinde e-ticaretin yapay zekâ kaynaklı elde edeceęi gelirlerin 36,8 milyar dolara ulaşması beklenmektedir (ICT Media, 2021).

Ülkelerarası rekabetin başlıca alanlarından birine evrilen yapay zeka teknolojisi, 21.yüzyıldaki jeopolitik, ekonomik, beřeri, sosyolojik ilişkileri ve stratejileri kökünden deęiřtirerek bir ulusal güvenlik meselesi haline gelmiştir (Technology & Telecommunications & Software, “Artificial Intelligence (AI) worldwide - statistics & facts”,01.06.2023,www.statista.com).

2.2. Yapay Zeka Tarihçesi

Yapay zeka, kavram olarak geęmişte kullanılan modern bilgisayarlar kadar geriye gitmektedir. Ancak yapay zeka kavramının doęuşu, Alan Turing'in 1950'de yayınlanan "Computing Machinery and Intelligence" çalışmasına uzanmaktadır. Turing eserinde sorduęu “Makineler düşünebilir mi?” sorusu yapay zeka kavramının gelişiminin temel kilometre taşlarından birini oluřturmuřtur. Yapay zeka disiplininin belirgin bir dönüm noktası, 1956'da Dartmouth Konferansı olarak bilinen bir etkinlikle geręekleşmiş ve yapay zeka arařtırmalarının ilerlemesi için bir yol haritası çizilmiştir.

Bilgisayar mühendisleri Stuart Russell ve Peter Norvig'in 1995 yılında yayınladıkları “Artificial Intelligence: A Modern Approach” çalışması ise yapay zeka arařtırmalarında referans eserlerden birine dönüşmüřtür. İki yazar, bilgisayar sistemlerini ayırt eden rasyonel düşünme yetisi ışığında yapay zekanın potansiyel hedeflerini ve tanımlamasını arařtırmışlardır. Mayıs 1997'de IBM ürünü Deep Blue'nun dünyaca ünlü satranç oyuncusu Garry Kasparov'a karřı elde ettięi başarı ise kamuoyunun konu üzerine ilgisini

yoğunlaştırmıştır. Deep Blue'nun çalışması, tüm olası hareketlerin değerlendirildiği ve ağırlıklandırıldığı sistematik algoritmasına dayanmaktaydı. Daha basit formlarda kendini ve sadece bir modele karşı başarı sağlayan ve dünyanın karmaşıklığını modelleme ve anlamlandırma kapasitesinden uzak olan Deep Blue'nun bu başarısının ardından geçen 25 yıl içinde yapay zeka tarihsel bir hızla gelişti. Bu süreçte, Yoshua Bengio, Geoffrey Hinton ve Yann LeCun üçlüsünün derin sinir ağları üzerine bilimsel çalışmaları, Geoffrey Hinton'un derin öğrenme üzerine ortaya koyduğu yeni yaklaşımlar, Ian Goodfellow'ın "Çekişmeli Üretici Ağ" (GAN) isimli tekniğin keşfi gibi yapay zekanın geliştirilmesini hızlandıran önemli çalışmalar damga vururken, ChatGPT, DeepDream, Google'ın sürücüsüz araçları gibi otonom sürüş teknolojileri, AlphaGO, DALL-E, ImageNet gibi çığır açan yapay zeka temelli programlar milyonlarca kullanıcıyla buluşmuştur. Turing'in makalesi başlangıç noktası alındığında yaklaşık 70 yıllık kısa bir geçmişe sahip olan yapay zeka sistemleri ve bilimsel gelişimi özellikle son 25 yılda büyük bir gelişme yaşanmıştır.

2.3. Otizm Nedir?

Nöro-gelişimsel bir bozukluk olarak tanımlanan bir durum olan otizm ve insanları sosyal etkileşim, iletişim ve davranış alanlarında belirgin farklılıklar sergilemesine neden olmaktadır. Otizm, genellikle erken çocukluk döneminde tespit edilen ve yaşam boyunca devam eden bir olgudur. Otizm Spektrum Bozukluğu (OSB) olarak da adlandırılan otizm, bireylerin sosyal becerileri, iletişim yetenekleri ve davranış kalıplarında çeşitlilik gösteren bir dizi özelliklerle kendini göstermektedir. OSB, duyuşsal anormalliklerin, tekrarlayan davranışların ve değişen düzeylerde zihinsel engelliliğin belirli bir kombinasyonu ile heterojen bir nöro-gelişimsel bir bozukluk olarak da tanımlanmaktadır. Bu özellikler, otizm spektrumunun genişliği nedeniyle her bireyde farklılık gösterebilmektedir. Otizm spektrumunda olan bireyler, belirli ilgi alanlarına yoğunlaşabilir, rutinlere bağlılık gösterebilir ve tekrarlayıcı davranışlar sergileyebilmektedir. The American Journal of Medicine baş editörü Joseph S. Alpert, otizmin bir spektrum bozukluğu olması sebebiyle, kişide yarattığı şiddet yelpazesi ile kendini gösterdiğini ifade etmektedir. En şiddetli haliyle, bu nöro-gelişimsel bozukluk genellikle kronik bir sağlık kurumunda kişi ömür boyu destekleyici bakıma ihtiyaç duyacak hale getirebilmektedir. Daha hafif biçiminde, otizimli bireyler başa çıkma stratejilerini öğrenerek normal bir hayat sürebilirler. Bununla birlikte, otizm sosyal

iletiřim alanındaki belirtiler, duygusal ve sosyal iletiřimde, karřılıklı diyalog kurmada, szel olmayan iletiřimde ve insani iliřkiler kuramama sorunlarını iermektedir (Troyb ve Barton, 2011). Otizm spektrum bozukluęunun nedeniyle ilgili nro-anatomik, nro-kimyasal, nro-psikiyatrik, nro-biyolojik, nro-psikolojik gibi alanlarda yapılan arařtırmalar, otizm spektrum bozukluęunun farklı trleri olduęunu ve bunun da bir tek nedenden kaynaklanmadıęını ortaya koymuřlardır. Otizmin tanılanmasına iliřkin yař genel olarak 3+-1 řeklinde deęerlendirilmiřtir. Bunun sebebi tamamen ailelerin ocukdaki konuřma algısına dayanmaktadır. Aileler ocukların  yařına kadar konuřmamasını normal grmekte ve bu baęlamda ocuęun konuřamaması onlar iin bir sorun teřkil etmemektedir.

Amerika Birleřik Devletleri Hastalık Kontrol ve Korunma Merkezleri (CDC) 2020 tarihli arařtırmasına gre gnmzde ABD’de her 36 ocuktan 1’ine otizm tanısı konulmaktadır. Bu istatistik, ABD’deki tm ocukların %2,7’sine denk gelmektedir. CDS verileri ocuklarda otizm grlme oranının 1985 yılından bugne kadar yaklařık 50 kat arttıęını gstermektedir (Centers for Disease Control and Prevention, “CDC Newsroom Releases”,10.06.2023,www.cdc.gov). İngiliz Ulusal Otizm Topluluęu (NAS) verilerine gre ise Birleřik Krallık’ta yaklařık 700.000 otizimli ocuk ve yetiřkin olduęu belirtilmektedir. lke, bu rakamla dnya zerinde otizmin en sık grldę yerlerden biridir. Bununla birlikte, Krfez lkeleri dnyada otizme en fazla rastlana lkelerdir (World Population Review). Tohum Otizm Vakfının 2021 yılı verilerine gre ise Trkiye’de gnmzde her 59 ocuktan biri otizm riski ile dnyaya gelmektedir. Bu kapsamda erken ocukluk dneminde otizm tanısının nemi giderek artmaktadır (Tohum Otizm, “Otizm Spektrum Bozukluęu”, 25.05.2023, www.tohumotizm.org.tr). Otizm Platformu’nun nceki yıllarda ngrdę verilere gre, Trkiye’de tahmini olarak 550 bin otizimli birey ve 0-14 yař grubunda 150 bin civarında otizimli ocuk bulunduęu varsayılmaktadır.


2.4. Otizm Tarihesi

Otizmin tarihi 20. yzyılın bařlarına kadar uzanırken, gnmzde kadar geen srede anlayıřımız ve yaklařımımız nemli lde geliřmektedir. İsvireli psikiyatr Eugene Bleuler, 1911’de řizofreniye baęlı belirli bir semptom grubunu tanımlamak iin “otizm” ifadesini kullanmıřtır. Otizm spektrumunun, 1940’lı yıllarda Avusturyalı bir ocuk hekimi Hans Asperger ve Leo Kanner gibi arařtırmacıların alıřmalarıyla daha

ayrıntılı bir şekilde tanımlandığı bilinmektedir. Nitekim kavram 1943 yılında Leo Kanner tarafından ilk kez tanımlanan bir bozukluk olarak literatüre girmiştir. Kanner, 1943'te, diğer insanlara karşı belirgin bir ilgi eksikliği gösteren, ancak çevresine sıra dışı bir ilgi gösteren 11 çocuğu incelediği bir rapor yayınlamıştır. Bu 11 vakada otizm tanısı konulan çocuklar sağlıklı bir bedene sahip olmalarına ve yaşlılarından farklı görünmemelerine rağmen davranışlarında çeşitli farklılıklar tespit edilmiştir (Alver ve Gümüş, 2020). Bu, genellikle “Kanner Sendromu” olarak anılan Erken Çocukluk Otizminin ilk örneği olarak tarihte yerini almıştır. Hans Asperger'in 1944 yılındaki çalışmaları, normal zeka ve dil gelişimi olan ancak sosyal ve iletişim becerilerinde güçlükler yaşayan çocuklardaki “otistik psikopati”yi tanımlamıştır. Daha sonra “Asperger Sendromu” olarak adlandırılan durum, ancak çok sonra otizm spektrumunun bir parçası olarak belirtilmiştir. Resmi olarak ilk kez 1980 yılında DSM-III'te yerini alan otizm 1994 yılına gelindiğinde DSM-IV'de “Yaygın Gelişimsel Bozukluklar” başlığı altında değerlendirilmektedir. Bu, otizmi çocukluk şizofrenisinden ayırmada çok önemli bir adım olarak kaydedilmiştir. 2013 yılında DSM-V, otizmin sınıflandırılma ve teşhis edilme şeklini yeniden tanımlamıştır. Nöroçeşitliliğe ilişkin çalışmaların artmasıyla, otizmin bir hastalık değil, nörolojik bir farklılık olduğu giderek akademik çevrelerce kabul görmektedir. Bu bağlamda, otizmde genetik ve çevresel faktörlerin anlaşılması günden güne gelişmektedir.

2.5. Yapay Zeka ve Otizm

Şekil 1'de gösterildiği gibi yapay zeka teknolojileri pek çok alanda, örneğin sağlık, robotik, üretim ve mühendislik gibi alanlarda kullanılırken hızlıca çözüm üretmeye odaklanmaktadır. Yapay zekanın otizmlili bireyler üzerinde farklı çözümler sunması da odaklanmış olduğu sağlık alanıyla doğrudan ilgilidir.



Şekil 1: Bazı Önemli Alanlarda YZ Uygulamalarının Genel Bir Görünümü

(Dlamini vd., 2020)

Teşhis ve tedavisi oldukça zor ve uzun bir süreçten oluşan otizm spektrum bozukluğu doğuştan gelen ya da yaşamın ilk yıllarında ortaya çıkan karmaşık bir nöro-gelişimsel bozukluktur (Çelik ve Şişeci Çeşmeli,2021). Bu bozukluğun fiziksel ve davranışsal olmak üzere çeşitli ayırt edici noktaları vardır. Otistik bireylerdeki yüz özelliklerindeki farklılık fiziksel anlamda en çarpıcı noktadır. Ayrıca otizmin sebeplerinde olduğu gibi tedavisinde de henüz tek bir konu üstünde fikir birliğine varılamamıştır (Danış, 2021).

2.6. DSM-V ile Otizm Spektrum Bozukluğu (OSB) Tanı Ölçütleri

Otizmli bireylerin hayatındaki zorluklar ile ilgili çeşitli araştırmalar geçmişten günümüze kadar gelmektedir. Otizm ilk kez 1943'te, Amerikalı çocuk psikiyatristi Leo Kanner tarafından tanımlanmıştır. Dünyada otizmin görülme sıklığı 68'de birdir. Dolayısıyla, ülkemizde de her 68 çocuktan birinin otizmden etkilendiği düşünülmektedir. Otizmin erkek çocuklarındaki yaygınlığı, kızlardan yaklaşık 4-5 kat fazladır. Her 42 erkek çocuktan birini ve 189 kız çocuğundan birini etkilediği kabul edilmektedir. Sosyal etkileşim ve iletişimde yetersizlikler ile sınırlı ilgiler ve yinelenen davranışlar otizmin temel özellikleri olarak kabul edilir. Bu özellikler bireyden bireye farklı yetersizlik derecelerinde görülebilmektedir (Otizm Türkiye, "Otizm",01.06.2023, www.otizmturkiye.org). En önemli ve dikkat çekici noktalardan birisi de DSM-V tanı

kriterleri ile birlikte OSB'nin tespitinde oldukça başarılı bir konuma gelmiş olmasıdır. Amerikan Psikoloji Birliği'nin (APA); 2013 yılında yayınladığı Zihinsel Bozuklukların Tanısal ve İstatistiksel El Kitabı'nda OSB tanı kriterleri güncel olarak karşımıza çıkmaktadır. DSM-5'te "Otizm Spektrum Bozukluğu" (OSB) başlığı altında Otizm, Asperger Sendromu, Atipik Otizm ve Çocukluk Dezintegratif Bozukluğu alt kategoriler olarak yer almaktadır (Cebeci ve Yenen, 2022). Bir bireyin Otizm Spektrum Bozukluğu (OSB) tanısı alabilmesi için belirlenen tanı kriterleri; (a) sınırlı/tekrarlanan ilgi ve davranış örüntüleri, (b) sosyal etkileşim ve iletişimde belirgin yetersizliklerle birlikte iki boyutta ortaya çıkmasıdır (Odluyurt ve Çattık, 2018).

Geçmişte veya halihazırda kendini gösteren sınırlayıcı, tekrarlayıcı davranış, ilgi veya aktiviteler (Aşağıdaki maddelerden en az ikisinde kendini gösterir.)

1. Kalıplaşmış veya tekrarlayıcı motor hareketler, nesne kullanımı veya konuşma (örneğin, basit motor stereotipler, oyuncakları sıralama veya nesneleri çevirme, eko-fali, kişisel deyimler).
2. Aynılığın ısrarı, rutinelere esnek olmayan bağlılık veya ritüel davranış veya sözsüz davranış kalıpları (örneğin, küçük değişikliklerden aşırı rahatsızlık, geçişlerde zorluklar, katı düşünce kalıpları, selamlama ritüelleri, her gün aynı yolu kullanma veya aynı yiyecekleri yeme ihtiyacı).
3. Yoğunluk veya odak açısından anormal olan son derece sınırlı, sabitlenmiş ilgiler (örneğin, olağandışı nesnelere güçlü bir şekilde bağlanma veya bunlarla meşgul olma, aşırı sınırlı veya perseveratif ilgi).
4. Duyusal girdilere veya çevrenin duyuşal yönlerine ilişkin aşırı veya az tepki verme (örneğin, acıya/sıcaklığa karşı bariz bir kayıtsızlık, belirli seslere veya dokulara ters tepki, nesnelerin aşırı derecede koklanması veya dokunulması, ışıklar veya hareketle görsel olarak büyülenme).

Semptomlar, erken gelişim döneminde olmalıdır (ancak sosyal talepler sınırlı kapasiteleri aşınca veya daha sonraki yaşamda öğrenilmiş stratejilerle maskeleninceye kadar tam olarak ortaya çıkmayabilir).

Belirtiler, sosyal, mesleki veya diğer önemli alanlarda mevcut işlevsellikte klinik olarak anlamlı bozulmaya neden olur.

Bu nöro-gelişimsel bozukluklar, zihinsel yetersizlik (zihinsel gelişim bozukluğu) veya genel gelişimsel gecikme ile daha iyi açıklanamaz. Zihinsel yetersizlik ve otizm spektrum bozukluğu sıklıkla birlikte görülür; otizm spektrum bozukluğu ve zihinsel yetersizlik ek tanıların konulabilmesi için sosyal iletişimin genel gelişim düzeyi için beklenenin altında olması gerekir (Autism Speaks, “Autism Diagnosis Criteria: DSM-5”,05.06.2023, www.autismspeaks.org).

2.7.Derin Öğrenme Modelleri

Çalışma Makine Öğrenmesinin alt kümesi olan Derin Öğrenme’nin mimarilerinden biri olan Convolutional Neural Network (CNN) olarak isimlendirilen sinir ağlarını temel alınmıştır. Bu çalışmada üç derin öğrenme algoritması kullanılmıştır. Bunlar CNN, EfficientNetB3, VGG16 algoritmalarıdır. Veriler bu üç algoritma üzerinde eğitilmiştir. Sonuçları eğitilen algoritmalar arasında karşılaştırılmıştır.

2.7.1.Convolutional Neural Network (CNN)

Evrişimsel Sinir Ağı olarak ilk çağrışım biyolojik olsa da bu algoritma, nesne tanıma konusunda en önemli yöntemlerden biridir. Burada fikri temel alan konu nesnelerin tespit edilmesidir. Farklı nesnelerin tespitinde kullanılmak üzere geliştirilen CNN elindeki görüntü veri setini tek katmanda değil, birden fazla katman üzerinde inceleyen bir algoritmadır (Değirmenciler ve ark., 2022). 2017’de Gazi Mühendislik Bilimleri Dergisi’nde CNN algoritmasının hayvanların görme merkezinden esinlenerek ortaya atıldığını ileri sürülmüştür (Şeker ve ark., 2017).


CNN uygulaması esas olarak görüntü işlemedir. Bununla birlikte, biyomedikal ve ses algılama gibi doğal dil işleme, birçok farklı alanda incelenmektedir. CNN, X-ray ve MR görüntülerinde tümörleri ve diğer düzensizlikleri daha doğru bir şekilde tespit edebildiği için tıbbi görüntülemede oldukça verimli bir uygulamadır. CNN modelleri, akciğer gibi bir insan vücudu bileşeninin resmini analiz edebilme ve önceden işlenmiş görüntülere dayalı olarak anormallikleri tespit edebilme yetisine sahiptir. Evrişimli sinir ağı, bilgisayarlardaki görme görevlerinde ve radyoloji de dahil olmak üzere bu işlemeye ihtiyaç duyan birçok sektörde ilgi çeken bir derin öğrenme yöntemi olarak ön plana çıkmaktadır.

CNN, katmanlı yapısıyla gizli öznitelikleri çıkararak işlem yapmaktadır (Cengil ve Çınar 2016). Görüntü sınıflandırma konusunda CNN kullanmış birçok çalışma bulunmaktadır.

Bunlardan birisi olan A. Krizhevsky tarafından gerçekleştirilen derin evrişimsel ağlar ile ImageNet sınıflandırmasıdır.

CNN algoritması görüntüyü çeşitli katmanlarda işlemektedir. Bu katmanlar sırasıyla Convolutional Layer, Non-Linearity Layer, Pooling (Downsampling) Layer, Flattening Layer, Fully-Connected Layer katmanlarıdır (Alzubaidi ve ark., 2021). Tipik görünümü, birkaç konvolüsyon katmanı ve bir havuzlama katmanından oluşan bir yığının tekrarlarından ve bir veya daha fazla tam bağlantılı katmandan meydana gelmektedir. Girdi verilerinin bu katmanlar aracılığıyla çıktıya dönüştürüldüğü adım ileri yayılım olarak adlandırılmaktadır.

Şekil 2’te de gösterildiği gibi ana hatları ile örnek CNN katmanlarının işlem sırası verilmiştir.



Şekil 2: CNN Mimarisinin Katmanları

(Alzubaidi ve ark., 2021)

2.7.1.1. CNN Katmanları

CNN mimarisi, birden fazla katmandan oluşur. CNN mimarisindeki her katman, işlevi de dahil olmak üzere aşağıda ayrıntılı olarak açıklanmaktadır.

Convolutional Layer: Bu katman, bir giriş veri kümesi üzerinde evrişim işlemi gerçekleştirmektedir. Evrişim işlemi, bir çekirdek (veya filtre) kullanır ve bu çekirdek, giriş verisinde kaydırılarak, belirli bir özellikler setini öğrenerek tespit etmektedir. Convolutional layers, özellikle görüntü işlemede oldukça etkili bir araçtır çünkü yerel özelliklerin öğrenilmesini kolaylaştırmaktadır

Non-Linearity Layer: Tipik evrişimsel katmanlar doğrusal sistemlerdir, dolayısıyla ifade güçleri sınırlıdır. Bunun üstesinden gelmek için çeşitli doğrusal olmayan CNN'ler içinde aktivasyon fonksiyonları olarak kullanılırken ayrıca birçok havuzlama stratejisi uygulanmıştır. Sinir ağı, doğrusallığı takip etmeyen fonksiyonlara başarılı bir şekilde yaklaşabilir veya doğrusal olmayan bir karar sınırı tarafından bölünen bir fonksiyonun sınıfını başarılı bir şekilde tahmin edebilir.

Pooling (Downsampling) Layer: Bu katman, evrişimli katmanların çıktısını alarak onu daha küçük bir boyuta düşürmektedir. Bu katmanın işlevi aşırı öğrenmeyi önlemek ve hesaplama verimliliğini arttırmaktır. İki temel pooling türü vardır: “max pooling ve average pooling”. Max pooling, maksimum değeri seçerken, average pooling bu bölgedeki tüm değerlerin ortalamasını alır.

Flattening Layer (Düzleştirme): Flattening katmanı, bir önceki katmandan gelen çıktıyı tek boyutlu bir vektöre dönüştürmek için kullanılmaktadır. Bu işlem pooling (havuzlama) katmanlarından sonra gerçekleştirilir ve bu çıktıyı tam bağlantılı (fully connected) katmanlara girebilir hale getirmektedir. Bahse konu işlem, modelin giriş verisindeki öğrenilmiş özelliklerin kullanılabilmesini sağlayarak kompleks öğrenme görevlerini gerçekleştirilebilmektedir.


Fully-Connected Layer: Bu katmanda her bir nöron önceki katmandaki tüm nöronlara bağlıdır ve bu katmandan çıkan çıktılar sonraki katmana tamamen bağlanmaktadır. Bu durum, bu katmandaki her bir nöronun önceki katmandaki tüm bilgileri alabileceği anlamına gelir. Bu katmanlar genellikle ağırlı çıktı katmanı olarak işlev görür ve arkadaki katmanlardan gelen özelliklerin birleştirilmesi ve hedeflenen çıktı sınıflarına karar verme işlemi gerçekleştirilmektedir.

2.7.1.2.VGG16

VGG16, VGGNet olarak da adlandırılan VGG modelini ifade eder. 16 katmanı destekleyen evrişimli sinir ağı (CNN) modelidir (Understanding VGG16:Concepts-Architecture and Performance, “What Is VGG16?”,29.05.2023,www.datagen.tech). 2022 Esen’in vurguladığı, etiketli görüntülerden öznetelik çıkarabilen çok katmanlı derin öğrenme mimarilerinden biri olan VGG-16; kendinden önce olan modellere göre temel farkı evrişimli katmanlarının ikili ya da üçlü şekilde kullanılmasıdır.Fully Connected(FC) katmanında 4096 nöronlu öznetelik vektörüne dönüştürülürken, FC katmanı çıkışında 1000 sınıflı softmax diye isimlendirilen fonksiyon ile başarıyı hesaplanmaktadır. 138

milyon parametre hesabı yapılmakta olan VGG-16 algoritması girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) arttığını makalesinde belirtmiştir (Esen ve Onan, 2022).

Şekil 3'te örnek bir VGG-16 katmanları gösterilmiştir.



Şekil 3: VGG-16 Katmanları

(Keçeli ve Kaya, 2018)

2.7.1.3.EfficientNetB0

Efficient-Net, CNN modeli ölçeklendirme tekniğini kullanmaktadır. Verimli sonuçlara ulaşmak için basit bileşik katsayılar kullanmaktadır. Geleneksel yöntemlerin aksine EfficientNet, her boyutu uyumlu şekilde ölçeklendirmektedir. Geleneksel yöntem dediğimiz bir ağın genişliği, çözünürlüğünü, derinliğini arttıran geleneksel yöntemler olarak nitelendirilmektedir. Dolayısıyla her boyutun tutarlı bir şekilde ölçekleniyor olması en önemli fark diyebiliriz (Batool ve Byun, 2023).

Modellerin performansı, her boyut ölçeklendiğinde iyileştirilir, ancak her ağ özelliği, kaynak kullanılabilirliği konusunda dengelendiğinde performans önemli ölçüde artar. Sistematik artış performansını olumlu yönde etkileyebilmektedir. Böylece modeli küçültmeye çalışırken derinlik, genişlik ve çözünürlük açısından ölçekleme yaparak daha verimli sonuçlar üretir (Uçar, 2021).

3. GEREÇ VE YÖNTEM

Araştırmada, kullanılan veri setinde bireylerin fotoğrafları train datası, validation datası, test datası ile eğitilip otizmlili mi değil mi tespitinin yapılması amaçlanmıştır. Veriler Kaggle sitesi üzerinden alınmıştır. Aynı zamanda DSM-V otizm tanı kriterleri doğrultusunda otizmlili bireyler için sorulan sorular ile sonuçlar elde edilmiş, birkaç gerçek örneklem üzerinden eğitilmiş modele tahmin yaptırılmıştır. Her iki sonucun değerlendirilmesi yapılarak sonuca ulaşılmıştır.

3.1. Araştırmanın Tipi

Araştırma tipi Karma (Hibrit) Araştırma olan nicel ve nitel araştırma yöntemlerini birleştiren bir yaklaşımdır. Eğitilen yapay zeka modelinde elde edilmiş sonuçlardan yola çıkarak otizm tespiti konusunda performansı değerlendirmek için kullanılmıştır.

3.2. Araştırmanın Modeli

Araştırma modeli olarak yapay zekanın alt başlıklarından olan Derin Öğrenme’de Makine Öğrenmesi modeli ile deneysel model seçeneği, train validation verisi ve test verisi olarak ayırmış olduğum veri setinde, kontrollü olarak performansın iyileştirilmesi adına testler gerçekleştirilmiştir. Dolayısıyla bu modelde araştırma modeline ilişkin oluşturulan eğitim ve test verileri ile kontrol sağlanmış olup, yapay zeka modelinin otizm tespiti üzerinde sonuçlarına varılmış ve model performanslarında karşılaştırmalar yapılmıştır.

3.3. Araştırmanın Evren ve Örneklemi

Araştırma otizmlili bireyleri, otizmlili bireyin tespitinde çalışan uzmanları kapsamaktadır.

3.4. Veri Toplama Araçları

Araştırmada veri toplama süreci için çeşitli araçlar kullanılmıştır. Bu araçlar, araştırma amaçlarına ve verilerin toplanmasına uygun olarak seçilmiştir. Veri toplama araçları şu şekildedir:

3.4.1. Veri Kaynağı: Kaggle isimli sitesinin sağladığı veri seti ile fotoğraf verileri üzerinde çalışılmıştır. Aynı zamanda Google Form kullanılarak otizmlili bireylerin tespit

aşamasında kullanılan soruların yanıtları ile veri sağlanmıştır. Anket araştırmacı tarafından otizm alanında uzman olan kişi tarafından destek alınarak hazırlanmıştır.

3.4.2.Anket: Katılımcılardan araştırma konusuyla ilgili soruların yer aldığı yapılandırılmış bir anket formu kullanılmıştır. Anketler, bireylerle yüz yüze görüşmeler veya çevrimiçi olarak dağıtılarak toplanmıştır. Ankette bireyin fotoğrafı ile birlikte araştırmaya uygun DSM-V kriterlerini karşılayıp karşılamadığı bilgisi alınmıştır.

3.4.3.Doküman İncelemesi: İlgili literatürden ve belgelerden elde edilen veriler araştırmada kullanılmıştır. Bu kapsamda, daha önce yapılan çalışmalar, raporlar, resmi kaynaklar veya diğer dokümanlar incelenerek veriler toplanmıştır.

Bu veri toplama araçları, araştırma sürecinde kullanılan veri toplama gereksinimlerine göre seçilmiş ilgili yöntemler doğrultusunda yazılmıştır.

3.5.Verilerin Analizi

Araştırmada veri analiz süreci için çeşitli analiz sürecinden geçmiştir. Bu analiz, araştırma amaçlarına ve verilerin toplanmasına uygun olarak yapılmıştır. Veri analiz süreci şu şekildedir:

3.5.1. Kodlama Verileri

Bu veri seti bireylerin yüz görüntülerinden oluşan bir veri setidir. Veri setinde otistik ve otistik olmayan olmak üzere iki sınıf vardır. Otistik olmayan sınıf (non autistic), otizm teşhisi konmamış bireylerin resimlerini içermektedir. Veri setindeki görüntüler .jpg formatındaki görüntülerden oluşmaktadır.

Kaggle sitesi üzerinden alınmış olan bu veri kümesindeki görüntüler, Google aramalarından ve çeşitli otizm odaklı web sitelerinden indirmelerden elde edilen görüntülerin bir sonucu olarak çeşitli boyutlardadır. Modeli eğitirken, tüm görüntülerin aynı şekilde olması gerekir. Bu nedenle, tüm görüntülerin aynı boyutta yeniden şekillendirilmesi gerekir. Görüntüler yeniden boyutlandırıldığında, tüm görüntülerin boyutları eşitlenmiştir.

3.5.2. Veri Setinin Özellikleri

Kaggle üzerinden veri sağlanan veri seti toplam 2926 fotoğraftan oluşmaktadır. Bu veri seti otistik ve otistik olmayan olacak şekilde etiketlenmiştir.

train datası: 2526

validation datası: 200

test datası: 200

olmak üzere veri seti ayrılmıştır.

DSM-V otizm tanı kriterleri için ise toplamda 10 soru sorulmuştur. sorulan sorulardan evet hayır niteliğinde cevaplar alınarak araştırmaya dahil edilmiştir. Sorulan sorular ise sırasıyla aşağıdaki gibidir:

Çocuğunuzun farklı davranışlar sergilediğini ne zaman fark ettiniz?

Çocuğunuz yineleyici davranışlar sergiliyor mu?

Çocuğunuzun nesnelere veya durumlara takıntısı var mı?

Çocuğunuz aynılıkta ısrar ediyor mu?

Çocuğunuz diğer kişilerle iletişim kurarken sorun yaşıyor mu?

Çocuğunuzda ekolali veya gecikmiş ekolali var mı ? (Sürekli aynı kelimeleri tekrar etme)

Çocuğunuzda dil gelişiminde gecikme veya aksama oldu mu?

Çocuğunuzda bireysellik eğilimi var mı? (Tek başına kalma isteği, etkinlik yapma isteği vs)


Çocuğunuz duysal anlamda hassasiyet taşıyor mu?

Çocuğunuzda problem davranış (ağlama, vurma, kendine zarar verme vb.) var mı?

yöneltlen bu soruların yanıtlarına göre belli bir yüzde oran elde edilip, eğitilmiş olan model ile de karşılaştırılarak tahmini yapılan birey için sonuca varılmıştır.

3.6. Araştırmada Kullanılan Modeller ve Sonuçları

3.6.1. CNN



Şekil 5: CNN Mimarisi

Keras kütüphanesini kullanarak oluşturduğum Evrişimli Sinir Ağı (CNN) ile kütüphane ve modülleri içe aktardıktan sonra model oluşturmak için *Sequential*, katmanları almak için *conv2D*, havuzlama dediğimiz Pooling katmanları için *MaxPooling2D* ve özellikleri düzleştirme işlemi için *Flatten* kullanarak *Dense* ile tam bağlı katmanlar oluşturulmuştur.

Model mimarisini tanımlarken evrişimli katman olan *conv2D* ile 32 adet olmak üzere (3,3) boyutunda filtre kullanılmıştır. Bu model 'relu' aktivasyon fonksiyonuyla başlamaktadır. Ardından MaxPooling ile (2,2)' lik havuzlama katmanı yer almaktadır. Ardından ikinci bir evrişimli katman yine aynı özelliklerde olan 32 kernel relu aktivasyon fonksiyonu ile devam etmektedir. Bir sonraki adımda havuzlama katmanı gelmektedir. Flatten ile düzleştirilerek 1D vektöre dönüştürme gerçekleştirilmektedir. Ardından iki Dense eklendikten sonra Birinci Dense 128 birim olmak üzere relu aktivasyonunu kullanırken, ikinci Dense 1 birim olacak şekilde ve ikili sınıflandırmayı kullanan 'sigmoid' aktivasyon fonksiyonu ile tamamlanmaktadır. Veriyi compile ederken optimizasyon fonksiyonu olan adam kullanılırken, metric olarak accuracy değeri dikkate alınmaktadır. Aynı zamanda loss değeri için binary crossentropy ile model compile edilmektedir.

Model mimarisi kurulduktan sonra ImageGenerator ile train, test ve valdiation fotoğraflar oluşturulmaktadır. Bu aşamada veri artırımı eğitim verisinde kullanılırken ölçeklendirme, yakınlaştırma aralığı yatay çevirmeler yer almaktadır. Eğitimi gerçekleştirilirken *steps_per_epoch* ile her epoch için eğitim ayarı yapılmaktadır, *validation_steps* ile

doğrulama için kaç adımın dikkate alınacağı önemsenmektedir. 350 iterasyon ile F1-score %53 accuracy değeri %98 olan bu modelde beta değeri ve sinir ağlarındaki aşırı öğrenmeyi engelleyecek drop-out, batch normalization gibi yöntemler ile model iyileştirmeye gidilmiştir. *Şekil 5*’de oluşturmuş olduğum CNN mimarisi yer almaktadır.

3.6.2. EfficientNetB0

EfficientNetB0 modelindeki 30 iterasyon callback 14 olmak üzere efficientNet keras kütüphanesi ile alınarak CNN mimarisinde model oluşturulup LeakyReLU (alpha 0.2) ile model eğitimi yapılmıştır. ReLU, girdi değerine göre işlem yapar eğer 0’dan büyükse direkt olarak aktarılırken, 0’dan küçükse 0 olarak işleme devam eder. Leaky ReLU, Relu’nun bu davranışından farklı olarak, girdi değeri 0’dan küçükse negatif bir eğim ile doğrusal olarak aktarır. Burada callback kullanılmasıdaki amaç ise aşırı öğrenme durumunu engelleyerek eğitilen veri için en doğru sonucu verecek epoch (iterasyon) ile sonuca ulaşmaktır.

3.6.3. VGG-16

Model keras kütüphanesinden VGG-16 modelini import edilerek, kendi parametrelerimi seçerek oluşturulmaya başlanmıştır. Tıpkı CNN mimarimde kullandığım data ayırma yöntemlerim ile burada da train, test, validation verileri dikkate alınmıştır. Batch size 12 seçilerek train, test, validation verileri target_size (224, 224) olmak üzere seçilmiştir. Kernel h5 dosyası ile ağırlıkları belirleyerek keras kütüphanesi ile çektiğim VGG-16 modelime shape olarak (224, 244, 3) ile devam edilmiştir. Model sırasıyla; *conv2D*, *conv2D*, *MaxPooling2D*, *conv2D*, *conv2D*, *MaxPooling2D*, *conv2D*, *conv2D*, *conv2D*, *MaxPooling2D*, *conv2D*, *conv2D*, *conv2D*, *MaxPooling2D*, *conv2D*, *conv2D*, *conv2D*, *MaxPooling2D*, *global_max_pooling2d* olacak şekilde modellenmiştir. 512 çıkış katmanı ile toplam 14,714,688 parametre ile sonuç vermektedir. Çıkan modelde CNN katmanı eklemek için *basemodel1* olarak adlandırılan modeli bir kez daha kendi CNN mimarisine eklenmektedir. Mimari Sequential ile tanımlandıktan sonra Flatten eklenerek Dense ile 3 ‘relu’ ve 1 ‘sigmoid’ aktivasyon fonksiyonu ile çıkış katmanına ulaşmaktadır. Dense katmanları 128, 64, 32 ve 1 olan çıkış katmanı ile adam optimizasyon fonksiyonu ile 25 epoch değeri ile loss 0.5486, accuracy 0.7233, val_loss 0.5873, val_accuracy 0.6900 sonucunu verirken aslında çok iyi sonuçlar alınmadığından kendi mimarim ile devam etmeye karar verilmiştir. CNN mimarisi ile karşılaştırmak için 350 ile eğitilen VGG-16 model, loss 0.3995, accuracy 0.8667, val_loss 0.5428, val_accuracy 0.7150 sonucunu

Vermektedir. F1 score olarak alınan sonuç ise; %57 oranında sonuç vermiştir.

```
17/17 [=====] - 43s 3s/step  
F1 Score: 0.5714285714285713
```

Şekil 6: VGG-16 F1 Score

Şekil 6'da skor iyileştirme için F1 skorun beta değeri ile ilgili iyileştirmeler yapılabilir.

3.6.4. Resnet50

Model keras kütüphanesini kullanarak ResNet50 ile kurulmuştur. Oluşturtulan model üzerinde (224,224,3) input shape kullanılmıştır. Optimizasyon fonksiyonu olan SGD ile learning rate 0,001 seçilip, momentum değeri 0,9 olarak belirlenmiştir. Bu mimari de CNN ile aynı 350 epoch değeri verilip modelin eğitimi izlenmiştir. Sonuç olarak 5 epoch değerinde daha başarılı bir eğitim gerçekleştirdiğini aşırı öğrenmeden kaçınmak için epoch ayarını yaparken de dikkatli olunmalıdır.

```
Epoch 7/350  
40/40 [=====] - 618s 15s/step - loss: 0.0171 - accuracy: 1.0000 - val_loss: 0.6098 - val_accuracy: 0.7900  
Epoch 8/350  
40/40 [=====] - 624s 16s/step - loss: 0.0106 - accuracy: 1.0000 - val_loss: 0.6336 - val_accuracy: 0.7950  
Epoch 9/350  
40/40 [=====] - 619s 15s/step - loss: 0.0078 - accuracy: 1.0000 - val_loss: 0.6570 - val_accuracy: 0.8000  
Epoch 10/350  
40/40 [=====] - ETA: 0s - loss: 0.0063 - accuracy: 1.0000
```

Şekil 7: İterasyon Sayısı 5 iken

```
Epoch 7/350  
40/40 [=====] - 618s 15s/step - loss: 0.0171 - accuracy: 1.0000 - val_loss: 0.6098 - val_accuracy: 0.7900  
Epoch 8/350  
40/40 [=====] - 624s 16s/step - loss: 0.0106 - accuracy: 1.0000 - val_loss: 0.6336 - val_accuracy: 0.7950  
Epoch 9/350  
40/40 [=====] - 619s 15s/step - loss: 0.0078 - accuracy: 1.0000 - val_loss: 0.6570 - val_accuracy: 0.8000  
Epoch 10/350  
40/40 [=====] - ETA: 0s - loss: 0.0063 - accuracy: 1.0000
```

Şekil 8: İterasyon Sayısı 350 iken

Epoch değerini arttırırken kontrollü bir eğitim için aşırı öğrenmeden kaçınmak için aşırı öğrenmenin metotlarını kullanarak bu durumun önüne geçilebilmektedir. Sonuç olarak 350 epoch değeri verildiğinde 7. epochda aşırı öğrenme olup, modele devam edilmesi ve sonuç elde etmek için 5 epoch yeterliliğine karar verilmiştir. Loss değeri 0,0871 olup accuracy değeri ise 0,9798 'dir.

4. BULGULAR

Veri setini derin öğrenme ile bireylerde otizm tespiti yapabilmek için veri seti olarak Kaggle sitesinden hazır şekilde alınan 2926 görüntülü dosya oluşturulmuştur. Veri setinin içindeki fotoğraflar "otizimli" ya da "otizimli değil" şeklinde etiketlenmiştir. Autistic (Otistik) ve Non_Autistic (Otistik Olmayan) olmak üzere 2 sınıf oluşturulmuştur.

Eğitim veri seti için 2526 görüntü, test veri seti için 200, validasyon veri seti için 200 olmak üzere görüntü ile modeller eğitilmiştir. Çalışma, Microsoft işletim sistemi üzerinde Google Colab'de Python diliyle yazılmıştır. Sınıflandırma için derin öğrenme modellerinden CNN, ResNet50, VGG-16 ve EfficientNetB0 derin öğrenme algoritmaları kullanılmıştır. Bütün algoritmalar 'Google Colab' ile Jupyter Notebook ortamında çalıştırılmıştır.

Son olarak otizm belirtisi kesinleşmiş bireylerin fotoğrafları örnek alınarak eğitilmiş model üzerinden testi gerçekleştirilmiş, yine otizm teşhisi kesin olan bireyin ailesi tarafından, ölçeklendirilmiş sorulara verilen yanıt üzerinden otizm olma olasılıkları karşılaştırılmıştır. Hem eğitilmiş modelin gerçek, otizm teşhisi kesin olarak konulmuş bireyin fotoğraf sonucunda elde edilen parametre ölçütlerinin sonuçları, hem de otizm teşhisi kesin olan bireyin ailesi tarafından yanıtlanan anket sonucu elde edilen oran karşılaştırılarak sonuca varılmıştır.

Çalışmada temel olarak kullanılan; numpy, pandas, torch, matplotlib, tensorflow ile keras temel alınarak model doğrultusunda gerekli tüm kütüphaneler kullanılmıştır.

Bu çalışmada dört model eğitimi analizinden oluşmaktadır. İlk olarak CNN temel mimarisi kullanılarak keras kütüphanesi esas alınıp, modelde kullanılmak üzere CNN ara katmanları içinde aktivasyon fonksiyonu olarak "reLu aktivasyon fonksiyonu" na karar verilmiştir. Modelin optimizasyonunu sağlamak için adam optimizasyonu kullanılmaktadır. Veri setinde çıkış katmanı için "autistic" ve "non_autistic" olarak iki sınıf olduğundan loss değeri olarak "binary_crossentropy" esas alınmıştır. Metrik değerinde ise ilk etapta "accuracy" değeri ile ilerleme kaydedilmiştir.

EfficientNetB0 modelinde hata matrisi ile accuracy loss değerleri değerlendirilmiştir.

VGG-16 algoritmasında hiper parametre olarak öncelikle random seed, learning rate epoch(iterasyon sayısı) ve batch size dikkate dikkate alınmıştır.

4.1.Kodlama

Veri seti çekildikten sonra çalışmanın ilk aşamaları olan veriyi tanımak için görüntüler incelenmiştir. Şekil 5’de gösterildiği üzere veri setinde etiketli olan bireylerden bir görüntüler çekilmiştir.



Şekil 9: Veri setindeki etiketli verilerin çekilmesi

Veri seti Google Drive metodu ile çekildikten sonra CNN algoritmasını ile Image Generator kullanarak verileri train, test, valid olmak üzere model eğitimi için hazırlanmıştır. Daha sonra veri setinde ‘Autistic’ ve ‘non_autistic’ olmak üzere etiketlenen verilerin örnekleri yer almaktadır.

Model eğitime artık hazır olan veriler için kritik olan epoch değerinin arttıkça CNN algoritmasının daha iyi öğreniyor olmasıdır. İlk etapta epoch değeri 50 iken loss değeri % 49,80 accuracy değeri % 76,41 çıkan modelde epoch değerini arttırdıkça modelin iyileştiğini gözlemlenmektedir. Bir sonraki aşamada 150, 250, 350 epoch değerleri sonucunda sırasıyla loss değeri % 25,76 ve accuracy değeri % 88,28 , loss değeri % 14,43 ve accuracy değeri % 94,69, loss değeri % 3,06 ve accuracy değeri % 98,75 olduğu gözlemlenmiştir. Model eğitimi sonunda otizm teşhisi kesin olan bireyin fotoğrafı modele verildiğinde model doğru tahminde bulunmuştur.

Oluşturulan CNN, ResNet50, VGG-16, EfficientNetB0 modelleri ile veri setinin eğitilmesi ve sonrasında test verilerinin modele verilmesi ile *Tablo 1*’de belirtilen

sonuçlar elde edilmiştir. Resnet50 hariç 3 model üzerinde gerçek zamanlı sonuçlarla tahminler yapılmıştır.

VGG-16 modelinde tutarlı sonuçlar elde etmek ve modeli doğru eğitmek için veri setinin yeterli gelmeme durumuna karşın görüntülerin merkezlenmesi için ortalama değerler kullanılmıştır. Bu, veri artırma yöntemlerinden biridir ve aşırı uyum (overfitting) riskini azaltabilir. Dolayısıyla modeli eğitmeden önce batch size ve target size beraberinde ortalama değerler de dikkate alınmıştır. Model eğitiminin sonunda loss, accuracy, validation loss, validation accuracy değerleri takip edilmiştir. Loss değerinin azalması sırasında accuracy değerinin artması, eş zamanlı olarak validation loss değerinin de azalması beklenir. Model de ise yine CNN algoritmasında olduğu gibi epoch değerinin artması modeli iyi yönde etkilemiştir diyebiliriz.

Tablo 1: Modellerin Karşılaştırılma Tablosu

Model Adı	Sınıflandırma	İterasyon(en iyi sonuç)	Loss değeri	Doğruluk
CNN	Otistik/ Otistik Değil	350	0.0306	0,9875
EfficientNetB0	Otistik/ Otistik Değil	14	0.2213	0.9143
VGG-16-	Otistik/ Otistik Değil	150	0.4917	0.7450
Resnet 50	Otistik/ Otistik Değil	5	0.0871	0.9798

CNN Modeli için sonuçlar aşağıdaki gibidir;

Şekil 10'da yer alan CNN modelindeki 350 iterasyon, 32 batch size ile model eğitiminde oldukça iyi bir model eğitimi diyebiliriz. Daha iyi modeller için de hiper parametrelerde daha da tutarlı gözlemler yaparak model eğitilebilir.

```
Epoch 348/350
20/20 [=====] - 4s 187ms/step - loss: 0.0289 - accuracy: 0.9953
Epoch 349/350
20/20 [=====] - 4s 184ms/step - loss: 0.0661 - accuracy: 0.9781
Epoch 350/350
20/20 [=====] - 5s 229ms/step - loss: 0.0306 - accuracy: 0.9875
```

Şekil 10: CNN Model Sonucu

Gerçek zamanlı sonuçlar için otizmli bireyin fotoğrafı her model için tahminlemede kullanılmış fakat veri izninden kaynaklı yalnızca ek bölümünde paylaşılacaktır. Aşağıdaki upload edilen fotoğraf sonucu da gerçek birey üzerinde yapılan tahminlemenin bir sonucudur.

Her modele aynı bireyin 3 fotoğrafı olmak üzere toplam 9 fotoğraf tahmini DSM-V tanı ölçütleri ile bireylerin tahminlemesi yapılmıştır.

CNN-Otizmli 1. birey:

```
uploaded=files.upload()

Dosyaları Seç with_autism_1.jpeg
• with_autism_1.jpeg(image/jpeg) - 207018 bytes, last modified: 23.06.2023 - 100% done
Saving with_autism_1.jpeg to with_autism_1.jpeg

print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 0s 18ms/step
[0.]
with_autism_1.jpeg : Autistic
```

Şekil 11: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (1) Bireyin Tahminlemesi

CNN-Otizmli 2. birey:

```
uploaded=files.upload()

Dosyaları Seç Autism_3.jpeg
• Autism_3.jpeg(image/jpeg) - 35328 bytes, last modified: 19.07.2023 - 100% done
Saving Autism_3.jpeg to Autism_3.jpeg

print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 0s 49ms/step
[1.]
Autism_3.jpeg : Non Autistic
```

Şekil 12: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (2) Bireyin Tahminlemesi

CNN-Otizmli 3. birey:

```
uploaded=files.upload()

Dosyaları Seç Autism_4.jpeg
• Autism_4.jpeg(image/jpeg) - 111609 bytes, last modified: 19.07.2023 - 100% done
Saving Autism_4.jpeg to Autism_4.jpeg

print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 0s 19ms/step
[6.842967e-23]
Autism_4.jpeg : Autistic
```

Şekil 13: CNN Modeli ile Tanı Ölçütlerine Göre Otizmli (3) Bireyin Tahminlemesi

Yukarıdaki 3 birey için gerçek zamanlı olarak paylaşılan veriler *Tablo 2*'deki gibidir. *Tablo 2*'deki sorulara göre %99.99 oranı ve %88.88 oranındaki tanı ölçütü yapılan bireylerin fotoğrafları modele verilmiştir.


EfficientNetB0 Modeli için sonuçlar aşağıdaki gibidir;

Şekil 10’de yer alan EfficientNetB0 modelindeki 30 iterasyon callback 14 olmak üzere efficientNet keras kütüphanesi ile alınarak CNN mimarisinde model oluşturulup LeakyReLU (alpha 0.2) ile model eğitimi yapılmıştır. ReLU, girdi değerine göre işlem yapar eğer 0’dan büyükse direkt olarak aktarılırken, 0’dan küçükse 0 olarak işleme devam eder. Leaky ReLU, Relu’nun bu davranışından farklı olarak, girdi değeri 0’dan küçükse negatif bir eğim ile doğrusal olarak aktarır (Derin Öğrenme, “Aktivasyon Fonksiyonları”, 13.07.2023, <https://atcold.github.io>). Burada callback kullanılmasıdaki amaç ise aşırı öğrenme durumunu engelleyerek eğitilen veri için en doğru sonucu verecek epoch(iterasyon) ile sonuca ulaşmaktır.

Şekil 14 ‘de gösterildiği gibi iterasyon sayısına bağlı olarak daha iyi öğrenen bir model söz konusudur.


	loss	categorical_accuracy	val_loss	val_categorical_accuracy
0	0.684795	0.691079	1.534214	0.570833
1	0.393526	0.834443	1.682677	0.604167
2	0.332357	0.859299	0.580243	0.791667
3	0.282233	0.890812	0.467949	0.858333
4	0.221310	0.914336	1.000965	0.770833

Şekil 14: EfficientNetB0 Model Sonucu



Şekil 15: EfficientNetB0 Grafik Sonuçları

Şekil 15’ de değerlendirme ölçekleri dikkate alınarak performansı ölçmek için validation verileri üzerinden de hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı ‘Hata Matrisi’ olan ‘Confusion Matrix’ ile değerlendirme yapılmış olup, sonuçlar aşağıdaki gibidir. Gerçek otizmlı bireyin gerçek otizmlı olduğunu 87 ile ifade ederken gerçekten otizmlı olduğu halde otizmlı değil diye 13 tahminde bulunmuştur. Bu değerlendirme üzerinden modelin yeterli olduğu ancak modeldeki parametreler ile daha iyi değerlendirmeler de ortaya çıkarılabileceği sonucuna ulaşılmıştır.



Şekil 16: EfficientNetB0 Hata Matrisi

EfficientNetB0 - Otizmlı 1. birey :

```
from PIL import Image
im = Image.open('autism_2.jpeg')
im.show()

print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 0s 42ms/step
[1. 0.]
autism_2.jpeg : Autistic
```

Şekil 17: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizmlı (1) Bireyin Tahminlemesi

EfficientNetB0 - Otizmlı 2. birey :

```
uploaded=files.upload()
```

Dosyaları Seç Autism_5.jpeg

- Autism_5.jpeg(image/jpeg) - 55223 bytes, last modified: 19.07.2023 - 100% done
Saving Autism_5.jpeg to Autism_5.jpeg

```
from PIL import Image  
im = Image.open('Autism_5.jpeg')  
im.show()
```

```
print(fn + " : Autistic")  
else:  
print(fn + " : Non Autistic")
```

```
1/1 [=====] - 0s 44ms/step  
[1. 0.]  
Autism_5.jpeg : Autistic
```

Şekil 18: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizimli (2) Bireyin Tahminlemesi

EfficientNetB0 - Otizm olmayan 3. birey :

```
uploaded=files.upload()
```

Dosyaları Seç Autism_3.jpeg

- Autism_3.jpeg(image/jpeg) - 35328 bytes, last modified: 19.07.2023 - 100% done
Saving Autism_3.jpeg to Autism_3.jpeg

```
from PIL import Image  
im = Image.open('Autism_3.jpeg')  
im.show()
```

```
print(fn + " : Autistic")  
else:  
print(fn + " : Non Autistic")
```

```
1/1 [=====] - 0s 49ms/step  
[1.]  
Autism_3.jpeg : Non Autistic
```

Şekil 19: EfficientNetB0 Modeli ile Tanı Ölçütlerine Göre Otizimli (3) Bireyin Tahminlemesi

Yukarıdaki 3 birey için gerçek zamanlı olarak paylaşılan veriler *Tablo 2*'deki gibidir. *Tablo 2* 'deki sorulara göre %99.99 oranı ve %88.88 oranındaki tanı ölçütü yapılan bireylerin fotoğrafları modele verilmiştir.

VGG16 Modeli için sonuçlar aşağıdaki gibidir;

Şekil 20 'de yer alan VGG16 modelindeki 150 iterasyon ile modeli eğitmiştir. Daha iyi model sonuçları için de hiper parametrelerde daha da tutarlı gözlemler yaparak model eğitilebilir.

```
50/50 [=====] - 15s 291ms/step - loss: 0.5339 - accuracy: 0.7200 - val_loss: 0.5664 - val_accuracy: 0.7150
Epoch 149/150
50/50 [=====] - 15s 291ms/step - loss: 0.4881 - accuracy: 0.7817 - val_loss: 0.5681 - val_accuracy: 0.7250
Epoch 150/150
50/50 [=====] - 15s 304ms/step - loss: 0.4917 - accuracy: 0.7450 - val_loss: 0.5276 - val_accuracy: 0.7150
CPU times: user 33min 52s, sys: 49.8 s, total: 34min 42s
Wall time: 42min 44s
```

Şekil 20: VGG16 Modeli Sonucu


Şekil 21'de görüldüğü gibi accuracy (doğruluk) ve validation accuracy (validasyon doğruluğu) grafiği çıkarılmıştır. Burada değerlerin birbirine yakınlığı modelin aslında deneme yanılma ile doğru parametre değerlerini yakalaması gerekmektedir.



Şekil 21: VGG16 Modeli Doğruluk Grafiği


Şekil 22 'de beklenen loss değerinin daha yüksek çıkmasından kaynaklı aslında yeterince eğitilmediğini gözlemleyebiliriz. Loss değeri ne kadar küçük olursa modelin doğruluk

oranı o yönde iyileşebilir. Loss ile accuracy ters orantılı iken daha iyi sonuç elde edilebilir.



Şekil 22: VGG16 Model Doğruluk Grafiği (2)

Şekil 23'de epoch değeri arttıkça grafikteki değişim gösterilmektedir.



Şekil 23: Epoch Değerine Göre VGG16 Model Grafinin Değişimi

VGG16- Otizm olan 1. birey :

```
uploaded=files.upload()

Dosyaları Seç Autism_4.jpeg
• Autism_4.jpeg(image/jpeg) - 111609 bytes, last modified: 19.07.2023 - 100% done
Saving Autism_4.jpeg to Autism_4.jpeg

if classes[0]<0.8:
    print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 1s 908ms/step
[6.8190054e-08]
Autism_4.jpeg : Autistic
```

Şekil 24: VGG16 Modeli ile Tanı Ölçütlerine Göre Otizimli (1) Bireyin Tahminlemesi

VGG16 ile modele verilir tahmin edilmek istenen fotoğrafların tümü doğru sonuçlar vermemiş olup aslında bu model üzerinde daha da çalışılması gerektiği anlamına gelmektedir.

VGG16- Otizm olan 2. birey :

```
uploaded=files.upload()

Dosyaları Seç with_autism_1.jpeg
• with_autism_1.jpeg(image/jpeg) - 207018 bytes, last modified: 23.06.2023 - 100% done
Saving with_autism_1.jpeg to with_autism_1.jpeg

from PIL import Image
im = Image.open('with_autism_1.jpeg')
im.show()

print(fn + " : Autistic")
else:
    print(fn + " : Non Autistic")

1/1 [=====] - 0s 29ms/step
[0.]
with_autism_1.jpeg : Autistic
```


Şekil 25: VGG16 Modeli ile Tanı Ölçütlerine Göre Otizimli (2) Bireyin Tahminlemesi

ResNet50 Modeli için sonuçlar aşağıdaki gibidir;

Şekil 26’da ResNet50 modeli için toplam 5 epoch kullanılmıştır. Modelin değerlendirme metrikleri loss, accuracy, validation loss ve validation accuracy metrikleridir. Sırasıyla 0.1307, 0.9473, 0.5243, 0.78 şeklinde.

```
Epoch 1/5
40/40 [=====] - 656s 16s/step - loss: 0.6804 - accuracy: 0.7173 - val_loss: 0.5258 - val_accuracy: 0.7200
Epoch 2/5
40/40 [=====] - 624s 16s/step - loss: 0.3645 - accuracy: 0.8369 - val_loss: 0.4990 - val_accuracy: 0.7300
Epoch 3/5
40/40 [=====] - 664s 17s/step - loss: 0.2562 - accuracy: 0.8915 - val_loss: 0.4466 - val_accuracy: 0.7850
Epoch 4/5
40/40 [=====] - 664s 17s/step - loss: 0.1572 - accuracy: 0.9450 - val_loss: 0.5161 - val_accuracy: 0.7450
Epoch 5/5
40/40 [=====] - 663s 17s/step - loss: 0.1307 - accuracy: 0.9473 - val_loss: 0.5243 - val_accuracy: 0.7800
```

Şekil 26: ResNet50 Modeli Sonucu



Şekil 27: ResNet50 Modeli Doğruluk Grafiği

4.1.1. Gerçek Zamanlı Sonuçların Değerlendirilmesi

Bu bölümde araştırmanın sonuçlarını değerlendirmek için otizm olduğu kesin olarak tespit edilmiş bireylerin bir uzman eşliğinde ölçüm parametreleri dikkate alınarak yakınlarına yöneltilmiş soruların yanıtlarından oluşmaktadır. Değerlendirmede elde edilen 9 yanıtın sonuçlarına yönelik yorumlar ve kodlama aşamasında elde edilmiş modeller ile birlikte değerlendirilerek sonuç tartışılacaktır. Oran niteliğinde sonuçlar model ile karşılaştırılacaktır. Sırasıyla sorular ve sonuçları aşağıdaki gibidir:


“Çocuğunuzun farklı davranışlar sergilediğini ne zaman fark ettiniz?” genel bilgi adına sorusuna verilen 9 yanıtın sonucunda en yüksek oran olan %44.4 12-24 ay arası fark edilmiştir.

Tablo 2: Gerçek Zamanlı Sonuçların Tablosu

Soru 1	Soru 2	Soru 3	Soru 4	Soru 5	Soru 6	Soru 7	Soru 8	Soru 9	Soru 10	Yüzde
0-12 ay	Evet	Evet	Evet	Evet	Hayır	Evet	Hayır	Evet	Evet	%77.77
12-24 ay	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	Hayır	%11.11
36-+ay	Evet	Evet	Evet	Evet	Evet	Evet	Hayır	Hayır	Evet	%77.77
12-24 ay	Evet	Evet	Evet	Evet	Evet	Evet	Hayır	Evet	Evet	%77.77
0-12 ay	Evet	Evet	Evet	Evet	Evet	Evet	Hayır	Evet	Evet	%88.88
12-24 ay	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	%99.99
12-24 ay	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	Evet	%99.99
24-36 ay	Evet	Evet	Evet	Hayır	Evet	Evet	Evet	Evet	Hayır	%77.77

Çocuğunuzun farklı davranışlar sergilediğini ne zaman fark ettiniz?


9 yanıt



“Çocuğunuz yineleyici davranışlar sergiliyor mu?” sorusuna verilen yanıt %88.9 **Evet** yanıtını vermektedir.


Çocuğunuz yineleyici davranışlar sergiliyor mu?

9 yanıt




“Çocuğunuzun nesnelere veya durumlara takıntısı var mı?” sorusuna verilen yanıt %88.9 **Evet** yanıtını vermektedir.

Çocuğunuz yineleyici davranışlar sergiliyor mu?
9 yanıt



“Çocuğunuz aynılıkta ısrar ediyor mu?” sorusuna verilen yanıt %88.9 **Evet** yanıtını vermektedir.


Çocuğunuz aynılıkta ısrar ediyor mu?
9 yanıt



“Çocuğunuz diğer kişilerle iletişim kurarken sorun yaşıyor mu?” sorusuna verilen yanıt %77.8 **Evet** yanıtını vermektedir.

Çocuğunuz diğer kişilerle iletişim kurarken sorun yaşıyor mu?


9 yanıt



“Çocuğunuzda ekolali veya gecikmiş ekolali var mı ? (Sürekli aynı kelimeleri tekrar etme)” sorusuna verilen yanıt %77.8 **Evet** yanıtını vermektedir.

Çocuğunuzda ekolali veya gecikmiş ekolali var mı ? (Sürekli aynı kelimeleri tekrar etme)


9 yanıt



“Çocuğunuzda dil gelişiminde gecikme veya aksama oldu mu?” sorusuna verilen yanıt %77.8 **Evet** yanıtını vermektedir.


Çocuğunuzda dil gelişiminde gecikme veya aksama oldu mu?

9 yanıt




“Çocuğunuzda bireysellik eğilimi var mı? (Tek başına kalma isteği, etkinlik yapma isteği vs)” sorusuna verilen yanıt %44.4 **Evet** yanıtını vermektedir.

Çocuğunuzda bireysellik eğilimi var mı? (Tek başına kalma isteği, etkinlik yapma isteği vs)
9 yanıt




“Çocuğunuz duyusal anlamda hassasiyet taşıyor mu?” sorusuna verilen yanıt %77.8 **Evet** yanıtını vermektedir.

Çocuğunuz duyusal anlamda hassasiyet taşıyor mu?
9 yanıt



“Çocuğunuzda problem davranış (ağlama, vurma, kendine zarar verme vb.) var mı?”
sorusuna verilen yanıt %89.9 **Evet** yanıtını vermektedir.

Çocuğunuzda problem davranış (ağlama, vurma, kendine zarar verme vb.) var mı?
9 yanıt



Yöneltilen bu soruların yanıtlarına göre belli bir yüzde oran elde edilip, eğitilmiş olan model ile de karşılaştırılarak tahmini yapılan birey için sonuca varılmıştır. Bu 9 yanıttan yola çıkarak uzman tarafından izni alınıp iletilen otizm teşhisi kesin olarak konulmuş bireyin fotoğrafı modele verilmiştir, aynı zamanda o bireye ait soruların yanıtları da paylaşılmıştır.

5.TARTIŞMA

Çalışmada vurgulanmak istenen otizm tespitine ilişkin sınıflandırma oldukça zorlu bir süreçtir. Hastalık tespitinde olduğu gibi yüksek oranlı kararlar verebilmek kritik ve önemlidir. Öte yandan yanlış bir tespit bireyi ve yakınlarını fazlasıyla etkileyecektir. Dolayısıyla büyük bir hassasiyetle çalışılması gereken bu konu için bu çalışma başlangıç düzeyinde durum tespiti ve verilerin ne şekilde değerlendirilip birleştirilebilir noktalarının olması gerektiğini ortaya koymaktadır. Bu bağlamda model eğitimi ve gerçek zamanlı cevapların dikkate alındığı çalışmanın yanı sıra otizmle ilgili çalışmalar konusunda dikkat çeken diğer çalışmaların sonuçları da göz önünde bulundurulmuştur. Diğer tüm çalışmalardan farklı kılan gerçek zamanlı sorulara DSM-V yöntemi ile ölçütlerin model sonucunda birlikte değerlendirilmesidir.

Tablo 3 ' de benzer nitelikte çalışma yürüten araştırmacıların hangi yöntemlere ile hangi oranda başarı elde ettikleri karşılaştırılmıştır.

Tablo 3: Benzer Veri Kümesi Kullanan Çalışmaların Değerlendirmesi

Yazarı, Yılı	Eğitim Yöntemi	Başarımı (%)
Ahmed ve ark, 2022:5	MobileNet	% 95
Beary ve ark., 2020	Conv MobileNet	% 71.7

Çalışmada veri setine benzer veri setlerinin kullanıldığı araştırmalar irdelenmiştir. Bu çalışmalarda en iyi sonuçlar ile kendi kurmuş olduğum modelleri karşılaştırıp arasındaki en önemli farkın derin öğrenme modellerinde farklı algoritmaları kullanarak sonuç elde etmiş olmak ve DSM-V yöntemi kullanılarak iki sonucun bir arada değerlendirilmesidir. *Tablo 3* 'te yer alan Ahmed ve arkadaşlarının araştırmasında MobileNet ile en iyi sonucu almış olmakla birlikte makale web uygulaması halinde otizm spektrum bozukluğu tespiti için yapay zeka ve derin öğrenme modelleri olan MobileNet, Xception, ve InceptionV3 modelleri ile önceden eğitilmiş sınıflandırma modelleri ile değerlendirilmiştir. En iyi model sonucunu kendi modelim ile karşılaştırdığımda metrik değerler doğrultusunda CNN modelimde daha iyi bir sonuç elde etmiş olmakla beraber DSM-V kriterlerini de dahil ederek daha gerçekçi sonuçlar elde ettiğim sonucu ortaya çıkmıştır. MobileNet

modeli için başarı oranı %95 iken CNN ile kendi mimarimi oluşturduğum modelin sonucu %98,75' dir.

Tablo 3'teki bir diğer araştırma makalesi olan Beary ve arkadaşlarının araştırmasında ise; en dikkat çeken MobileNet modelinin son versiyonu ile eğitildiğini vurgulayan aynı zamanda alfa değeri olarak 1 değerini seçerek sonucunda % 71.7 başarı oranı yakalamıştır. Bu durumda kendi modelim ile karşılaştırdığımda kullanılan modeller dışında kendi modelini kurmak belirleyici etkenleri hassas şekilde seçmek için daha doğru bir yol olabilir. Dolayısıyla her iki araştırma da modelime oranla daha zayıf sonuçlar elde ettiğinden modelimin amacıma ulaşmam için iyi sonuçlar verdi diyebilirim.



6. SONUÇ VE ÖNERİLER

Çalışma sonucunda elde edilen bulguların değerlendirilmesi bu bölümde verilmiştir. Tez kapsamında çalışmada otizm tespiti için kullanılan fotoğraf veri setini CNN, VGG-16, EfficientNetB0 modellerinde test edildi. Eş zamanlı olarak otizm tespiti kesin olan bireyler için sorular DSM-V kriterlerine göre sorular yöneltilip bu sorulara verilen cevaplar ile modeldeki sonuçlar ile karşılaştırılmıştır. Elde edilen sonuçlara göre otizm tespiti için kullanılmış olan bu yöntemlerin gerçek zamanlı şekilde kullanılması, geliştirilebilmesi ve modelin test edilmesi gerektiğine ve daha fazla veriye ihtiyaç olduğu, kurulan modellerin temel olarak etkilendiği durumun veri setinin sınırlı bir sayı olması olmuştur. Hazır kullanılan veri setlerinden elde edilen doğruluk oranları (eş zamanlı olarak doğruluk, duyarlılık, kesinlik vb) metriklerin de modelin başarılı sonuç verdiğini ortalama değerler doğrultusunda söyleyebiliriz. Modelin daha başarılı olması için eldeki veri setinden daha büyük bir veri seti olması gerektiği konusu kritik bir nokta olduğunu göstermektedir.

Çalışmada otizmli ve otizmli olmayan bireylerin etiketlenmiş olduğu veri seti ve değerlendirme için otizm tespiti kesin olarak konulmuş bireyin fotoğrafı tahminlemede kullanılmıştır. Ortalama olarak veri büyütme işlemi uygulanarak küçük oranda veri sayısı artırılmıştır. En yüksek CNN ile %98,75 doğruluk oranı elde edilmiştir. Uygulama Google Colab üzerinde Jupyter Notebook geliştirme ortamı kullanılarak Python programlama dilinde geliştirilmiştir. Elde edilen sonuçlar geliştirilen modellerin otizm tespiti için kullanılmasında olumlu sonuçlar elde edileceğini göstermektedir.

Çalışmadaki kısıtlarımız arasında ise, her millettten otizmli olan bireylere kolayca ulaşamıyor olmaktır. İnsan hassasiyeti, ailelerin duygu durumu gibi faktörlerin olması kendi veri setimizi oluşturmayı oldukça zorlaştırabilir. Bundan sonraki çalışmalarda veri örneklerinin artırılması başarı oranını arttıracak, özellikle yüz deformasyonlarının dikkat çektiği bu çalışmada yüz oranlarındaki matematiksel hesabın yapılarak çok daha net sonuçlar elde edileceğini düşünmekteyim. Böylece verilerden daha kesin sonuçlar almak için bu yöntem performansında iyileşmesine yardımcı olacaktır.

KAYNAKLAR

Aktivasyon fonksiyonları (part 1). Erişim adresi
<https://atcold.github.io/pytorch-Deep-Learning/tr/week11/11-1/>

Alver, E. & Gümüş, Ç. (2020). OTİZM SPEKTRUM BOZUKLUĞUNA SAHİP BİREYLERDE EĞİTİMİN ÖNEMİNE DİKKAT ÇEKMEK ÜZERE HAZIRLANMIŞ DERGİ İLANI TASARIMI ÖRNEKLERİ . İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi , 19 (39) , 1423-1435 . DOI: 10.46928/iticusbe.765640

Artificial Intelligence (AI) worldwide - statistics & facts. Erişim adresi
<https://www.statista.com/topics/3104/artificial-intelligence-ai-orldwide/#topicOverview>

Autism Prevalence Higher, According to Data from 11 ADDM Communities Erişim adresi
<https://www.cdc.gov/media/releases/2023/p0323-autism.html>

Autism Rates by Country. Erişim adresi <https://wisevoter.com/country-rankings/autism-rates-by-country/>

Autism Rates by Country. Erişim adresi <https://worldpopulationreview.com/country-rankings/autism-rates-by-country>

Autism Speaks. (Erişim tarihi: 05.06.2023). What Are the Symptoms of Autism?
<https://www.autismspeaks.org/what-are-symptoms-autism>

Aydos, S. & Çalış, E. S. (2021). Otizm Spektrum Bozukluğu Öncesi ve Sonrasıyla Tanı: Çocuk Gelişimci Bakış Açısıyla Bir İnceleme . Türkiye Sağlık Bilimleri ve Araştırmaları Dergisi , 4 (1) , 31-53 . DOI: 10.51536/tusbad.779103

- Bhola, J., Jeet, R., Jawarneh, M. M., & Pattekari, S. A. (2021). Machine Learning Techniques for Analysing and Identifying Autism Spectrum Disorder. In S. Kautish & G. Dhiman (Eds.), Artificial Intelligence for Accurate Analysis and Detection of Autism Spectrum Disorder (pp. 69-81). IGI Global. <https://doi.org/10.4018/978-1-7998-7460-7.ch005>
- Cebeci, Ö. & Yenen, E. T. (2022). Otizm Spektrum Bozukluğu Tanısı Alan Bireylerde Becerileri Öğretiminde Bilgi ve İletişim Teknolojilerin Kullanımı . Maarif Mektepleri Uluslararası Eğitim Bilimleri Dergisi , 6 (1) , 1-18 . DOI: 10.46762/mamulebd.1094089
- Centers for Disease Control and Prevention. (Erişim tarihi: 10.06.2023). One in 36 (2.8%) U.S. children aged 5 to 17 has autism; 1 in 44 (2.3%) has ADHD. <https://www.cdc.gov/media/releases/2023/p0323-autism.html>
- Columbia University - Department of Computer Science. (Erişim tarihi: 13.07.2023). Convolutional Neural Networks (CNNs) - Week 11 Part 1. <https://atcold.github.io/pytorch-Deep-Learning/tr/week11/11-1/>
- Çelik, S. and Şişeci Çeşmeli, M. (2021) ‘Çocuklar için Otizm Spektrum Bozukluğunun Veri Madenciligi yöntemleri İle Analizi’, Acta Infologica, 0(0), pp. 167–186. doi:10.26650/acin.882187.
- Çinar, Ahmet & ERKUŞ, Merve & Tuncer, Taner. (2023). Türk İşaret Dilindeki Harflerin Tespiti İçin Derin Öğrenme Tekniğinin Kullanımı. International Conference on Scientific and Innovative Studies. 1. 360-365. 10.59287/icsis.626.
- Danış, M. Z. (2001). Otistik Çocuklar. Ufkun Ötesi Bilim Dergisi, 1(2), 65-82.
- DataGen. (Erişim tarihi: 29.05.2023). VGG16 - A Comprehensive Guide. <https://datagen.tech/guides/computer-vision/vgg16/>
- Değirmenciler, A. , Cengiz, B. & İleri, K. (2022). COVID-19’un Yayılmasını Önlemek için CNN ile Yüz Maskesi Tespiti . Mühendislik Bilimleri ve Araştırmaları Dergisi , 4 (2) , 259-265 . DOI: 10.46387/bjesr.1167636

- Esen, F. A. & Onan, A. (2022). Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması . Avrupa Bilim ve Teknoloji Dergisi , ICIAS 2022 , 151-155 . DOI: 10.31590/ejosat.1181081
- Farooq, M. S., Tehseen, R., Sabir, M., & Atal, Z. (2023). Detection of autism spectrum disorder (ASD) in children and adults using machine learning. Scientific reports, 13(1), 9605. <https://doi.org/10.1038/s41598-023-35910-1>
- GÜVEN, H. and AYVAZ GÜVEN, E.T. (2023) ‘Use of artificial intelligence applications in e-commerce’, International Journal of Management and Administration, 7(13), pp. 69–94. doi:10.29064/ijma.1194949.
- Hosseini, M. P., Beary, M., Hadsell, A., Messersmith, R., & Soltanian-Zadeh, H. (2022). Deep Learning for Autism Diagnosis and Facial Analysis in Children. Frontiers in computational neuroscience, 15, 789998. <https://doi.org/10.3389/fncom.2021.789998>
- Hosseini, M.-P. (2022) ‘Deep learning for autism diagnosis and facial analysis in children’, Frontiers in Computational Neuroscience, 15. doi:10.3389/fncom.2021.789998.
- Hoşgör, H. & Güngördü, H. (2022). Sağlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Araştırma . Avrupa Bilim ve Teknoloji Dergisi , (35) , 395-407 . DOI: 10.31590/ejosat.1052614
- KABA D, AYSEV A (2020). DSM-5 Tanı Ölçütlerine Göre Erken Çocukluk Döneminde Otizm Spektrum Bozukluğunun Değerlendirilmesi. Türk Psikiyatri Dergisi, 31(2), 106 - 112. 10.5080/u23735
- Kaya, U. (2015). Zihinsel Yetersizlikten Etkilenmiş Çocukların Tanılanmasında Tanı Ölçütlerinin Tarihsel Gelişim ve Değişimi. (1907 Yılı Tanı Ölçütleri ile 2013 Yılı DSM-5 Tanı Ölçütlerinin Karşılaştırılması) . Hacettepe University Faculty of Health Sciences Journal , 3rd National Congress of Child Development and Education (International Participations)

(Congress Book) , - . Retrieved from
<https://dergipark.org.tr/en/pub/hsbfd/issue/7893/103884>

Li, Z., Yang, L., Chen, H., Fang, Y., Zhang, T., Yin, X., Man, J., Yang, X., & Lu, M. (2022). Global, regional and national burden of autism spectrum disorder from 1990 to 2019: results from the Global Burden of Disease Study 2019. *Epidemiology and psychiatric sciences*, 31, e33. <https://doi.org/10.1017/S2045796022000178>

Mazurek, M.O., Lu, F., Symecko, H. ,A Prospective Study of the Concordance of DSM-IV and DSM-5 Diagnostic Criteria for Autism Spectrum Disorder. *J Autism Dev Disord* 47, 2783–2794 (2017). <https://doi.org/10.1007/s10803-017-3200-7>

National Framework to Deliver Improved Outcomes in All Age Autism Assessment Pathways: Guidance for Integrated Care Boards. Eriřim adresi <https://www.england.nhs.uk/long-read/a-national-framework-to-deliver-improved-outcomes-in-all-age-autism-assessment-pathways-guidance-for-integrated-care-boards/>

NHS England. (Eriřim tarihi: 19.07.2023). A National Framework to Deliver Improved Outcomes in All Age Autism Assessment Pathways: Guidance for Integrated Care Boards. <https://www.england.nhs.uk/long-read/a-national-framework-to-deliver-improved-outcomes-in-all-age-autism-assessment-pathways-guidance-for-integrated-care-boards/>

Odluyurt, S. & attık, M. (2018). Otizm Spektrum Bozukluęu Olan Bireyler İin Teknoloji Temelli Mdahale Yntemleri . *Kastamonu Eęitim Dergisi* , 26 (6) , 1851-1861 . DOI: 10.24106/kefdergi.2203

Otizm Nedir? (Eriřim tarihi: 25.05.2023), Eriřim adresi <https://tohumotizm.org.tr/otizm/>

Otizm Trkiye. (Eriřim tarihi: 01.06.2023), Eriřim adresi <http://www.otizmturkiye.org/otizm/>

zyurt, F. (2019). Uzaktan Algılama Grntlerinin Evriřimsel Sinir Aęları ve Komřuluk Bileřen Analizi Tabanlı zniteliklerinin Sınıflandırılması . *Afyon Kocatepe niversitesi Fen Ve Mhendislik Bilimleri Dergisi* , 19 (3) , 669-675 . DOI: 10.35414/akufemubid.558311

- Raj, S. and Masood, S. (2020) ‘Analysis and detection of autism spectrum disorder using machine learning techniques’, *Procedia Computer Science*, 167, pp. 994–1004. doi:10.1016/j.procs.2020.03.399.
- Sağdıç, Z. A. & Sani-bozkurt, S. (2020). Otizm spektrum bozukluğu ve yapay zeka uygulamaları . *Açıköğretim Uygulamaları ve Araştırmaları Dergisi* , 6 (3) , 92-111 .
- Statista. (Erişim tarihi: 01.06.2023). Artificial Intelligence (AI) - Worldwide. <https://www.statista.com/topics/3104/artificial-intelligence-ai-orlwdwide/#topicOverview>
- Şeker, A. , Diri, B. & Balık, H. H. (2017). Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme . *Gazi Mühendislik Bilimleri Dergisi* , 3 (3) , 47-64 .
- Tohum Otizm Vakfı. (Erişim tarihi: 25.05.2023). Otizm Nedir? <https://tohumotizm.org.tr/otizm/>
- Uçar, M. (2021). Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti . *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi* , 23 (68) , 521-529 . DOI: 10.21205/deufmd.2021236815
- Understanding VGG16: Concepts, Architecture, and Performance. Erişim adresi <https://datagen.tech/guides/computer-vision/vgg16/#>
- Wise Voter. (Erişim tarihi: 17.07.2023). Autism Rates by Country. <https://wisevoter.com/country-rankings/autism-rates-by-country/>
- World Population Review. (Erişim tarihi: 19.07.2023). Autism Rates by Country. <https://worldpopulationreview.com/country-rankings/autism-rates-by-country>
- Zeyad A. T. Ahmed, Theyazn H. H. Aldhyani, Mukti E. Jadhav, Mohammed Y. Alzahrani, Mohammad Eid Alzahrani, Maha M. Althobaiti, Fawaz Alassery, Ahmed Alshaflut, Nouf Matar Alzahrani, Ali Mansour Al-madani, "Facial Features Detection System To Identify Children With Autism Spectrum Disorder: Deep Learning Models", *Computational and Mathematical Methods in Medicine*, vol. 2022, Article ID 3941049, 9 pages, 2022. <https://doi.org/10.1155/2022/3941049>

EKLER

Ek 1: Kodlar, Gerçek Zamanlı Fotoğraflar ve Yanıt Formu

Kodlama Dosyaları



CNN_Autism.ipynb



EfficientBO_Autism.ipynb



VGG16_Autism.ipynb



resnet50_Autism.ipynb



VGG16_epoch350_Autism.ipynb



CNN_Autism_F1score
_ipynb.ipynb

Gerçek Zamanlı Veriler



EXCEL FORM YANITLARI.csv.zip



OTİZMLİ BİREYLERDE
TANI AŞAMASINDAKİ

Gerçek Zamanlı Verilerin Fotoğrafları



Gerçek Zamanlı Verilerin Fotoğrafları.zip