

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU OLAN
ÇOCUKLARIN EL YAZILARININ GÖRÜNTÜ İŞLEME
TEKNİKLERİ İLE ANALİZİ**

YÜKSEK LİSANS TEZİ

Özlem YILDIZ BUDAK

Bilgisayar Mühendisliği Anabilim Dalı

HAZİRAN 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU OLAN
ÇOCUKLARIN EL YAZILARININ GÖRÜNTÜ İŞLEME
TEKNİKLERİ İLE ANALİZİ**

YÜKSEK LİSANS TEZİ

Özlem YILDIZ BUDAK

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Muhammed Fatih ADAK

Ortak Danışman: Doç. Dr. Enes SARIGEDİK

HAZİRAN 2025

Özlem Yıldız Budak tarafından hazırlanan “DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU OLAN ÇOCUKLARIN EL YAZILARININ GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE ANALİZİ.” adlı tez çalışması 30.06.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Doç. Dr. M. Fatih ADAK (Danışman)
	Sakarya Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi M. Ali Nur ÖZ
	Sakarya Uygulamalı Bilimler Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi Can YÜZKOLLAR
	Sakarya Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU OLAN ÇOCUKLARIN EL YAZILARININ GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE ANALİZİ.” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(30/06/2025).

(imza)

Özlem YILDIZ BUDAK





Eşim ve çocuklarıma ithafen..



TEŞEKKÜR

Yüksek lisans eğitimim süresince değerli bilgi ve rehberliğiyle beni yönlendiren, sabrı ve desteğiyle bu süreci benim için daha anlamlı hale getiren tez danışmanım Doç. Dr. Muhammed Fatih ADAK'a en derin şükranlarımı sunarım. Kendisinin akademik bilgisi ve yol göstericiliği olmadan bu çalışmayı tamamlamak mümkün olmazdı.

Bu süreçte bana manevi destek veren, sabrı ve sevgisiyle her zaman yanımda olan, anlayışı, teşvikleri, desteği sayesinde bu süreci daha kolay aşmamda yardımcı olan değerli eşime en içten teşekkürlerimi sunarım.

Bu çalışma Sakarya Üniversitesi Bilimsel Araştırma Projeleri Komisyonu (BAPK) tarafından 2025-27-70-17 numaralı proje kapsamında desteklenmiştir.

Özlem YILDIZ BUDAK



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Tezin Amacı	3
2. DEHB (DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU).....	5
2.1. DEHB'nin Tanımı ve Tarihçesi	5
2.2. DEHB'nin Nedenleri.....	6
2.2.1. Genetik yatkınlık.....	7
2.2.2. Beyin yapısı ve nörokimyasal farklılıklar	7
2.2.3. Doğum öncesi ve sonrası risk etmenleri	8
2.3. DEHB Belirtileri ve Alt Tipleri.....	8
2.3.1. Bilişsel ve dikkatle ilgili belirtiler.....	9
2.3.2. Davranışsal ve sosyal belirtiler	9
2.3.3. Motor koordinasyon ve el becerileri	10
2.3.4. Duygusal ve fiziksel özellikler.....	10
2.4. DEHB ve Eşlik Eden Öğrenme Güçlükleri.....	11
2.4.1. Okuma güçlükleri (disleksi).....	12
2.4.2. Yazma güçlükleri (disgrafi)	13
2.4.3. Matematiksel güçlükler (diskalkuli)	14
2.5. DEHB ve El Yazısı Problemleri	14
2.6. Görüntü İşleme ve Yapay Zeka Destekli Tanı Yöntemleri.....	17
2.6.1. Dijital el yazısı analizi.....	17
2.6.2. Eye-tracking (göz izleme) ile dikkat analizi	17
2.6.3. fMRI ile prefrontal kortekste aktivite farklılığı	18
2.6.4. Derin öğrenme modelleri ile çoklu veri entegrasyonu.....	18
2.7. Görüntü İşleme Teknikleri ile DEHB Ön Teşhisi.....	18
2.7.1. El yazısı görüntüleme analizi	19
2.7.2. Dijital kalem verileri	19
2.7.3. Göz takibi ve yüz ifadesi.....	20
2.7.3.1. Göz takibi (eye-tracking) sistemleri.....	20
2.7.3.2. Yüz ifadesi analizi.....	21
2.7.3.3. Tanısal ve klinik kullanım.....	21
2.7.4. fMRI ve EEG tabanlı yöntemler	21
2.7.4.1. fMRI (fonksiyonel manyetik rezonansı görüntüleme).....	22

2.7.4.2. EEG (elektroensefalografi) tabanlı analizler	22
2.7.4.3. Tanı sürecine katkıları	22
2.7.5. Yapay zeka destekli tanı sistemleri	23
2.7.5.1. Makine öğrenmesi tabanlı tanı modelleri	23
2.7.5.2. Derin öğrenme yaklaşımları	23
2.7.5.3. Multimodal veri entegrasyonu	24
2.7.5.4. Klinik uygulamalar ve gelişmiş YZ sistemleri	24
3. MATERYAL YÖNTEM.....	25
3.1. Görüntü İşleme	25
3.1.1. Görüntü.....	25
3.1.2. Görüntü yakalama	25
3.1.3. Sayısal görüntü	26
3.1.4. Görüntü işleme adımları.....	27
3.1.5. Görüntü işleme türleri	28
3.1.6. Görüntü işlemenin temelleri	30
3.1.7. Görüntü işleme uygulama alanları	30
3.2. Yolo (You Only Look Once)	32
3.2.1. Yolo algoritmasının temelleri.....	33
3.2.2. Yolo algoritmasının tarihsel gelişimi ve sürümleri	34
3.2.3. YOLOv11 mimarisi.....	35
3.2.3.1. Backbone yapısı (girdinin bölünmesi)	37
3.2.3.2. Neck yapısı (öznitelik haritası çıkışı).....	37
3.2.3.3. Head yapısı (özelleştirilmiş katmanlar).....	38
3.2.4. YOLOv11 performans analizi ve ROC eğrisi	39
3.2.4.1. ROC eğrisinin temel kavramları	39
3.2.4.2. Roc eğrisinin YOLOv11 üzerindeki etkileri	40
3.2.4.3. YOLOv11 ve diğer sürümler ile karşılaştırmalı ROC performansı ..	41
3.2.5. YOLOv11'in avantajları ve dezavantajları	42
3.2.5.1. Avantajları	43
3.2.5.2. Dezavantajları.....	45
3.2.6. El yazısını tanımada ROC analizi	45
4. UYGULAMA.....	49
4.1. Veri Toplama ve Etiketleme	50
4.2. Görüntü Etiketleme	51
4.3. Model Eğitimi	53
4.4. Model Testi	55
4.5. ROC Analizi	67
4.6. Model Değerlendirmesi	70
4.7. YOLOv11 ile Geliştirilen Modelin Forest CNN ile Karşılaştırılması	75
4.7.1. Mimari ve İşleyiş Farkları	77
4.7.2. Forest CNN ile ROC Eğrisi ve Karışıklık Matrisi:	78
5. SONUÇ VE ÖNERİLER.....	81
6. KAYNAKÇA	83
ÖZGEÇMİŞ.....	95

KISALTMALAR

ACC	: Anterior Singulat Korteks
AR	: Artırılmış Gerçeklik
AUC	: Area Under the Curve
BAPK	: Bilimsel Araştırma Projeleri Komisyonu
BoF	: Bag of Freebies
CNN	: Konvolüsyonel Sinir Ağları
CPU	: Merkezi İşlem Birimi
CSP	: Çapraz Aşama Kısmı
CSV	: Virgülle Ayrılmış Değerler[Excel]
DAT1	: Dopamin Taşıyıcı Geni
DEHB	: Dikkat Eksikliği ve Hiperaktivite Bozukluğu
DL	: Derin Öğrenme
DRD4-DRD2	: Dopamin Reseptör Genleri
DSM-5	: Mental Bozuklukların Tanısal ve İstatistiksel
EEG	: Elektroensefalografi
FDA	: ABD Gıda ve İlaç Dairesi
fMRI-MRI	: Manyetik Rezonans Görüntüleme
FN	: False Negative
FP	: False Positive
FPR	: False Positive Rate
GIS	: Coğrafi Bilgi Sistemi
GPU	: Graphics Processing Unit
IoT	: Nesnelerin İnterneti
LSTM	: Long Short-Term Memory
mAP	: Mean Average Precision
ML	: Makine Öğrenmesi
MR	: Manyetik Rezonans
NEBA	: Neuropsychiatric EEG-Based Assessment Aid
NMS	: Non-Maximum Suppression
PET	: Pozitron Emisyon Tomografisi

RGB	: Red, Green, Blue
RNN	: Tekrarlayan Sinir Ağları
ROC	: Receiver Operating Characteristic
SGD	: Stochastic Gradient Descent
SPECT	: Tek Foton Emisyonlu Bilgisayarlı Tomografi
SPP	: Spatial Pyramid Pooling
SVM	: Support Vektör Machine
TBR	: Theta / Beta Oranı
TN	: True Negative
TP	: True Positive
TPR	: True Positive Rate
TPU	: Tensör İşlem Birimi
VR	: Sanal Gerçeklik
YOLO	: You Only Look Once
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zeka

SİMGELER

%	: Yüzde
^	: Üs
2D	: Uzunluk ve Genişlik
3D	: Uzunluk, Genişlik ve Derinlik
4K	: Ultra High Definition
B	: 1 Piksel Değeri
Fe	: Demir
GB	: Gigabyte
M	: Sütun
N	: Satır
n	: Bit Sayısı
T	: Şiddet Birimi
x,y	: Yatay Dikey Koordinat
Zn	: Çinko
θ	: Confidence Değer



TABLO LİSTESİ

Sayfa

Tablo 3.1. YOLO Algoritmalarının Sürümlerine Göre Karşılaştırılması.....	34
Tablo 3.2. YOLOv11'in Diğer Sürümlerle Karşılaştırmalı ROC Performansı.	41
Tablo 4.1. Model Eğitiminde Kullanılan DEHB'li Veriler.	51
Tablo 4.2. Test Edilen Modelin Karışıklık Matrisi.	70
Tablo 4.3. Karışıklık Matrisi Oluşumu.....	73
Tablo 4.4. Forest CNN ile YOLO Özelliklerinin Karşılaştırılması.	76
Tablo 4.5. Forest CNN-YOLO Mimari ve İşleyiş Farkları.	78



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. DEHB EL Yazısı Bozuklukları.	15
Şekil 3.1. Görüntü İşleme Adımları.	28
Şekil 3.2. Modelde Kullanılan YOLO Mimarisi.	36
Şekil 3.3. Yolov11 ve ROC Karşılaştırması.	42
Şekil 3.4. ROC Eğrisi.	47
Şekil 4.1. LabelImg Kütüphanesi.	52
Şekil 4.2. Etiketleme İşlemi.	52
Şekil 4.3. Etiketleme İşlemi.	53
Şekil 4.4. Conf.yaml Dosyası.	54
Şekil 4.5. Kütüphane Yükleme.	54
Şekil 4.6. Google Drive Bağlantısı.	54
Şekil 4.7. Dosya Bağlantısı.	54
Şekil 4.8. YOLO Kütüphanesi.	55
Şekil 4.9. Model Eğitimi.	55
Şekil 4.10. UTF-8 Formatına Çevirme.	55
Şekil 4.11. Modeli *.zip Formatına Çevirme.	55
Şekil 4.12. Model Test.	56
Şekil 4.13. F1 Skor.	57
Şekil 4.14. Sınıf Dağılımı.	58
Şekil 4.15. Duyarlılık-Güven Skoru Eğrisi.	59
Şekil 4.16. Hassasiyet-Güven Skoru Eğrisi.	61
Şekil 4.17. Model Eğitim Süreci.	62
Şekil 4.18. Yeni Görüntüler Üzerinde Tahminler Yapma.	64
Şekil 4.19. Kütüphanlerin İçer Alınması.	64
Şekil 4.20. Eğitilmiş Modelin Sisteme Yüklenmesi.	65
Şekil 4.21. Görsellerin Sisteme Yüklenmesi.	65
Şekil 4.22. Tahmin Sonuçları.	65
Şekil 4.23. Modelle Tahmin Yapılması.	65
Şekil 4.24. Tahminlerin Güven Skorları.	66
Şekil 4.25. Tahminlerin Listeye Alınması.	66
Şekil 4.26. Tahminlerin Terminale Yazdırılması.	66
Şekil 4.27. Tahmin sonuçların .csv formatına kaydedilmesi.	67
Şekil 4.28. ROC Analizi.	67
Şekil 4.29. Kütüphanelerin İçer Alınması.	68
Şekil 4.30. Excel dosyaların İçer alınması.	68
Şekil 4.31. Değişkenlerin Hazırlanması.	68
Şekil 4.32. ROC Eğrisi için Değerlerin Hesaplanması.	69
Şekil 4.33. AUC Skorunun Hesaplanması.	69
Şekil 4.34. AUC Skorunun Hesaplanması.	69
Şekil 4.35. AUC Skorunun Hesaplanması.	70
Şekil 4.36. Karışıklık Matrisinin Hesaplanması.	72

Şekil 4.37. Karışıklık Matrisi Üretimi.	72
Şekil 4.38. Skor'un Hesaplanması.	73
Şekil 4.39. Karışıklık Matrisi Oluşumu.	73
Şekil 4.40. Değişkenlerin Tanımlanması.	74
Şekil 4.41. TPR Değerinin Hesaplanması.....	74
Şekil 4.42. FPR Değerinin Hesaplanması.	74
Şekil 4.43. Sonuçların Çıktılarının Alınması.	75
Şekil 4.44. Forest CNN Algoritması ile ROC Eğrisi.	78
Şekil 4.45. Forest CNN Algoritması ile Karışıklık Matrisi.	79



DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU OLAN ÇOCUKLARIN EL YAZILARININ GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE ANALİZİ

ÖZET

Görüntü işleme gerçek yaşamdaki görüntülerin işlenerek özelliklerinin değiştirilmesiyle yeni bir resim oluşturulması sürecidir görüntü işleme teknikleri ile istenilen görüntüyü alıp satır ve sütundan oluşacak şekilde örnek eklenmesiyle sayısal görüntü oluşur böylelikle görsel karakterler sayısallaştırılması olarak veriler saklanır. Teze örnek konu olarak yapılan çalışmalarda ilkökul düzeyindeki çocukların el yazısı verileri görüntü işleme teknikleri yöntemleri ve algoritmaları ile incelenerek doğru olarak kabul edilen örnek çalışmayla karşılaştırılarak dikkat eksikliği, hiperaktivite ve benzeri bozukluklarının erken dönem tespit edilmesiyle müdahale edilmesidir. Teze konu olan çalışmaların Görüntü işleme adımları ile ilk olarak verilerin sayısallaştırılarak, gerekli algoritmalar ile yeni görüntü elde edilmesi ile resmin üzerindeki en küçük resim elemanı olan pikseller üzerine gerçekleştirilmesidir.

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), temel olarak dikkatsizlik, aşırı hareketlilik ve dürtüsel davranışlarla karakterize edilen nörogelişimsel bir bozukluktur. Bu rahatsızlığa sahip bireylerde semptomların dağılımı ve yoğunluğu farklılık gösterebilir; bu da her bireyin kendine özgü klinik özellikler sergilemesine neden olmaktadır. Örneğin, dikkat sorunlarının ön planda olduğu çocuklar çoğunlukla düşük enerji seviyelerine sahip, içe dönük, sınıf ortamında iletişimi sınırlı, tepki süreleri yavaş, hayal kurmaya eğilimli ve sosyal etkileşimden uzak bireyler olarak tanımlanabilir. Dikkatlerini uzun süre sürdürememe, görev tamamlama güçlükleri ve çevresel uyaranlara karşı yüksek hassasiyet gibi özellikler bu grupta sıkça gözlenmektedir. İlginçtir ki, bu bireyler akademik görevlerde dikkatlerini toparlayamazken, yüksek uyarıcı içeren dijital oyunlara uzun süre odaklanabilirler. Ayrıca, öğrenilen bilgileri hatırlamada zorluk yaşamaları ve görsel-motor destekli etkinliklerden daha fazla verim almaları da dikkat çeken bulgular arasındadır (V. Berninger et al., 2017).

Bu bağlamda, el yazısı becerileri; bireyin dikkat kapasitesi, motor koordinasyonu ve bilişsel süreçleri hakkında doğrudan bilgi sunan önemli bir göstergedir. Literatürde, DEHB tanısı almış bireylerin el yazısında görülen düzensizliklerin ve motor kontrol sorunlarının, bozukluğun tanı sürecinde belirleyici olabileceği vurgulanmaktadır (Çak et al., 2018). Bu çalışmada, çocuklara ait el yazısı örnekleri görüntü işleme teknikleriyle sayısal ortama aktarıldı ve ilgili algoritmalar kullanılarak analiz edildi. Böylece, geleneksel yöntemlerin ötesinde, daha objektif, sistematik ve tekrarlanabilir bir değerlendirme süreci elde edildi.

Görüntü işleme teknikleri yöntemleri ve algoritmaları ile ilkökul düzeyindeki çocukların el yazısı incelenerek dikkat eksikliği, hiperaktivite bozukluğu tespitinde kullanılmasıdır. Görüntü işlemede temel yöntemler kullanılarak el yazısının doğru kabul edilen örnek çalışmalar ile kıyaslanarak anlamlı bir ilişki kurulmasıdır. Görüntü dönüşümleri, iyileştirme, onarma, bölümleme, sıkıştırma, algılama ve bazı teknikler

ile görüntü işleme algoritmaları doğrusal dönüştürmeler vb. teknikler kullanılarak el yazısı verilerinin analiz sonuçlarının incelenmesidir. Araştırmaların bulgularının eğitim ve klinik pratikteki yansımaları ve erken müdahale olanaklarının vurgulanmasıdır. DEHB tanısıyla ilgili makine öğrenimi çalışmaları genellikle nörogörüntüleme ve elektroensefalografi (EEG) üzerine odaklanmaktadır. EEG, beyin nöronları tarafından üretilen elektriksel aktivitenin beyin dalgaları olarak kağıt üzerine kaydedilmesi işlemidir. Bu tür yaklaşımlar ve benzer yöntemler literatürde giderek daha fazla kullanılmaktadır. El yazısı ve yazma becerisi eksiklikleri, çeşitli çalışmalarda görüldüğü üzere DEHB ve benzeri bozuklukların bir göstergesi olabilmektedir. Örneğin, bir yazma güçlüğü bozukluğu olan disgrafinin tespitinde makine öğrenmesi yöntemleri kullanılmış ve yaş, cinsiyet gibi kişisel özelliklerle birlikte el yazısı örnekleriyle sınıflandırma performansı ortalama %70 civarında gerçekleşmiştir. Tek karakter yazmaya odaklanan bir çalışmada ise yapay sinir ağları kullanılarak %50 ile %75 arasında bir doğruluk oranı elde edilmiştir (Barry, Clarke, et al., 2003).

Bu yöntemler ve müdahaleler hem zaman alıcı hem de çocuk için oldukça zorlayıcıdır. Bu testler uzun zaman alır ve çocukların hareketsiz kalması gerekir. Oysa daha kolay yöntemler DEHB tanısı koymada yardımcı olabilir. Bu motivasyonla, bu çalışma DEHB teşhisi için el yazısını kullanarak çok kısa ve basit bir süreçle önemli sonuçlar elde etmiştir. Önerilen model ile okullardaki öğretmenler ve hatta bir mobil uygulama aracılığıyla ebeveynler risk altındaki çocukları tespit edebilir ve gerekli yönlendirmeleri yapabilir. Bu çalışmada el yazısı nesne algılama algoritmaları yardımıyla analiz edilmiş ve DEHB ön tanısı koymada başarılı sonuçlar elde edilmiştir.

ANALYSIS OF HANDWRITINGS OF CHILDREN WITH ATTENTION DEFICIT AND HYPERACTIVITY DISORDER USING IMAGE PROCESSING TECHNIQUES

SUMMARY

Image processing refers to the systematic transformation of real-world visual input into a format suitable for computational analysis by altering, enhancing, or extracting specific features from the original image. This transformation involves sampling the visual content into a grid of rows and columns, assigning numerical values to each discrete unit, or pixel, thereby digitizing the image. Once in a numerical format, the image can be subjected to a variety of algorithms for further analysis. These processes enable detailed investigations of visual characteristics that are not easily perceivable through manual inspection. In recent years, image processing has been increasingly applied in behavioral and neurodevelopmental research, where subtle visual indicators—such as handwriting irregularities—can provide valuable insights into cognitive and motor functioning.

The field of image processing includes various techniques, each serving a unique purpose. For example, image enhancement methods improve visual clarity (e.g., histogram equalization, contrast stretching), while image segmentation isolates meaningful regions (e.g., lines of text, individual letters). Edge detection algorithms (such as Sobel or Canny filters) highlight the structural boundaries of objects, whereas morphological operations refine character shapes by eliminating noise or filling in gaps. Geometric transformations, including rotation and scaling, are employed to normalize handwriting data before analysis. These foundational techniques, when used in combination, enable high-precision assessments of dynamic patterns within handwriting samples.

Within the scope of this study, image processing techniques were applied to the analysis of handwriting samples obtained from elementary school-aged children. These samples were digitized and evaluated using advanced computational methods with the aim of detecting early indicators of Attention Deficit Hyperactivity Disorder (ADHD) and other related neurodevelopmental conditions. By comparing the children's handwriting against predefined normative reference samples that reflect developmentally appropriate standards, deviations in motor control and visual consistency could be objectively identified. These deviations were then interpreted as potential markers of attentional and executive function impairments. The methodology followed in this study includes steps such as image digitization, preprocessing (e.g., grayscale conversion, noise filtering, binarization), feature extraction (e.g., stroke uniformity, spacing, line alignment), and high-level pattern analysis using object detection algorithms.

ADHD is a widely studied neurodevelopmental disorder characterized primarily by persistent symptoms of inattention, hyperactivity, and impulsivity, which can manifest in varying combinations and intensities. The heterogeneity of the disorder results in diverse clinical presentations, often complicating the diagnostic process. Children

presenting predominantly inattentive symptoms frequently exhibit behaviors such as reduced physical energy, internalized focus, delayed responsiveness, limited verbal participation, and difficulty sustaining attention in structured academic contexts. These symptoms can significantly hinder academic performance and social integration. Intriguingly, many such children are able to maintain prolonged attention on highly stimulating tasks—such as digital games—highlighting the influence of environmental and motivational factors on attentional regulation.

The connection between ADHD and handwriting performance lies in the cognitive and motor demands of writing tasks. Handwriting requires the integration of multiple domains: sustained attention, working memory, fine motor control, visual-motor integration, and executive planning. In this regard, handwriting is not simply a mechanical skill but a window into underlying neurocognitive functioning. Inconsistent letter sizing, erratic spacing, irregular stroke formation, and poor line alignment are among the most commonly observed features in the handwriting of individuals with ADHD. These motor expression patterns can be captured digitally, enabling objective quantification of features that may otherwise be evaluated subjectively by educators or clinicians.

This study builds upon existing literature that suggests handwriting analysis can serve as a viable adjunct to traditional diagnostic tools. Previous research has demonstrated that children with ADHD often display significant deviations in handwriting consistency when compared to their neurotypical peers. Furthermore, advancements in machine learning have allowed for the development of predictive models capable of identifying such deviations with increasing accuracy. For example, in studies focused on dysgraphia—a handwriting disorder that may co-occur with ADHD—classification models using machine learning algorithms have achieved accuracies of approximately 70%. These models typically incorporate both visual handwriting features and demographic variables such as age and gender to enhance predictive power. Similarly, in studies analyzing individual characters using artificial neural networks, classification accuracy has ranged between 50% and 75%, depending on the complexity and quality of the input data.

The current study utilized a supervised learning approach, where labeled handwriting samples were used to train classifiers such as Support Vector Machines (SVM), Random Forests, and Convolutional Neural Networks (CNNs). Feature sets included both static features (e.g., letter size, slant, baseline drift) and dynamic features (when available, such as pen pressure or stroke speed). The inclusion of cross-validation techniques ensured robustness and minimized overfitting. Furthermore, data augmentation methods—such as synthetic image generation and geometric transformation—were employed to increase the diversity and generalizability of the training dataset.

Despite their diagnostic utility, traditional methods such as neuroimaging, electroencephalography (EEG), and psychometric assessments are often resource-intensive, requiring specialized equipment and trained personnel. Moreover, they demand prolonged periods of stillness and concentration, which can be particularly challenging for young children, especially those already exhibiting symptoms of hyperactivity or inattention. These constraints underscore the need for accessible, efficient, and child-friendly alternatives. Handwriting-based analysis, as proposed in this study, addresses this gap by offering a rapid, low-cost, and minimally intrusive screening approach that can be easily implemented in educational environments.

The model developed in this research incorporates object detection algorithms capable of identifying and quantifying handwriting features such as spacing, alignment, stroke uniformity, and pressure intensity. These parameters are processed to detect statistically significant deviations from expected developmental norms. The system has been designed with scalability and usability in mind, enabling its potential deployment as a mobile application. Such a tool could empower teachers and parents to perform preliminary screenings outside of clinical settings and make informed decisions regarding further evaluation or intervention. Importantly, this approach facilitates early identification of risk, which is critical in optimizing long-term academic and behavioral outcomes for children with ADHD.

From an ethical and practical perspective, early identification must be balanced with caution to avoid overdiagnosis or stigmatization. Therefore, it is essential that tools developed for educational use be positioned as preliminary screening instruments, not as substitutes for formal clinical diagnosis. Additionally, data privacy, informed consent, and transparency in algorithmic decision-making are key principles that must be maintained, especially when involving sensitive developmental information of minors.

The findings of the study support the broader shift in contemporary diagnostics toward integrating computational tools with traditional assessment frameworks. By transforming subjective behavioral observations into quantifiable data points, image processing and machine learning open new avenues for early detection and personalized intervention. The model presented in this study serves as a step toward more inclusive and technologically informed practices in child psychology and special education. It also offers a promising direction for future research into the intersection of digital phenotyping, cognitive neuroscience, and educational assessment.

Looking ahead, future research may benefit from integrating multimodal data sources—including handwriting dynamics (via digital pen tablets), speech patterns, and behavioral video recordings—to develop more comprehensive predictive models. Longitudinal studies tracking the developmental trajectory of at-risk children could further validate the prognostic power of handwriting-based screening tools. In addition, cross-cultural validations and language-specific handwriting analyses will be essential in ensuring the global applicability of such models.

In conclusion, the application of image processing techniques to handwriting analysis provides a robust and innovative method for identifying early signs of ADHD. The objective and replicable nature of this approach enhances diagnostic reliability, while its simplicity and accessibility support broad adoption in educational and clinical contexts. As digital tools continue to advance, such methodologies may play a central role in the development of proactive, data-driven mental health screening systems for children, ultimately contributing to more inclusive, equitable, and effective educational support systems.



1. GİRİŞ

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), çocukluk döneminde ortaya çıkan ve bireyin yaşamı boyunca devam edebilen, bilişsel ve davranışsal işlevleri etkileyen yaygın bir nörogelişimsel rahatsızlıktır (American Psychiatric Association, 2013). DEHB tanısı belirlemede bilinen altın standart yöntem klinik tedavi uzmanı tarafından olabildiğince farklı kaynaktan toplanan bilgilerle konulan tanıdır (Asherson et al., 2016). Mevcut literatürde, Dikkat Eksikliği ve Hiperaktivite Bozukluğu'nun (DEHB) tanısını kesin olarak doğrulamak ya da dışlamak amacıyla kullanılabilecek, yüksek öngörü gücüne sahip standartlaştırılmış yardımcı testler, klinik araştırmalar ya da güvenilir biyobelirteçler henüz geliştirilmemiştir. Nörogörüntüleme (Manyetik Rezonans (MR), PET, SPECT) ve Elektroensefalogram (EEG) de nadir vakalarda ayırıcı tanıda faydalı olabilmelerine rağmen rutin klinik değerlendirmede önerilmemektedir (Faraone, Sergeant, et al., 2003). Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), sadece bilişsel değil aynı zamanda motor gelişimi de etkileyen çok boyutlu bir nörogelişimsel bozukluktur. Literatürde, DEHB'ye özgü temel semptomlardan olan dikkatsizlik, hiperaktivite ve dürtüselliliğin motor becerilerle yakından ilişkili olduğu belirtilmektedir. Araştırmalar, DEHB tanısı almış çocukların yaklaşık %30 ila %50'sinde motor koordinasyon güçlükleri gözlemlendiğini ortaya koymaktadır (Goulardins et al., 2017). Bu tür motor sorunların, çocukların günlük yaşamda karşılaştıkları işlevsel zorlukları artırdığı rapor edilmiştir. Dikkat problemlerinin el yazısı gibi ince motor becerileri de olumsuz yönde etkileyebileceği vurgulanmaktadır (Ghanizadeh, 2010). Çak ve arkadaşları tarafından yürütülen bir çalışmada, 8–11 yaş aralığındaki çocuklarda, yaşla birlikte motor becerilerde gözlenen doğal gelişim eğiliminin, DEHB tanılı bireylerde belirgin biçimde görülmediği ortaya konmuştur (Çak et al., 2018). DEHB olan çocukların yaklaşık %80'inde semptomlar ergenlik döneminde devam ederken, yetişkinlikte de devam edebilmektedir (Faraone, SERGEANT, et al., 2003). Berninger ve arkadaşları, yaptığı çalışmada daha önceki çalışmaları tekrar ederek, DEHB özellikle kötü el yazısı ile ilgili olabileceğini ifade etmiştir (V. Berninger et al., 2017). Günümüzde DEHB ve el yazısı ile ilgili geniş bir literatür oluşmaya devam etmektedir. DEHB tanısı konulması ile ilgili makine

öğrenimi çalışmaları genellikle nörogörüntüleme ve Elektroensefalografi (EEG) üzerine odaklanmaktadır. Elektroensefalografi (EEG), beynin nöronal aktiviteleri sonucu oluşan elektriksel sinyallerin, özel cihazlar aracılığıyla kaydedilerek beyin dalgaları biçiminde görselleştirilmesini sağlayan bir ölçüm yöntemidir. Bu ve buna benzer yaklaşımların literatürde kullanıldığı görülmektedir. Örneğin bir çalışmada wavelet transform kullanılarak entropi özellikleri çıkarılmış makine öğrenmesi yöntemiyle %87'ler civarında bir başarı elde edilmiştir (Aljalal et al., 2022). Benzer bir çalışmada EEG sinyalleri kullanılarak yapay sinir ağları ile DEHB sınıflandırılması yapılmış ortalamada %93'lük doğruluk değeri elde edilmiştir (Mohammadi et al., 2016). Benzer başarının yine EEG sinyalleri ve yapay sinir ağları kullanarak elde edildiği görülmüştür (Catherine Joy et al., 2022). Bireyin göz hareketlerinden DEHB tanısı konulabileceği belirtilmiştir (Munoz et al., 2003). Bunu destekleyen bir çalışmada karar ağaçları kullanılarak başarı elde edilmiştir (De Silva et al., 2019). Göz hareketlerine benzer bir çalışmada gözbebeği ve iris çapının DEHB tanısında yardımcı olabileceği belirtilmiş ve yapılan istatistiksel analizlerde başarılı sonuçların alındığı görülmüştür (Nobukawa et al., 2021). Bunların yanında Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ya da fonksiyonel MR tekniği ile DEHB tanısı çalışmaları bulunmaktadır. fMRI tekniği çalışmakta olan beyindeki fonksiyonel süreçleri kandaki oksijen seviyesine bağımlı sinyalleri temel alarak ölçüm yapar. Nörogörüntülemede makine öğreniminin birincil hedeflerinden biri, beyin sağlığının, hastalıkların ve bozuklukların göstergesi olan nörobelirteçleri ortaya çıkarmaktır (Khosla et al., 2019). fMRI verisini kullanarak derin öğrenme tekniklerinin karşılaştırıldığı bir çalışmada, derin öğrenme tekniklerinin derin olmayan tekniklere göre daha başarılı olduğunu belirtmişlerdir (Yin et al., 2022).

Yukarıda verilen yöntemler ve girişimler hem zahmetli hem de çocuk için oldukça zorlayıcı testlerdir. Bu testler uzun zaman almakta ve çocuklar sabit kalmaları gerekmektedir. Dolayısıyla bu projede DEHB tanısı koymada el yazısının kullanarak çok kısa ve olağan işleyen bir süreç ile oldukça önemli sonuçlar elde edilmesi planlanmaktadır. Bu yöntem ile okullarda öğretmenler ve hatta mobil uygulama ile ebeveynler bile risk altındaki çocuğunu tanıyabilir ve gerekli yönlendirmeleri yapabilir. El yazısı ve yazma beceri eksikliklerinin DEHB ve benzeri rahatsızlıklarında bir işaret olabileceği yapılan çalışmalardan görülebilmektedir. Örneğin yazı yazma güçlüğü olan disgrafi hastalığının tespitinde makine öğrenmesi yöntemi kullanılmış el

yazı örnekleri ile yaş cinsiyet gibi kişisel özellikler ile birlikte sınıflandırma performansı ortalamada %70'ler civarında olmuştur. Bu bilgiler ışığında özetle, Ülkemizde son prevelans çalışmasında DEHB yaygınlığı %12 civarında bulunmuştur (Ulu Ercan, 2018). Bu kadar yaygın görülen bir hastalığın riskini erken safhada saptayabilmek, çocukların eğitim hayatlarına yönelik hayati önem taşıyabilir, tanı alamayan ya da fark edilmeyen birçok çocuk eğitim hayatından kopmakta birçok psikolojik ek hastalık ile uğraşmak zorunda kalmaktadır. DEHB tanısında makine öğrenimi yöntemler kullanılmakla birlikte oldukça zahmetli ve pahalı girişimleri gerektirmektedir, el yazısı ile ilgili yapılan çalışmaların ise metodolojisi daha kısıtlıdır. Bu çalışmanın özgün kısmında ülkemizde DEHB riski olan çocuklar çok erken tespit edilebilecek ve bunu yaparken hiçbir çocuk uzun uğraşı gerektiren onları zorlayıcı ya da rutinin dışında hiçbir girişime maruz bırakılmayacaktır.

El yazısı ve yazma beceri eksikliklerinin DEHB ve benzeri rahatsızlıklarında bir işaret olabilmesi ve bunun yapay zekâ teknikleri ile %70 ve üstü bir doğruluk oranı ile tespit edilebilme durumu projenin özgün değerini oluşturmaktadır. Bu proje özellikle çocuk psikolojisi üzerine yapılacak olan pratik çalışmalar için önemli bir ön ayak ve referans oluşturacaktır.

1.1. Tezin Amacı

Bu çalışmanın amacı, Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı almış çocukların el yazısı becerilerini inceleyerek, bu bireylerin yazılarında karşılaştıkları okunaklılık, akıcılık ve yazının kâğıt yüzeyine yerleştirilmesi gibi alanlardaki zorlukları ortaya koymaktır. Elde edilen bulguların, yazı yazma becerilerinin değerlendirilmesine katkı sağlayarak DEHB tanı ve müdahale süreçlerine destek olması hedeflenmektedir.



2. DEHB (DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU)

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), çocukluk döneminde en sık rastlanan nöropsikiyatrik bozukluklardan biri olarak kabul edilmektedir ve gelişimsel süreç boyunca bireyin bilişsel, davranışsal ve sosyal işlevselliğini önemli ölçüde etkileyebilmektedir (American Psychiatric Association, 2013). Akademik başarısızlık, sosyal ilişki sorunları ve özgüven kaybı gibi çok yönlü sorunlara yol açabilir. Tanı süreci genellikle gözlem ve psikometrik testlere dayansa da, son yıllarda dijital veriler ve yapay zeka destekli analizler alternatif yollar sunmaktadır. Bu bağlamda el yazısının incelenmesi önemli bir araştırma alanı haline gelmiştir

2.1. DEHB'nin Tanımı ve Tarihçesi

DEHB, DSM-5'e göre üç alt tipe ayrılmaktadır: dikkat eksikliğinin baskın olduğu tip, hiperaktivite-dürtüsellik baskın olduğu tip ve birleşik tip. İlk olarak 18. yüzyılda tanımlanan bozukluk, 1980'lerden sonra daha sistematik biçimde DSM sınıflandırmalarına girmiştir. Biyolojik temelli bir bozukluk olan DEHB'nin nörolojik altyapısında dopamin ve norepinefrin gibi nörotransmitter sistemlerinin bozulduğu gözlemlenmiştir. Genetik yatkınlık önemli bir etkidir (American Psychiatric Association, 2013).

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), çocukluk çağına başlayıp yetişkinliğe kadar sürebilen, dikkatsizlik, aşırı hareketlilik ve dürtüsellik ile karakterize bir nörogelişimsel bozukluktur. Bu bozukluk, her bir yerde farklı şekillerde görülebilir. Bazı çocuklarda dikkat dağınıklığı ön plandayken, bazı çocuklarda aşırı hareketlilik ve kontrolsüz davranışlar daha belirgindir (American Psychiatric Association, 2013).

Araştırmalar, DEHB'li bireylerde genetik yatkınlık bulunduğunu ve bu çocukların bazılarında anne karnındayken bile normalden fazla hareket ettiklerinin gözlemlendiğini göstermektedir. Beyin görüntüleme çalışmaları, DEHB'li bireylerde dikkat ve hareket kontrolünden sorumlu bazı beyin bölgelerinde farklılıklar olabileceğini ortaya koymuştur (Franke et al., 2018). EEG (elektroensefalografi) gibi

yöntemlerle yapılan ölçümlerde ise bazı çocuklarda hafif nörolojik sapmalar saptanmıştır.

Cinsiyete bağlı olarak belirtiler değişebilir. Erkek çocuklarda daha çok hareketlilik ve dürtüsellik görülürken, kız çocuklarda genellikle dikkat dağınıklığı baskın olmaktadır. Ayrıca, DEHB'li çocukların çoğunda büyüdükçe hareketlilik azalabilir, ancak dikkat eksikliği belirtileri çoğu zaman yaşam boyu devam eder (Faraone et al., 2015).

DEHB tedavisinde ilaçlar önemli rol oynar. Ancak yalnızca ilaç tedavisi yeterli olmayabilir. Aile, öğretmen ve doktor iş birliğiyle yürütülen bir destek sistemi, tedavi sürecini daha etkili hale getirir. Özellikle okul ve ev ortamlarında çocuğa uygun düzenlemeler yapılması, çocuğun başarısı için oldukça önemlidir (Pliszka, 2007).

2.2. DEHB'nin Nedenleri

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), karmaşık bir etiyolojiye sahip olup; genetik, nörobiyolojik ve çevresel faktörlerin etkileşimi sonucunda ortaya çıkan nörogelişimsel bir bozukluktur.

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı konmuş bireyler üzerinde yapılan nörobiyolojik çalışmalar, bazı ortak fizyolojik özelliklerin varlığına işaret etmektedir. Bu bireylerde sıklıkla dopamin düzeylerinde düşüklük tespit edilmiştir. Dopamin, dikkat, motivasyon ve ödül mekanizmalarında kritik rol oynayan bir nörotransmitterdir. Ayrıca, sosyal muhakeme ve davranış kontrolü gibi işlevleri yöneten prefrontal korteksin, DEHB'li bireylerde diğer beyin bölgelerine kıyasla daha az etkin çalıştığı rapor edilmiştir (Shaw et al., 2007).

Yapısal beyin görüntüleme teknikleri kullanılarak gerçekleştirilen araştırmalarda ise DEHB'li bireylerin beyinde gri madde hacminin azaldığı gözlemlenmiştir. Gri madde, motor kontrol, karar verme, öz düzenleme ve konuşma gibi temel bilişsel işlevlerde rol oynayan sinir hücrelerinden oluşan bölgedir (Castellanos et al., 1996). Bu farklılıklar, DEHB'nin sadece davranışsal bir bozukluk değil, aynı zamanda biyolojik temellere dayanan bir durum olduğunu desteklemektedir.

DEHB, erkek çocuklarda kızlara oranla yaklaşık 2 ila 3 kat daha yaygın görülmektedir. Bu durumun ortaya çıkmasında biyolojik, genetik, çevresel ve psikososyal faktörlerin etkileşiminin rol oynadığı düşünülmektedir (Faraone, SERGEANT, et al., 2003). Genetik yatkınlık özellikle önemli bir risk unsurudur; DEHB öyküsü bulunan ebeveyn

ya da kardeşlerde benzer semptomların gözlenme olasılığı artmaktadır. Bunun yanı sıra, doğum öncesi dönemde alkol veya sigara kullanımına maruz kalma, erken doğum, doğum komplikasyonları ve erken çocukluk döneminde geçirilen beyin travmaları gibi çevresel faktörler de DEHB gelişiminde etkili olabilmektedir (Linnet et al., 2003).

Güncel araştırmalar, DEHB'nin temel nedenlerini üç ana başlık altında toplamaktadır: genetik yatkınlık, nöroanatomik ve nörokimyasal farklılıklar ve çevresel risk etmenleridir.

2.2.1. Genetik yatkınlık

DEHB'nin kalıtsal yönü oldukça güçlüdür. Aile, ikiz ve genetik çalışmalar; bu bozukluğun özellikle birinci derece akrabalarda görülme oranının yüksek olduğunu göstermektedir (Faraone et al., 2018). Yapılan çalışmalar, DEHB'nin gelişiminde rol oynayan bazı aday genlerin varlığını ortaya koymuştur:

- Dopamin reseptör genleri: Özellikle DRD4 ve DRD2 genleri, dopamin salınımı ve alımını düzenler. DRD4 7-repeat aleli taşıyan bireylerde DEHB semptomlarına daha sık rastlandığı saptanmıştır (Brookes et al., 2006).
- Dopamin taşıyıcı geni (DAT1): DAT1 genindeki polimorfizmler, sinaptik boşlukta dopamin düzeylerinin düzenlenmesini etkileyerek dikkat ve dürtü kontrol mekanizmalarını değiştirir (Franke et al., 2009).

Genetik yapı çevresel etkenlerle birleşerek semptomların ortaya çıkmasında önemli bir rol oynar (Faraone et al., 2018).

2.2.2. Beyin yapısı ve nörokimyasal farklılıklar

Nörogörüntüleme çalışmalarına göre DEHB'li bireylerde bazı beyin bölgelerinde yapısal ve işlevsel farklılıklar gözlemlenmiştir:

- Prefrontal korteks: DEHB'li bireylerde yürütücü işlevlerden sorumlu bu bölgede hacim azalması ve aktivite düşüklüğü sıkça rapor edilmiştir. Bu durum planlama, dikkat sürdürme ve dürtü kontrolü gibi işlevleri etkiler (Castellanos & Proal, 2012).
- Bazal ganglionlar ve serebellum: Hareket koordinasyonu ve dürtü denetimi ile ilişkili olan bu yapılar, DEHB'li çocuklarda genellikle küçüktür ya da yeterince organize değildir (Bush, 2011).

- Dopamin ve norepinefrin metabolizması: DEHB'nin biyokimyasal temelinde dopamin ve norepinefrin düzeylerinde dengesizlik yer alır. Bu nörotransmitterler dikkat, motivasyon ve ödül mekanizmalarıyla ilişkilidir (Rubia, 2018).

Bu nöroanatomik farklılıklar, hem fMRI hem EEG çalışmalarında doğrulanmıştır.

2.2.3. Doğum öncesi ve sonrası risk etmenleri

Çevresel faktörler, genetik ve biyolojik yatkınlığı bulunan bireylerde DEHB semptomlarının şiddetini artırabilir. Özellikle prenatal ve perinatal dönemlerdeki riskler önemlidir.

- Prenatal toksin maruziyeti: Anne karnındayken sigara dumanına , alkol ve kurşun gibi nörotoksinlere maruz kalan bebeklerde DEHB riski artar (Millichap & Yee, 2012).
- Düşük Doğum Ağırlığı ve Erken Doğum : Beyin Gelişimini sekteye uğratabilecek bu etkenler, DEHB ile ilişkilidir (Linnet et al., 2003).
- Doğum Komplikasyonları: Oksijensiz kalma, uzamış doğum süresi gibi faktörler beyin gelişimini olumsuz etkileyebilir (Linnet et al., 2003).
- Beslenme ve Erken Çocukluk Travmaları: Demir , Çinko ve Omega-3 eksikliği; stresli aile ortamı ya da ihmal gibi durumlar nörogelişimi etkileyebilir (Asil & Rakıcıoğlu, 2013).

Bu çevresel faktörler, özellikle genetik yatkınlıkla birleştiğinde bozukluğun ortaya çıkma ihtimalini önemli ölçüde artırmaktadır.

2.3. DEHB Belirtileri ve Alt Tipleri

Çocuklarda Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısına ilişkin davranışsal bulgular, motor aktivite düzeyinde artış ile ilişkilidir. DEHB'li çocukların gereksiz yere sağa sola koşmaları, sürekli hareket halinde bulunmaları ve aşırı konuşmaları, bu bozuklukla karakterize edilebilecek belirgin özellikler arasında yer almaktadır. Ayrıca , çocukların sakin kalma yeteneklerindeki eksiklik; el ve ayak hareketlerinin kontrol edilememesi, impulsivite ve dikkat sürelerinin kısa olması gibi gözlemler, DEHB' nin klinik belirtisi olarak değerlendirilebilir (Barkley, 1997).

Hiperaktivite sendromlarının bulunmadığı durumlarda ise çocuklarda daha çok sessizlik, içine kapanıklılık, yavaşlık ve dalgınlık gibi davranışsal özellikler

gözlemlendiği durumlarda “Dikkat Eksikliği Bozukluğu” tanısı konulabilmektedir. Bu farklı klinik tablolar, DEHB’nin alt tiplerinin belirlenmesi sürecinde önemli bir ayrım oluşturmaktadır (American Psychiatric Association, 2013). Hiperaktivite semptomlarının çoğunlukla bebeklik döneminde başladığı ancak semptomların çocuğun okul yaşamına adım atmasıyla daha belirgin hale geldiği literatürde ifade edilmektedir (Lisa L Weyandt, 2007).

2.3.1. Bilişsel ve dikkatle ilgili belirtiler

DEHB’li bireyler dikkatlerini odaklamakta ve sürdürmekte zorluk yaşarlar. Genellikle bir işe başladıktan kısa bir süre sonra başka bir uyarana yönelirler. Dikkat eksikliği, akademik başarısızlıkla doğrudan ilişkilidir ve aşağıdaki davranışlarla gözlenebilir (American Psychiatric Association, 2013).

- Görevlerini tamamlayamama, dikkat dağınıklığı, yapılan işlerin yarım kalması.
- Ayrıntılara dikkat etmeme, sık yapılan dikkatsizce hatalar.
- Eşyaları sık kaybetme (kitap, kalem, oyuncak vb.)
- Günlük sorumlulukları unutma, planlama güçlüğü.
- Defter, ödev ya da etkinliklerde düzensizlik ve organizasyonda zorlanma.

Bu belirtiler, özellikle okul çağındaki çocukların eğitim hayatında belirgin zorluklar yaşamalarına neden olur (Lisa L Weyandt, 2007).

2.3.2. Davranışsal ve sosyal belirtiler

Dikkat Eksikliği ve Hiperaktivite Bozukluğu’nun (DEHB) davranışsal boyutu; dürtüsellik, motor hareketlerin kontrolünde zayıflık ve toplumsal kurallara uyumda yetersizlik gibi belirtilerle karakterizedir. Bu belirtiler, bireyin hem kişisel gelişimini hem de sosyal çevresiyle olan etkileşimini olumsuz yönde etkileyebilmektedir (American Psychiatric Association, 2013).

Davranışsal düzeyde, bireyde sürekli ve yersiz konuşma, karşısındaki kişilerin sözünü kesme eğilimi ve aktif dinleme becerisinde zayıflık gözlenebilir. Ayrıca, sınıf gibi yapılandırılmış ortamlarda amaçsız biçimde dolaşma, yerinde uzun süre oturamama ve dikkat gerektiren görevleri tamamlamada güçlük yaygındır (Çelebi & Ünal, 2019).

Grup etkinlikleri sırasında sırasını bekleyememe, akranlarla sık sık çatışmaya girme ve sosyal kuralların ihlali şeklinde davranışlar sıkça raporlanmaktadır. Bu bireylerde

zaman zaman saldırganlık, tehditkâr söylemler, fiziksel zarar verme ya da nesnelere yönelik yıkıcı davranışlar gibi antisosyal eğilimler de gözlemlenebilir (Mash & Barkley, 2003).

DEHB’li çocuklar, özellikle yönlendirme gerektiren sosyal ortamlarda kurallara uymakta zorlanmakta, dışsal denetime yüksek derecede ihtiyaç duymaktadır. Ayrıca tehlike algılarındaki zayıflık, bireyin kendisini fiziksel ya da sosyal açıdan riske atacak davranışlara yönelmesine neden olabilir (Sergeant et al., 2002). Bu tür davranış örüntüleri, bireyin sosyal uyumunu sekteye uğratmakta ve arkadaşlık ilişkilerinde süreklilik sağlamasını engellemektedir.

2.3.3. Motor koordinasyon ve el becerileri

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı alan çocuklarda ince motor becerilere ilişkin belirgin yetersizlikler gözlemlenmektedir. Günlük yaşamda karşılaşılan düğme ilikleme, ayakkabı bağlama, makas kullanma gibi öz bakım ve işlevsel becerilerde başarısızlık sık rastlanan durumlardandır (Piek et al., 1999).

Bununla birlikte, yazı yazma sürecinde de çeşitli zorluklar ortaya çıkmaktadır. Bu çocuklar genellikle harf boyutunu ayarlamada, satır hizasına uygun yazmada ve yazı düzenini sürdürmede güçlük yaşamaktadırlar (Rosenblum & Livneh-Zirinski, 2008). Bu sorunların temelinde, el-göz koordinasyonu ve ince motor planlama becerilerindeki yetersizliklerin yer aldığı bildirilmektedir (Meyer & Sagvolden, 2006).

İnce motor becerilerdeki bu sınırlılıklar yalnızca akademik başarıyı değil, aynı zamanda günlük yaşamda bağımsız hareket etme ve öz bakım becerileri gibi gelişimsel alanları da olumsuz etkilemektedir (Barkley, 1997). Bu nedenle, DEHB’li çocukların erken dönemde motor gelişim açısından değerlendirilmesi ve uygun müdahale programlarına yönlendirilmesi büyük önem taşımaktadır.

2.3.4. Duygusal ve fiziksel özellikler

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı almış bireylerde, duygusal düzenleme güçlükleri yaygın olarak gözlemlenmektedir. Bu bireylerde ruh halinde ani değişimler, öfke patlamaları ve sinirlilik gibi duygusal dalgalanmalar sıklıkla görülür. Ayrıca düşük stres toleransı ve depresif eğilimler, duygu durumunu daha da istikrarsız hale getirebilmektedir (Shaw et al., 2014).

Uyku düzeninde bozulmalar da DEHB'nin sık karşılaşılan belirtileri arasındadır. Bu çocuklarda gece uyanmaları, uykuya dalmakta güçlük ve yetersiz uyku kalitesi gibi problemler rapor edilmiştir. Bu durum, gündüz işlevselliğini olumsuz yönde etkilemekte, dikkat ve duygusal dengeyi daha da zorlaştırmaktadır.

DEHB'li bireylerde merkezi sinir sisteminin düşük uyarılmışlık düzeyinde çalıştığı ve bu nedenle acıya karşı toleransın arttığı, dış uyaranlara yeterli tepki verilemediği de bazı çalışmalarda vurgulanmıştır. Bunun yanı sıra, bazı bireylerde obsesif-kompulsif eğilimler, aşırı titizlik ve kontrol etme ihtiyacı gibi davranışlar da görülebilir (Cortese et al., 2009).

Sosyal açıdan ise bu bireylerin yardımsever, sosyal yönü güçlü ve esprili bir kişilik yapısına sahip oldukları; ancak sınır koymada ve sosyal ilişkilerde uygun mesafeyi korumada zorluk yaşadıkları bildirilmektedir. Tüm bu semptomlar, yalnızca bireyin genel yaşam kalitesini değil, aynı zamanda ebeveyn tutumlarını, aile içi ilişkileri ve eğitimsel süreci de doğrudan etkilemektedir (Hinshaw, 2017).

2.4. DEHB ve Eşlik Eden Öğrenme Güçlükleri

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), bireylerin dikkatlerini sürdürmede ve odaklanmada zorluk yaşadıkları, aşırı hareketlilik ve dürtüsellik sergiledikleri bir nörogelişimsel bozukluktur (Lisa L Weyandt, 2007). DEHB'nin yanı sıra bu bozukluğu taşıyan bireylerde sıklıkla eşlik eden öğrenme güçlüklerine de rastlanmaktadır.

DEHB'li bireylerin öğrenme süreçlerinde karşılaştıkları zorluklar; dikkat dağınıklığı, düşük organizasyon becerileri, planlama güçlükleri, zaman yönetiminde yetersizlik ve dürtüsel davranışlarla ilişkilendirilmektedir. Bu özellikler, özellikle akademik başarı üzerinde olumsuz etkiler yaratmaktadır.

Eşlik eden öğrenme güçlükleri, DEHB'li bireylerin bilişsel becerilerinde yaşadıkları sınırlılıklar nedeniyle öğrenme süreçlerinde aksaklıklar yaşanmasına neden olur. Bu güçlükler; dil becerileri, okuma, yazma ve matematiksel işlemler gibi alanlarda belirginleşebilir. Araştırmalar, öğrenme güçlüklerinin DEHB tanısı almış bireylerin yaklaşık %20–30'unda görüldüğünü ortaya koymaktadır (Lisa L Weyandt, 2007). Bu bireylerde dikkat eksiklikleri ve aşırı dürtüsellik, öğrenmenin verimli gerçekleşmesini engelleyebilmektedir.

DEHB sıklıkla özgül öğrenme güçlükleri, davranış bozuklukları ve anksiyete bozuklukları gibi durumlarla birlikte görülmektedir. Bu durum, bireyin akademik gelişimini olduğu kadar sosyal uyumunu da olumsuz etkileyebilir.

2.4.1. Okuma güçlükleri (disleksi)

Disleksi, yazılı dili anlamada güçlük olarak tanımlanır ve DEHB’li bireylerde sıkça karşılaşılan bir eşlik eden güçlüktür. DEHB, okuma sürecinde dikkat eksikliği, okuma hızında düşüş ve yanlış anlamalar gibi sorunlara yol açabilir (Fletcher et al., 2018).

Disleksi, özellikle okuma becerilerinde kalıcı ve belirgin zorluklarla tanımlanan özgül bir öğrenme bozukluğudur. Bu durum çoğunlukla ilkokul çağında, çocuğun okuma sürecine başlamasıyla fark edilir (American Psychiatric Association, 2013). Disleksiye sahip çocuklar, görsel olarak benzer harfleri (örneğin “b” ile “d”, “p” ile “q”) karıştırma eğilimindedir. Okuma sırasında harf ya da kelime atlama, heceleri karıştırma, kelimeler içinde harf sırasını değiştirme gibi hatalar yaygındır (Sally E. Shaywitz, n.d.). Aynı zamanda bu bireyler, okuduklarını anlama ve anlatma konularında da ciddi güçlükler yaşarlar (Snowling & Hulme, 2012).

Disleksi çoğunlukla yazma ve aritmetik becerilerle ilgili zorlukların da eşlik ettiği karmaşık bir öğrenme bozukluğudur. Zeka düzeyi normal ya da üzerinde olan bireylerde, akademik gereksinimler artana kadar fark edilmeden ilerleyebilir; ancak sınıf düzeyi yükseldikçe belirtiler belirgin hâle gelir (Lyon et al., 2003).

Okuma bozukluğuna bağlı olarak gözlemlenebilecek hatalar şunlardır:

- Harflerin yanlış okunması veya karıştırılması
- Harf ya da hece atlama
- Kelime eksiltme ya da yanlış kelime kullanımı
- Harf sıralamasında bozulmalar
- Satır takibi zorlukları ve okumada yavaşlık
- Cümlelere sondan veya ortadan başlama eğilimi

Bu tür hatalar çocuğun akademik başarısını olumsuz etkilerken özgüven gelişimini de sınırlayabilir. Dolayısıyla, disleksiye yönelik erken tanı ve müdahale, bireyin eğitim hayatı açısından kritik öneme sahiptir. Bu süreçte bireyselleştirilmiş öğretim

yaklaşımları ve teknolojik destek araçları etkili olmaktadır (Snowling & Hulme, 2012).

2.4.2. Yazma güçlükleri (disgrafi)

DEHB'li çocuklar, yazılı ifadelerini düzgün ve organize bir şekilde oluşturmakta zorluk yaşayabilirler. Yazı yazma süreci, sıklıkla dürtüsellik ve motor beceri eksiklikleri nedeniyle aksar. Bu durum, yazılı anlatım becerilerini olumsuz etkileyebilir.

Çocukluk döneminde sıkça karşılaşılan yazma güçlükleri, dil algısında ve ifade etmede yaşanan sorunlarla birlikte görülmektedir. Bu bozukluklar, özellikle Disleksi ve DEHB gibi nörogelişimsel bozukluklarla eş zamanlı olarak ortaya çıkabilir. Yazılı anlatım becerilerindeki yetersizlikler, çocukların akademik performansını olumsuz etkileyebilir. Bu bireylerde, yazılı ifadeyi üretme, yazım kurallarına uyum sağlama ve düzenli bir metin oluşturma becerileri sınırlı olabilir (Cutting & Denckla, 2001).

Yazma bozukluğu olan çocuklarda sık rastlanan hatalar arasında; görsel olarak benzer harfleri (örneğin b–d, m–n, c–ç, s–ş) karıştırma ya da bu harfleri yanlış kullanma yer almaktadır. Ayrıca, noktalı harfler ile noktasız harflerin (o–ö, u–ü, ı–i) birbirine karıştırılması da yaygın bir durumdur. Heceleme hataları, kelimelerin bölünerek yazılması, yazı sırasında noktalama işaretlerinin ihmal edilmesi, düzensiz sayfa yerleşimi ve paragraf oluşturma becerisinin eksikliği de dikkat çeken diğer sorunlar arasındadır (Graham & Harris, 2005).

Bu çocuklar genellikle karmaşık, okunaksız ve düzensiz yazı karakterleri sergilerler. Sözcükler arasında boşluk bırakmadan yazma, satır hizasını koruyamama ve sözcükleri yanlış kopyalama gibi motor beceriye dayalı eksiklikler de gözlemlenmektedir. Görsel-motor koordinasyonun zayıflığı, yazılı materyalin doğru ve düzenli bir biçimde aktarılmasını zorlaştırmaktadır.

Bu bağlamda, eğitim ortamlarında bu belirtilerin erken fark edilmesi ve uygun müdahale programlarının uygulanması büyük önem taşımaktadır. Yazma bozukluklarının yalnızca akademik değil, aynı zamanda psikososyal etkileri de dikkate alınmalı ve bütüncül bir destek yaklaşımı benimsenmelidir.

2.4.3. Matematiksel güçlükler (diskalkuli)

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) olan bireyler, akademik alanda özellikle matematiksel işlemleri yürütme konusunda belirgin zorluklar yaşayabilmektedir. Bu bireylerde dikkat sürelerinin kısa olması, işlem basamaklarını takip etmede güçlük yaşamalarına ve sayısal veriye odaklanmada yetersizlik göstermelerine yol açmaktadır. Bu durum, yalnızca soyut matematiksel kavramların öğrenilmesini değil, aynı zamanda günlük yaşamda karşılaşılan temel aritmetik işlemlerin uygulanmasını da olumsuz etkileyebilir (Geary, 2010).


Aritmetik beceri yetersizliği gösteren çocukların karşılaştığı başlıca güçlük alanları şu şekilde sıralanabilir: Matematiksel terimlerin, sembollerin ve işlemlerin kavramsal olarak anlaşılmasında zorlanma, sayma ve sayı dizilerini öğrenmede gecikme, toplama, çıkarma, çarpma ve bölme gibi temel işlemlerin mantığını kavrayamama, Geometrik şekil ve simgeleri tanıma ve yorumlamada zorluk yaşama, problem çözme stratejileri geliştirmede yetersizlik (Aysev & Öner, 2002).

Bu zorluklar, sadece akademik başarıyı değil, çocuğun özgüvenini ve okul motivasyonunu da olumsuz etkileyebilmektedir. Bu nedenle, DEHB'li bireylerin eğitim sürecinde bireyselleştirilmiş öğretim stratejilerine yer verilmesi ve dikkat eksikliğini telafi edici yöntemlerin kullanılması büyük önem taşımaktadır.

2.5. DEHB ve El Yazısı Problemleri

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) çocukluk çağında görülen en yaygın nörogelişimsel bozukluklardan biridir ve bireylerin akademik, sosyal ve kişisel yaşamlarını doğrudan etkileyebilir (*Bilim Teknik*, n.d.). Bu bozukluğun erken ve doğru bir şekilde tespit edilmesi, bireylerin uygun destek mekanizmalarına yönlendirilmesi açısından kritik önem taşımaktadır. Geleneksel tanı yöntemleri büyük ölçüde davranışsal gözlemlere ve uzman görüşlerine dayanmakta, bu da onları öznel yorumlara açık hale getirmektedir (Sarıgedik, 2024). Bu bağlamda, teknolojik yaklaşımların DEHB'nin teşhis sürecine entegre edilmesi, daha güvenilir, tekrarlanabilir ve ölçeklenebilir çözümler geliştirilmesi açısından son derece değerlidir. El yazısı, bireyin motor koordinasyonu, dikkat düzeyi ve bilişsel süreçleri hakkında zengin bilgiler içerdiğinden, DEHB'yi tespit etmek için potansiyel bir biyogösterge olarak öne çıkmaktadır (Shin et al., 2023).

Bazı DEHB’li el yazısı veri örnekleri Şekil 2.1 'de verilmiştir. DEHB için teşhis sürecinin bir parçası olarak, çocuklardan genellikle alfabenin tüm harflerini ve dairesel şekiller içeren karakterleri ve bir cümleyi elle yazmaları istenir. Bu, el yazısının motor kontrol, tutarlılık ve detaylara dikkat gibi çeşitli yönlerinin değerlendirilmesine yardımcı olur.



Şekil 2.1. DEHB EL Yazısı Bozuklukları.

DEHB’li çocuklar, motor becerileri ve yazı yazma sürecinde çeşitli zorluklar yaşayabilirler. Araştırmalar, DEHB’li bireylerin ince motor becerilerinde ve el-göz koordinasyonunda güçlük çekebileceğini göstermektedir (Rosenblum & Livneh-Zirinski, 2008). Bu durum, yazı yazarken harfleri düzgün oluşturamama, satır hizasını koruyamama, düzensiz boşluk bırakma ve kelimeleri eksik yazma gibi problemlere neden olabilir. DEHB’li çocukların yazıları genellikle düzensiz, okunaksız ve standart dışıdır. Bu yazı bozuklukları, akademik başarıyı doğrudan etkileyerek öğrencilerin okulda ek zorluklar yaşamasına neden olabilir (Kaplan Kılıç et al., 2025).

Motor beceriler, bireyin vücudunu kullanarak gerçekleştirdiği hareketleri kapsar ve iki ana gruba ayrılır: Kaba Motor Beceriler, koşmak veya zıplamak gibi büyük kas gruplarını içeren hareketler; İnce Motor Beceriler ise yazı yazmak veya düğme iliklemek gibi daha küçük, hassas kas hareketlerini ifade eder. Literatürde, Dikkat

Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı alan çocukların önemli bir bölümünde bu becerilerde belirgin yetersizliklerin olduğu bildirilmektedir. Örneğin, *Research in Development Disabilities* dergisinde yayımlanan araştırmalar, DEHB’li çocukların yarısından fazlasında hem kaba hem de ince motor becerilerde sorunlar gözlemlendiğini ortaya koymuştur.

İnce motor becerilerde yaşanan problemler genellikle sarsıntılı el hareketleri, düşük el-göz koordinasyonu ve zayıf kas kontrolü ile kendini göstermektedir. Bu durum, çocuğun yazı yazarken hem hızını hem de yazının okunaklılığını olumsuz etkileyebilir. Öğretmenler tarafından çocukların yazılı performansları “düzensiz” ya da “özensiz” olarak değerlendirilebilir. Bu tür etiketlemeler, özellikle grup çalışmaları sırasında akran ilişkilerini olumsuz etkileyebilir, çocuklar sosyal izolasyon ya da dışlanma riskiyle karşı karşıya kalabilir (Rosenblum et al., 2010).

Bunun yanı sıra, yaşanan bu motor güçlükler , öğrencide başarısızlık hissi, hayal kırıklığı ve düşük benlik saygısı gibi duygusal sorunlara yol açabilir. Bu psikososyal etkiler yalnızca akademik başarıyı değil, çocuğun genel psikolojik gelişimini de olumsuz yönde etkileyebilir (Chang & Yu, 2010). Sonuç olarak Çocuk el yazısı gerektiren ödevlerden kaçınma eğilimi gösterebilir bu da öğrenme sürecinde yeni engeller doğurabilir.

DEHB’li çocukların el yazısı ile ilgili karşılaştığı başlıca sorunlar:

- El-Göz Koordinasyon Problemleri: Yazı yazarken harflerin boyutlarını ve hizasını koruyamama (Rosenblum et al., 2010).
- Dikkat Eksikliği Kaynaklı Sorunlar: Yazı yazma sırasında dikkatini çabuk dağılması, kelimelerin veya harflerin eksik bırakılması (Barkley, 1997).
- Hız Kontrol Problemleri: Aşırı hızlı veya yavaş yazma eğilimi, bu da okunaksız yazıya yol açabilir (Tucha et al., 2006).
- Baskı ve Motor Kontrol Zorlukları: Kalem tutuşunda zorlanma ve yazıya uygulanan baskının düzensiz olması (Rosenblum et al., 2003).
- Harf ve Kelimelerde Tutarsızlık: Aynı kelimenin farklı harflerinin değişik büyüklüklerde yazılması, harfler arası düzensiz boşluklar ve kelime sonlarında harflerin eksik bırakılması (Rosenblum et al., 2010).

Bu problemlerin üstesinden gelebilmek için, DEHB’li çocuklara özel yazı eğitimi verilmesi, motor becerilerini geliştirmeye yönelik egzersizler yapılması ve teknolojik yazı desteklerinden (tabletler, klavyeler) faydanılması önerilmektedir.

2.6. Görüntü İşleme ve Yapay Zeka Destekli Tanı Yöntemleri

Dikkat Eksikliği ve Hiperaktivite(DEHB) genellikle bireylerin dikkatlerini sürdürmede zorluk yaşaması, aşırı hareketlilik ve dürtüsellik gibi belirtilerle tanımlanan nörogelişimsel bir bozukluktur (American Psychiatric Association, 2013). DEHB’nin tanısı çoğunlukla gözlemler ve çeşitli psikometrik testlerle yapılırken, bu yöntemlerin subjektif doğası, tanı sürecinin doğruluğunu sınırlayabilmektedir. Ancak, son yıllarda yapay zeka ve görüntü işleme teknolojilerinin kullanımı, DEHB tanısını daha güvenilir hale getirmektedir (Zylowska et al., 2008). Bu yöntemler, biyolojik verilerin daha doğru bir şekilde analiz edilmesini sağlayarak, klinik tanıyı destekleyici bir araç olarak önemli bir rol oynamaktadır. Dijital el yazısı analizi, eye-tracking, fMRI ve derin öğrenme tabanlı çoklu veri entegrasyonu gibi yöntemler, DEHB’nin daha hızlı ve doğru bir şekilde tanımlanmasına olanak tanımaktadır.

2.6.1. Dijital el yazısı analizi

Dijital el yazısı analizi, DEHB’li bireylerin yazılı ifade becerilerini değerlendirmek için kullanılan bir yöntemdir. Bu analiz; yazma hızını, basıncını, hizalamayı ve diğer parametreleri değerlendirerek, bireylerin dikkat seviyeleri hakkında önemli bilgiler sunar (Shin et al., 2023). DEHB’li bireylerde, genellikle düzensiz el yazısı ve düşük yazma hızı gözlemlenir, bu da onların dikkat ve motor beceri problemlerini işaret eder (Hamdi et al., 2020). Dijital yazı analizi, geleneksel gözlemlerden daha objektif ve güvenilir bir ölçüm sağlayarak tanı sürecini hızlandırabilir (Puyjarinet et al., 2024). Yapay zeka, bu yazı özelliklerini otomatik olarak analiz eder ve DEHB ile ilişkili olabilecek kalıpları belirler, böylece klinik değerlendirme için önemli bir araç oluşturur (Shin et al., 2023).

2.6.2. Eye-tracking (göz izleme) ile dikkat analizi

Eye-Tracking teknolojisi, DEHB’li bireylerde dikkat dağılmasını incelenmesinde yaygın olarak kullanılmaktadır. Eye-tracking bireylerin göz hareketlerini izleyerek, belirli bir hedefe ne kadar süreyle odaklandıklarını ve dikkatin nasıl dağıldığını gösterir. DEHB’li bireyler, genellikle daha kısa sürelerle odaklanabilirler ve göz

hareketlerinde daha fazla dağılma eğilimindedirler. Bu teknolojinin, DEHB'nin tanısına katkıda bulunabilir ve dikkat eksikliklerinin derecesi hakkında daha ayrıntılı bilgi sunabilir.

2.6.3. fMRI ile prefrontal kortekste aktivite farklılığı

Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI), beyin aktivitelerindeki değişiklikleri incelemek için kullanılan bir tekniktir. DEHB'li bireylerde, özellikle prefrontal kortekste işlevsel farklılıklar gözlemlenmiştir. Bu bölge, dikkat, planlama, karar verme ve dürtü kontrolü gibi bilişsel işlevleri yönetir. fMRI ile yapılan çalışmalarda DEHB'li bireylerde prefrontal korteks aktivitelerinde anlamlı farklar bulunmuştur. Yapay zeka, fMRI verilerini analiz ederek, prefrontal kortekste meydana gelen bu aktivite farklılıklarını daha hızlı ve hassas bir şekilde belirleyebilir. Bu tür bir analiz, DEHB'nin nörogelişimsel bir bozukluk olduğunu daha kesin bir şekilde ortaya koyar ve tanıyı biyolojik verilerle destekler (Bush et al., 2005).

2.6.4. Derin öğrenme modelleri ile çoklu veri entegrasyonu

Derin öğrenme (DL) modelleri, farklı biyobelirteçlerden gelen verileri entegre etmek için güçlü bir araçtır (L. Zhang et al., 2020). DEHB tanısında, dijital el yazısı eye-tracking ve fMRI verileri gibi çoklu biyolojik verilerin entegrasyonu, daha güvenilir ve doğru sonuçlar elde edilmesini sağlar (Puyjarinet et al., 2024). Derin öğrenme tabanlı modellerin, DEHB tanısındaki doğruluğu önemli ölçüde artırabileceğini öne sürmüşlerdir. Bu modeller, farklı veri kaynaklarından gelen bilgileri tek bir çerçevede değerlendirerek, tanı sürecini daha kapsamlı ve doğru hale getirebilir (Yu et al., 2025).

2.7. Görüntü İşleme Teknikleri ile DEHB Ön Teşhisi

Yapay zeka, makine öğrenmesi ve görüntü işleme alanlarındaki gelişmeler, nörogelişimsel bozuklukların teşhisinde yeni ve etkili yöntemlerin geliştirilmesini sağlamıştır. Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB)'da bu bağlamda erken tanısı için görüntü işleme temelli analiz yöntemlerinden yararlanılan bozukluklardan bir haline gelmiştir. Görüntü işleme teknikleri, bireylerin davranışsal çıktılarından (Örneğin; el yazısı, yüz ifadesi, göz hareketleri vb.) anlamlı veriler elde edilmesini sağlayarak tanı sürecine katkıda bulunmaktadır.

2.7.1. El yazısı görüntüleme analizi

Görüntü işleme teknikleriyle harf hizalama, satır düzeni ve harf büyüklüğü tutarsızlıkları gibi sorunlar otomatik olarak analiz edilebilmektedir.

DEHB’li bireylerin motor kontrol problemleri nedeniyle el yazısı performanslarında bozulmalar gözlemlenmektedir. Bu bozulmalar arasında harf boyutlarında tutarsızlık, hizalama sorunları, baskı kuvvetinde dalgalanmalar ve yazı hızında anormallikler yer almaktadır. Bu tür el yazısı örnekleri dijital ortama aktarıldığında, çeşitli görüntü işleme algoritmaları ile analiz edilebilmekte ve DEHB’ye özgü kalıplar tespit edilebilmektedir (Hamstra-Bletz & Blöte, 1993).

Yapılan araştırmalarda, özellikle dijital kalemler ve tabletler kullanılarak elde edilen yazı verilerinden hız, ivme, kalem basıncı ve yön gibi parametrelerin analiz edilmesiyle DEHB’li bireyler ile kontrol grubu arasında anlamlı farklar bulunduğu görülmüştür. Bu veriler makine öğrenmesi algoritmaları ile eğitilen modellerde sınıflandırma amaçlı kullanılarak yüksek doğruluk oranlarına ulaşılabilmektedir (Drotár et al., 2016).

2.7.2. Dijital kalem verileri

Dijital kalemler, bireyin yazı yazma sürecindeki tüm motor hareketlerini milisaniyelik hassasiyetle kaybeden gelişmiş araçlardır. DEHB tanısında bu kalemler; basınç, hız, ivme, yön, duraklama süresi ve çizgi sürekliliği gibi parametreleri analiz ederek nöromotor kontrol ve dikkat düzeyleri hakkında bilgi verir (Baş et al., 2020).

Toplanan Temel Parametreler;

- Kalem Basıncı(Pressure): DEHB’li bireylerde kalem baskısında düzensizlikler sıkça görülür. Bu durum, ince motor koordinasyon sorunlarının bir göstergesi olabilir (Rosenblum et al., 2003).
- Yazım Hızı(Velocity): Yazma hızındaki ani değişimler, dikkat dağınıklığına ya da dürtüsellğe işaret edebilir. DEHB’li çocuklarda sabit hızla yazı yazmak genellikle zordur (Rosenblum et al., 2003).
- Ritim ve İvme (Acceleration): Kalemın yön değiştirme sıklığı ve eğilimleri analiz edilerek motor kontrol tutarlılığı ölçülebilir. DEHB grubunda bu tür veriler yüksek varyans gösterir (Rosenblum et al., 2003).

- Zamanlama ve Duraklamalar (Timing & Pauses): Yazı sırasında harfler veya kelimeler arasındaki duraksamalar, dikkat kaybı anlarında artış gösterir. Bu, bireyin yazı sürecine olan bilişsel katılımının dolaylı bir göstergesidir (Asselborn et al., 2018).
- Yol Uzunluğu ve Trajektori(Trajectory Analysis): DEHB’li bireylerin yazı karakteristikleri incelendiğinde, harf yapılarının dışına taşma, hizalamada sorunlar ve düz çizgi sürdürülemezliği gibi örüntüler gözlemlenir (Asselborn et al., 2018).

Verilerin işlenmesi ve analiz sürecinde dijital kalemler ile toplanan bu veriler, çeşitli görüntü işleme algoritmaları ve makine öğrenmesi modelleri (Örneğin: SVM, CNN, LSTM) ile işlenir. Yazı örnekleri, önceden etiketlenmiş veri setleriyle karşılaştırılarak, bireyin DEHB’li olup olmadığını belirlemeye yönelik sınıflandırmalar yapılır. Bu sayede DEHB’ye özgü yazı örüntüleri yüksek doğrulukla saptanabilir.

2.7.3. Göz takibi ve yüz ifadesi

Eye-Tracking sistemleri dikkat süresini, yüz tanıma sistemleri ise sosyal ve duygusal ipuçlarını analiz ederek tanıya katkı sunar.

DEHB tanısında geleneksel klinik gözlemler dışında teknolojik yöntemlerden biri de göz takibi (eye-tracking) ve yüz ifadesi analizi (facial expression recognition) sistemleridir. Bu sistemler, bireyin dikkat, odaklanma ve sosyal-duygusal tepkilerini ölçerek tanı sürecine nesnel katkı sunar (Kalkanlı et al., 2024).

2.7.3.1. Göz takibi (eye-tracking) sistemleri

Eye- tracking teknolojisi, bireyin göz hareketlerini, odak noktalarını ve görsel uyaranlara verdiği tepkileri analiz eder. DEHB’li bireylerde genellikle şu anomaliler gözlemlenir:

- Kısa Sabitleme Süreleri: Görsel öğelere kısa süreli bakışlarla odaklanamama (Kalkanlı et al., 2024).
- Sıklıkla Göz Kırpma ve Kaçış Hareketleri: Dikkat dağınıklığına bağlı olarak, gözlerin sürekli hareket halinde olması (Kalkanlı et al., 2024).
- Düzensiz Göz İzleme Yolları: Metin ya da görsel tarama sırasında takip yollarının bozulması (Kalkanlı et al., 2024).

Bu tür veriler, bireyin dikkat kontrol kapasitesi hakkında doğrudan bilgi sunar ve makine öğrenmesi modelleriyle sınıflandırma için kullanılabilir (Kalkanlı et al., 2024).

2.7.3.2. Yüz ifadesi analizi

Yüz tanıma sistemleri, bireylerin mikro ifadelerini ve duygusal tepkilerini analiz ederek sosyal-duygusal becerilerini değerlendirir. DEHB'li bireylerde şu örüntüler görülebilir.

- Zayıf duygusal yanıtlar ve aşırı tepkiler (Kara, 2014) (Örneğin öfke kontrolü zayıflığı).
- Anlık duygu geçişlerine belirginlik: Yüz mimiklerinde kontrolsüzlük, dürtüsellik izleri (Kara, 2014).
- Sosyal ipuçlarını yorumlamada zorlanma: Karşısındakinin duygusunu algılamada güçlük, yanlış tepki verme (Kara, 2014).

Bu analizler özellikle grup çalışmaları ve etkileşimli testlerde uygulanarak bireyin sosyal uyum düzeyi hakkında çıkarımlarda bulunulmasını sağlar.

2.7.3.3. Tanısal ve klinik kullanım

Göz izleme verileri, dikkat dağılım haritaları oluşturarak bireyin dikkat odaklarını görselleştirir. Yüz ifadesi analizi, özellikle duygusal regülasyon bozuklukları ve dürtüsel davranışları nesnel ölçümlerle tespit etmekte kullanılır. Bu sistemler makine öğrenmesi algoritmalarıyla birleştirilerek otomatik tanı sistemlerine entegre edilebilir.

2.7.4. fMRI ve EEG tabanlı yöntemler

Beyin görüntüleme verileri, DEHB'li bireylerdeki frontal korteks aktivite farklılıklarını ortaya koymakta ve makine öğrenmesi ile sınıflandırılabilir (Durstun et al., 2003).

DEHB tanısında beyin görüntüleme tekniklerinin kullanımı, bireyin nörobiyolojik yapılarındaki işlevsel ve yapısal farklılıkların tespit edilmesini mümkün kılmaktadır. Özellikle Fonksiyonel Manyetik Rezonans Görüntüleme (fMRI) ve Elektroensefalografi (EEG) tabanlı analizler, dikkat ve yürütücü işlevlerle ilişkili beyin bölgelerindeki sapmaları inceleyerek DEHB tanısını destekleyen bilimsel veriler sunar (Barkley, 2015).

2.7.4.1. fMRI (fonksiyonel manyetik rezonansı görüntüleme)

fMRI bireyin beyin aktivitesini kan akışındaki değişiklikleri temel alarak ölçen ileri düzey bir görüntüleme tekniğidir. DEHB'li bireylerde aşağıdaki bölgelerde farklı aktivasyon desenleri gözlemlenmiştir.

- Prefrontal Korteks: Dikkat, karar verme ve planlamada sorumlu bu bölgede aktivite düşüklüğü sıklıkla rapor edilmiştir (Doğru, H. & Dursun, 2023).
- Anterior Singulat Korteks(ACC): Hata farkındalığı ve dürtü kontrolü ile ilgili aktivite bozuklukları gözlenmiştir.
- Bazal Ganglionlar ve Serebellum: Motor koordinasyon ve yürütücü işlevlerde rol oynayan bu yapılarda hacimsel azalma ve düşük bağlantılılık tespit edilmiştir (Doğru, H. & Dursun, 2023).

fMRI analizleri, özellikle konyolüsyonel sinir ağı(CNN) gibi derin öğrenme modelleriyle işlenerek bireylerin sınıflandırılmasında yüksek doğruluk oranlarına ulaşılmasını sağlar (Riaz et al., 2020).

2.7.4.2. EEG (elektroensefalografi) tabanlı analizler

EEG, beynin elektriksel aktivitesini ölçen ve özellikle zaman çözünürlüğü yüksek olan bir yöntemdir. DEHB tanısı için EEG sinyalleri özellikle delta, theta, alfa ve beta dalga örüntüleri açısından incelenmektedir.

- Artmış Theta Aktivitesi: DEHB'li çocuklarda özellikle frontal bölgelerde theta dalgası oranının arttığı tespit edilmiştir. Bu durum düşük dikkat düzeyiyle ilişkilidir (Barry, Johnstone, et al., 2003).
- Düşük Beta Aktivitesi: Beta dalgaları genellikle dikkatli ve uyanık durumlarda gözlemlenir. DEHB'li bireylerde bu dalgalarda azalma yaygındır (Barry, Johnstone, et al., 2003).
- Theta / Beta Oranı (TBR): Tanı kriteri olarak sıkça kullanılan bu oran, DEHB grubunda anlamlı biçimde daha yüksektir (Mao et al., 2025).

2.7.4.3. Tanı sürecine katkıları

Objektif ölçüm davranışsal testlerle kıyasla beyin aktivitelerine dayalı nesnel veriler sunar. Erken Tanı Potansiyeli özellikle 5-8 yaş arası çocuklarda davranışlar henüz belirginleşmeden nörofizyolojik farklılıklar tespit edilebilir (Lohani et al., 2025). Tedavi takibi ilaç tedavisi sonrası fMRI veya EEG analizlerinde görülen değişimler tedaviye yanıtın izlenmesine olanak tanır.

2.7.5. Yapay zeka destekli tanı sistemleri

Yapay Zeka (YZ) teknolojileri, sağlık hizmetlerinde tanı, sınıflandırma ve karar destek sistemleri alanında önemli bir yer edinmiştir. Özellikle DEHB (Dikkat Eksikliği ve Hiperaktivite Bozukluğu) gibi tanısı büyük oranda öznel değerlendirmelere dayalı nörogelişimsel bozukluklar için, YZ tabanlı yaklaşımlar hem objektif ölçütlerin kullanılması hem de çok boyutlu veri analizlerinin gerçekleştirilmesi açısından önemli olanaklar sunmaktadır. Gelişmiş makine öğrenmesi ve derin öğrenme algoritmaları, EEG, fMRI, göz hareketi izleme ve davranışsal test verilerini işleyerek yüksek doğruluk oranlarıyla tanı desteği sağlayabilmektedir (Rubia, 2018).

YZ tabanlı tanı sistemlerin başlıca avantajları tanı sürecine nesnellik kazandırmaları, büyük veri kümelerinde öğrenme kapasitesine sahip olmaları, erken yaşta tanı ve müdahale olasılığı sunmaları ve kişiye özel tedavi planlamasını kolaylaştırmaktadır (Lohani et al., 2025). Bununla birlikte etik sorunlar (özellikle çocuk verilerinde mahremiyet) veri standardizasyon eksiklikleri, kültürel farklılıklar ve klinik genellenebilirlik gibi sınırlılıklar halen önemini korumaktadır.

2.7.5.1. Makine öğrenmesi tabanlı tanı modelleri

Makine öğrenmesi (ML), sistemlerin deneyim yoluyla öğrenmesini sağlayan algoritmalar bütünüdür. DEHB'nin tanılmasında; bireylerin elde edilen EEG, göz takibi ve davranışsal performans gibi çok çeşitli biyobelirteçler ML algoritmalarına aktarılmakta ve sınıflandırıcı modeller aracılığıyla değerlendirme yapılmaktadır. Örneğin; Destek Vektör Makineleri (Support Vector Machines-SVM) ve Karar Ağaçları (Decision Trees) gibi denetimli öğrenme algoritmaları, özellikle EEG temelli theta/beta oranı, göz sabitleme süresi ve yazı hızı gibi parametrelerle DEHB sınıflamasında etkin biçimde kullanılmaktadır. Bu modeller, farklı DEHB alt tiplerini ayırt edebilme kapasitesine sahiptir (Alsharif et al., 2024).

2.7.5.2. Derin öğrenme yaklaşımları

Derin Öğrenme çok katmanlı yapar sinir ağlarını kullanan ve özellikle büyük veri kümelerinde yüksek performans gösteren bir alt disiplin olarak, DEHB tanısında son yıllarda sıkça tercih edilmektedir.

Konvolüsyonel Sinir Ağları (CNN) , başta fMRI görüntüleri olmak üzere görsel temelli verilerin sınıflandırılmasında başarıyla uygulanmaktadır. CNN modelleri,

DEHB'ye özgü prefrontal korteks aktivite örüntülerini öğrenerek yüksek tanı doğruluğunu sağlayabilmektedir (Riaz et al., 2020).

Tekrarlayan sinir ağırları(RNN) ve özellikle uzun kısa süreli bellek mimarileri, EEG gibi zaman serisi biçimindeki verilerin analizinde kullanılmakta ve bireyin dikkat ve dürtüsellik örüntülerini hassas biçimde yakalayabilmektedir (Alsharif et al., 2024).

2.7.5.3. Multimodal veri entegrasyonu

Tanı performansını artırmak amacıyla tek bir veri türü yerine çoklu veri kaynaklarını aynı yapay zeka modelinde birleştirilmesi eğilimi artmıştır. Bu yaklaşım multimodal veri entegrasyonu olarak adlandırılmakta ve özellikle DEHB gibi heterojen bozukluklar için daha kapsamlı değerlendirme imkanı sunmaktadır (Rehman et al., 2025).

El yazısı dinamikleri, EEG dalga örüntüleri, yüz ifadeleri, göz hareketleri ve davranışsal görev performansları gibi çok çeşitli modalitelerden elde edilen veriler, yapay zeka sistemlerinde bütünleştirilmesinde ve daha duyarlı tanısal modeller geliştirilmektedir.

2.7.5.4. Klinik uygulamalar ve gelişmiş YZ sistemleri

Yapay zeka destekli tanı sistemleri, araştırma düzeyinden klinik pratiğe geçmeye başlamıştır. Özellikle ABD Gıda ve İlaç Dairesi (FDA) tarafından onaylanan NEBA (Neuropsychiatric EEG-Based Assessment Aid), DEHB tanısında kullanılan ilk yapay zeka destekli EEG analiz sistemlerinden biridir. NEBA sistemi, theta/beta oranını ölçerek klinisyenlerin karar süreçlerine objektif veri sağlamaktadır (Stein et al., 2016).

Bunun dışında çeşitli mobil uygulamalar ve web tabanlı karar destek platformları, hem uzmanlara hem de ailelere ön tanı konusunda rehberlik etmek üzere geliştirilmektedir. Bu sistemler, düşük maliyetli ve hızlı bir tarama aracı olarak öne çıkmaktadır (Carlat, 2014).

3. MATERYAL YÖNTEM

3.1. Görüntü İşleme

3.1.1. Görüntü

Görüntü, gerçek dünyadaki üç boyutlu nesnelerden oluşan bir sahnenin basitleştirilmiş bir temsidir. Matematiksel olarak iki değişkenli bir fonksiyon olarak da ifade edilebilir. Görüntü üç boyutlu bir görünümün iki boyutlu bir haritası olarak tanımlanabilir.

Görüntü İşleme, dijital ortamdaki görsellerin çeşitli yöntemlerle analiz edilmesini, üzerinde işlem yapılmasını ve daha kullanışlı hale getirilmesini amaçlayan çok disiplinli bir alandır. Gelişen teknoloji ile birlikte, görüntü işleme tekniklerinin kullanım alanları sağlık, güvenlik, eğitim, tarım, ulaşım gibi birçok sektörde hızla yaygınlaşmaktadır. Bu alandaki ilerlemeler sayesinde, görüntülerin hem analiz hem de karar destek süreçlerinde etkin şekilde kullanılması mümkün hâle gelmiştir.

Dijital görüntü işleme süreci, görüntülerin bilgisayar sistemleri tarafından algılanabilir ve anlamlandırılabilir hale getirilmesini sağlar. Bu süreçte temel amaç, görüntü verisinden anlamlı ve yapılandırılmış bilgi üretmektir (Gonzales, R.C, & Woods, 2018). Görseller genellikle piksellerden oluşur ve her piksel belirli bir yoğunluk ya da renk bilgisi taşır. Görüntünün işlenmesi sırasında bu piksellerin değeri çeşitli matematiksel algoritmalar yardımıyla dönüştürülerek analiz edilir (A. K. Jain, 1989).

Görüntü işleme yazılımları, kullanıcıya görüntüleri iyileştirme, analiz etme ve çeşitli filtreleme yöntemleriyle işleme olanağı sunar. Ayrıca görüntülerin yorumlanmasında kullanılan teknikler sayesinde, sadece iki boyutlu (2D) değil, üç boyutlu (3D) veriler de analiz edilebilir. Bu nedenle görüntü işleme, özellikle makine öğrenmesi ve yapay zeka sistemleriyle bütünleşerek çağdaş dijital analiz çözümlerinin temel bileşenlerinden biri hâline gelmiştir (Sonka, 2014).

3.1.2. Görüntü yakalama

Görüntü yakalama, gerçek dünyadaki bir nesne ya da sahnenin sayısal ortama aktarılması sürecidir. Bu işlem genellikle dijital kameralar, tarayıcılar veya sensör

sistemleri aracılığıyla gerçekleştirilir. Görüntü yalnızca durağan sahneler için değil, video gibi hareketli içerikler üzerinden de alınabilir. Gelişmiş yazılımlar sayesinde bu görüntüler çerçeve bazlı analiz edilerek işlenebilir hale getirilir (Gonzales, R.C, & Woods, 2018).

Ayrıca ekran üzerinde görüntü yakalama, yani "ekran görüntüsü alma" işlemi de dijital görüntü yakalama yöntemlerinden biridir. Örneğin; bilgisayarlarda 'Print Screen' tuşu kullanılarak, anlık ekran görüntüsü hafızaya alınabilir. Bu yöntem, hem kullanıcı arayüzlerinin belgelenmesinde hem de sistem analizlerinde yaygın biçimde kullanılmaktadır (A. K. Jain, 1989). Görüntü yakalama, görüntü işleme sürecinin ilk ve en kritik adımı olarak kabul edilir; çünkü kalite ve çözünürlük düzeyi, sonraki işlem aşamalarının doğruluğunu doğrudan etkiler.

Görüntü yakalama sistemleri, DEHB'li çocukların el yazısı performansını dijital ortama aktararak yazı hızı, doğruluğu, okunabilirlik gibi parametreleri nesnel olarak ölçmeye olanak tanır. Bu sistemler, çocukların yazı sürecindeki motor kontrol ve dikkatle ilgili sorunları belirlemeye yardımcı olurken, bireye özgü müdahale stratejileri geliştirmede etkili olabilir (Shin et al., 2023).

Özellikle dijital kalem ve tablet gibi araçlarla elde edilen el yazısı verilerinden, hız, ivme, basınç gibi parametreler analiz edildiğinde, DEHB'li çocuklar ile kontrol grubu arasında istatistiksel olarak anlamlı farklılıklar tespit edilebilmektedir. Bu analizler, makine öğrenmesi modelleriyle birleştirilerek, %90'ın üzerinde doğruluk oranıyla DEHB tanısına katkıda bulunur (Shin et al., 2023).

Ayrıca, el yazısı ile not tutma alışkanlığı, dikkat süreçlerini uyarmakta ve ilgili beyin bölgelerindeki aktiviteyi destekleyerek DEHB'li çocukların dikkat düzeyini artırmaya yardımcı olabilir. Bu beklenen gelişme, özellikle eğitimsel ve klinik ortamda bireye yönelik destekleyici stratejilerin belirlenmesine olanak sağlar (V. W. Berninger et al., 2002).

3.1.3. Sayısal görüntü

Sayısal görüntü piksellerden oluşur ve her piksel belirli bir renk veya gri tonunu temsil eden sayısal değerlerle ifade edilir (A. K. Jain, 1989). Sayısal görüntüler genellikle bitmap (raster) ve vektör görüntüler olmak üzere iki ana gruba ayrılır: sayısal değerlerden oluşan ve bilgisayar ortamında görüntülenebilen görüntülerdir (Sonka, 2014).

Sayısal görüntü sayısal verilerle ifade edilen ve bilgisayar ortamında saklanabilen bir görsel temsil biçimidir. Yani bir görüntünün piksellerden oluşan dijital halidir. Görüntü işleme arasındaki fark ise sayısal görüntü ham veriyi temsil ederken görüntü işleme bu görüntü üzerinde gerçekleştirilen işlemleri kapsamaktadır (Gonzales, R.C, & Woods, 2018). DEHB’li çocukların el yazısı analizi ile veriler sayısal görüntü hali ile alınır ve Görüntü işleme teknikleri ile el yazısı analiz edilerek bireye özgü müdahale planları geliştirilebilir (Erdoğan, 2021).

3.1.4. Görüntü işleme adımları

Görüntü işleme, dijital bir görselin bilgisayar ortamında analiz edilmesi, filtrelenmesi ve iyileştirilerek anlamlı hale getirilmesini kapsayan çok aşamalı bir süreçtir. Bu süreçteki temel amaç, görüntü üzerinde çeşitli işlemler gerçekleştirerek yeni ve işlevsel bilgiler elde etmektir. Görsellerin gri tonlamaya dönüştürülmesi, istenmeyen parazitlerin (gürültülerin) temizlenmesi, keskinlik ve netlik ayarlarının yapılması gibi işlemler görüntü işleme sürecinin önemli adımlarıdır (Gonzales, R.C, & Woods, 2018).

Sayısallaştırılan bir görüntü, en küçük birim olan piksel düzeyinde değerlendirilir. Tüm görüntü işleme algoritmaları bu pikseller üzerinden çalışır. Piksel bazlı işlemler sayesinde kontrast iyileştirme, renk düzeltme, kenar tespiti gibi uygulamalar hayata geçirilir (Petrrou & Petrou, 2011).

Görüntü işleme süreci genel olarak üç temel aşamada gerçekleştirilir:

Görüntü Edinimi: Bu ilk aşamada dijital kameralar, tarayıcılar veya optik sensörler gibi donanımlar aracılığıyla görüntü verileri elde edilir. Bu görüntüler işlenmemiş, ham formda olduğu için daha sonraki işlemlerin temelini oluşturur. Görüntünün kalitesi, tüm sürecin verimliliğini doğrudan etkiler (Bovik, 2005).

Ön İşleme: Bu aşama, ham görüntünün kalite açısından iyileştirilmesini içerir. Parazit (gürültü) giderme, kontrast artırma, renk düzeltme gibi işlemler uygulanır. Örneğin; tıbbi görüntülerde MRI taramaları üzerinde yapılan ön işlemler sayesinde tümör gibi yapılar daha net şekilde görülebilir (Bovik, 2005). Görüntüler istenen boyutlara ölçeklenebilir ve gereksiz bölgeler kesilebilir.

Görüntü Analizi ile bu aşamada görüntüdeki önemli öznitelikler çıkarılır veya yorumlanır. Kullanılan algoritmalar sayesinde veriler sınıflandırılabilir, tanımlanabilir hale gelir. Örneğin; yüz tanıma uygulamalarında görüntüdeki yüz hatları belirlenir ve

veri tabanındaki örneklerle eşleştirilir. Benzer şekilde, DEHB’li çocukların el yazısı örnekleri üzerinden yapılan analizlerde, yazı karakteristikleri sağlıklı bireylerle karşılaştırılarak dikkat düzeyi ve motor kontrol becerileri değerlendirilebilir (Erdoğan, 2021).



Şekil 3.1. Görüntü İşleme Adımları.

3.1.5. Görüntü işleme türleri

Görüntü işleme, uygulama alanına ve ihtiyaçlara göre farklı tekniklere ayrılır. Her tür, kendi işlem mantığına ve amacına uygun yöntemler içerir. Kullanılan teknikler değiştikçe, elde edilmek istenen sonuçlar da farklılaşır. Aşağıda görüntü işleme sürecinde öne çıkan başlıca teknik türler özetlenmiştir:

3.1.5.1. Noktasal işlemler

Noktasal işlemlerde, her piksele ayrı ayrı müdahale edilir. Komşu piksellerin değeri göz önünde bulundurulmadan, yalnızca ilgili pikselin değeri baz alınır. Özellikle kontrast ayarları ve renk dönüşümleri gibi işlemler bu yöntemle uygulanır (Pratt, 2007).

3.1.5.2. Uzamsal alanda görüntü işleme

Uzamsal alanda görüntü işlemede ise her pikselin çevresindeki komşularıyla ilişkisi dikkate alınarak işlem yapılır. Görüntüye filtreler uygulamak, kenar belirleme veya keskinleştirme gibi işlemler uzamsal alanda gerçekleştirilir (Jähne, 2005).

3.1.5.3. Frekans alanında görüntü işleme

Frekans tabanlı işlemlerde görüntü işleme ise Fourier dönüşümü gibi yöntemlerle frekans bileşenlerine ayrılır. Daha sonra bu bileşenler üzerinden işlemler yapılır. Özellikle gürültü azaltma ve görüntü netleştirme gibi görevlerde tercih edilir (Bovik, 2010).

3.1.5.4. Renkli görüntü işleme

Renkli görüntüler, genellikle kırmızı, yeşil ve mavi (RGB) kanallarından oluşur. Bu yöntemle her kanal ayrı ayrı işlenir. Renk düzeltme, renk filtreleme ve renkli nesne tespiti gibi uygulamalar renkli görüntü işleme kapsamında değerlendirilir (Sonka, 2014).

3.1.5.5. İkili görüntü işleme

İkili görüntü işleme yönteminde ise yalnızca iki renk kullanılır: siyah ve beyaz. Genellikle nesne tespiti, belge tarama, kenar ayrımı gibi temel sınıflandırma işlemlerinde kullanılır. Özellikle metin veya şekil ayrıştırmada etkilidir (Theodoridis, 2008).

3.1.5.6. Morfolojik görüntü işleme

Morfolojik işlemler, görüntüdeki yapısal öğeleri analiz etmek için kullanılır. Genişletme (dilation), aşındırma (erosion), açma ve kapama gibi işlemlerle görüntünün şekil özellikleri iyileştirilir. Nesne sınırlarının belirginleştirilmesinde etkilidir (Serra, 1988).

3.1.5.7. Geometrik görüntü işleme

Geometrik görüntü işlemede ise görüntünün şekil ve konum özelliklerini değiştirir. Döndürme, yeniden boyutlandırma, çarpıtma veya hizalama işlemleri bu kapsamdadır. Görüntüleri standart hale getirmek için yaygın olarak kullanılır (Pitas, 2000).

3.1.5.8. Görüntü geliştirme

Görüntü geliştirme, görsel kalitenin artırılmasına yönelik yapılan işlemleri kapsar. Renk dengeleme, kontrast artırma ve netlik iyileştirme gibi işlemler bu başlık altında yer alır (R. Jain et al., 1995).

3.1.5.9. Görüntü restorasyonu

Restorasyon işlemleri, bozulmuş görüntüleri onarmayı amaçlar. Bulanıklık giderme, eksik bilgi tamamlama ve parazitleri temizleme bu yöntemle gerçekleştirilir. Özellikle eski veya düşük çözünürlüklü görüntüler için kullanılır (Andrews & Hunt, 1977).

3.1.5.10. Görüntü bölgeleme

Görüntü bölgeleme yönteminde ise, görüntünün farklı bölgelere ayrılarak her bölgenin ayrı bir nesneye ya da arka plana karşılık gelmesini sağlar. Nesne tespiti, sınıflandırma ve analiz işlemleri için temel adımdır (Marr & Hildreth, 1980).

3.1.5.11. Görüntü tanıma

Görüntü tanıma işlemleri, görüntüdeki nesneleri belirleme ve sınıflandırma amacını taşır. Otomatik yüz tanıma, nesne etiketleme, araç tespiti gibi uygulamalarda kullanılır. Güvenlik, sağlık ve yapay zekâ tabanlı sistemlerde yaygın bir tekniktir (Fukunaga, 1990).

3.1.6. Görüntü işlemenin temelleri

Görüntü işleme alanında, yapay sinir ağları, genetik algoritmalar ve bulanık mantık gibi yapay zekâ temelli sistemler sıkça kullanılan yöntemler arasında yer almaktadır. Ancak bu yöntemlerin kullanıldığı süreçler genel olarak "görüntü işleme" başlığı altında incelenmektedir (A. K. Jain, 1989).

Görüntü işleme problemlerine yaklaşırken tercih edilecek yöntemlerin yanı sıra kullanılan platform, yazılım araçları ve analiz edilecek görüntülerin türü büyük önem taşımaktadır. Bu bileşenlerin uygun şekilde belirlenmesi, uygulamanın başarısını doğrudan etkilemektedir.

Farklı teknik ve yöntemlerin bir arada kullanılması ise yalnızca sonucun doğruluğunu değil, aynı zamanda sistemin esnekliğini, işlem verimliliğini ve uygulama sürecinin gerçekleştirilebilirliğini de olumlu yönde etkiler (Szeliski, 2010).

3.1.7. Görüntü işleme uygulama alanları

Görüntü işleme, dijital ortamda elde edilen görsellerin analizi, iyileştirilmesi ve anlamlandırılması amacıyla uygulanan sistematik bir yaklaşımdır. Gelişen donanım altyapısı ve algoritmik ilerlemelerle birlikte, görüntü işleme teknikleri yalnızca mühendislik disiplinleriyle sınırlı kalmayıp sağlık, tarım, ulaşım, güvenlik, enerji ve eğlence gibi farklı sektörlerin dijital dönüşümünde de merkezi bir rol üstlenmiştir (Gonzales, R.C, & Woods, 2018).

Özellikle tıbbi görüntüleme alanında, manyetik rezonans (MRI) ve bilgisayarlı tomografi (CT) gibi teknolojiler sayesinde hastalıkların erken teşhisi ve tedavi planlaması daha sistematik ve güvenilir bir hâle gelmiştir. Bu görüntüleme yöntemleri,

vücudun iç yapılarının detaylı bir şekilde incelenmesine olanak tanıyarak, tümörlerden damar tıkanıklıklarına, iç organ hasarlarından nörolojik bozukluklara kadar pek çok hastalığın belirlenmesini kolaylaştırmaktadır. Bu teknolojiler aynı zamanda cerrahi müdahalelerde görüntü tabanlı rehberlik sağlayarak hekimin operasyonel başarısını arttırmaktadır (Sözen & Yücel, 2010).

Güvenlik sektörü, görüntü işlemeyi başta yüz tanıma ve hareket algılama olmak üzere çok çeşitli amaçlarla entegre etmiştir. Gerçek zamanlı analiz sistemleri sayesinde, izleme kameralarından gelen veriler işlenerek potansiyel tehditler otomatik olarak tespit edilebilmekte; biyometrik sistemler yardımıyla havaalanları, kamu binaları ve sınır geçiş noktalarında kimlik doğrulama süreçleri hızlı ve etkili bir biçimde gerçekleştirilebilmektedir (Azuma, 1997).

Üretim ve sanayi alanlarında görüntü işleme, kalite kontrol ve hata tespiti gibi süreçlerin otomasyonu için vazgeçilmez bir araç hâline gelmiştir. Görüntü tabanlı denetim sistemleri sayesinde üretim bandındaki her bir ürün, insan müdahalesine gerek kalmaksızın yüksek hassasiyetle değerlendirilebilmekte ve üretim verimliliği optimize edilmektedir (Szeliski, 2010).

Eğlence sektöründe ise görüntü işleme; görsel efektler, sanal karakter üretimi, artırılmış gerçeklik (AR) ve sanal gerçeklik (VR) gibi teknolojilerin geliştirilmesinde temel bileşenlerden biridir. Özellikle dijital oyun tasarımı ve film prodüksiyonunda, kullanıcı deneyimini artıran gerçekçi sahnelerin oluşturulmasında aktif bir rol oynamaktadır (Sonka, 2014).

Tarımda görüntü işleme teknolojisi, dijital tarım uygulamalarının temelini oluşturarak ürün gelişimi, hastalık teşhisi, sulama ihtiyacı analizi ve verim tahmini gibi birçok süreçte etkin biçimde kullanılmaktadır. Bu sistemler, nesnelerin interneti (IoT) ile entegre edildiğinde, daha akıllı ve sürdürülebilir tarım uygulamalarının önünü açmaktadır (Kamilaris & Prenafeta-Boldú, 2018).

Uydu görüntüleme ise özellikle coğrafi bilgi sistemleri (GIS) kapsamında; arazi kullanımı, çevresel değişim izleme ve doğal afetlerin erken uyarısı gibi konularda geniş ölçekte veri analizi sunar. Yüksek çözünürlüklü uydu görüntüleri, afet yönetimi ve şehir planlaması gibi kritik karar süreçlerini destekleyen stratejik bir araçtır (Richards & Jia, 2006).

Tüm bu uygulamaların yanında, görüntü işlemenin yaygınlaşmasını sınırlayan bazı teknik ve operasyonel zorluklar da mevcuttur. Özellikle gelişmiş donanım ihtiyacı, yazılım lisans maliyetleri ve yüksek işlem gücü gereksinimi, bu teknolojinin küçük ve orta ölçekli işletmeler tarafından benimsenmesini zorlaştırmaktadır. Ayrıca, görsel verilerin gizliliği ve güvenliği, yetkisiz erişim ve veri manipülasyonu gibi tehditler karşısında önemli bir sorun alanı oluşturmaktadır. Bu nedenle, güvenli veri yönetimi ve etik kurallara uygunluk büyük önem taşımaktadır.

Sonuç olarak, görüntü işleme teknolojisi, sayısız sektörde otomasyon, doğruluk ve verimlilik artışı sağlamaktadır. Ancak bu teknolojinin sürdürülebilir ve güvenli şekilde uygulanabilmesi için altyapısal yatırımların yanı sıra, uzmanlık ve disiplinler arası iş birlikleri de zorunlu hâle gelmiştir.

3.2. Yolo (You Only Look Once)

Görüntü işleme ve bilgisayarlarla görme, günümüz dijital çağında görsel verilerin analizine yönelik artan ihtiyaçlarla birlikte hızla gelişen bilimsel disiplinler arasında yer almaktadır. Teknolojik altyapının güçlenmesi ve yapay zeka odaklı algoritmaların gelişimi, bu alandaki akademik çalışmalara son yıllarda önemli bir dinamizm kazandırdı (Lecun et al., 2015). İnsan algısının yetersiz kaldığı veya yüksek doğruluk gerektiren durumlarda, bilgisayar destekli sistemler sayesinde daha hızlı, güvenilir ve kararlı sonuçlara ulaşmak mümkün hale geldi.

Teknolojik dönüşümün en önemli çıktılarından bir olan Nesne Tespiti (Object Detection), görüntü üzerinde yer alan nesneleri hem konumlarının hem de sınıflarının otomatik olarak belirlenmesini sağlayan bir yöntemdir. Nesne Tespiti, otonom araç sistemlerinden güvenlik kameralarına, tıbbi görüntü analizlerinden üretim hatlarına kadar pek çok alanda geniş uygulama yelpazesine sahiptir.

Derin öğrenme tabanlı nesne tespit algoritmaları ihtiyaca cevap vermek üzere öne çıktı; özellikle You Only Look Once (YOLO) algoritması bu alandaki başarısıyla dikkat çekmiştir (Redmon et al., 2016). YOLO, görüntüye tek bir geçişte işleyerek nesne tespitini gerçekleştiren bir yapıya sahiptir ve bu özelliği sayesinde hem yüksek hız hem de kabul edilebilir düzeyde doğruluk saptamaktadır. YOLO algoritmasının sürümleri zaman içinde gelişerek daha hassas, daha düşük gecikmeli ve daha yüksek performanslı hale gelmiştir (Bochkovskiy et al., 2020). Yolov11, önceki sürümlere kıyasla daha iyi doğruluk oranları, daha düşük işlem süresi ve genel olarak kararlı bir

performans sunmaktadır. Modelin mimarisinde yapılan iyileştirmeler sayesinde, daha küçük nesneleri algılamada daha başarılı sonuçlar elde edilmekte olup Yolov11'in bu güçlü yapısı, görüntü işleme tabanlı özel uygulamalarda tercih edilmesini mümkün kılmaktadır.

İlkokul seviyesindeki çocuklara (8-11 yaş) ait el yazısı örneklerinden DEHB (Dikkat Eksiliği ve Hiperaktivite Bozukluğu) tanısı konulmasına yönelik bir model geliştirildi. Geliştirilen sistem, Yolov11 nesne tespiti algoritması kullanılarak çocukların el yazılarındaki dikkat dağınıklığı, hizalama bozuklukları, yapısal düzensizlikler ve harf formu gibi özellikleri analiz etmektedir. Elde edilen sınıflandırma çıktıları, ROC (Receiver Operating Characteristic) analizi ile değerlendirilerek modelin tanısal başarı düzeyi ölçülmüştür. Bu yaklaşım, yapay zeka destekli görüntü işleme tekniklerinin, davranışsal ve motor göstergelerle dayalı erken tanı süreçlerinde nasıl etkili bir şekilde kullanılabileceğini ortaya koymaktadır.

3.2.1. Yolo algoritmasının temelleri

YOLO (You Only Look Once) algoritması, görüntüde yer alan nesnelerin gerçek zamanlı olarak tespit edilmesini amaçlayan, derin öğrenme temelli bir nesne algılama yöntemidir. Geleneksel nesne tespiti yaklaşımlarından farklı olarak YOLO, bir görüntüye tek bir geçişte (Single Pass) işleyerek tüm sahneyi bütünsel bir bakış açısıyla analiz eder. Bu yaklaşım, hem işlem süresini azaltmakta hem de yüksek hızlı tahminlerde bulunmaya olanak sağlamaktadır. YOLO mimarisi, giriş görüntüsünü sabit boyutlu hücrelere bölerek, her bir hücre içerisinde nesne bulunup bulunmadığını tahmin eder (Redmon et al., 2016).

YOLO algoritmasının temel özelliği, tüm nesne tespit sürecini tek bir evrişimli sinir ağı (CNN) ile gerçekleştirmesidir. Bu yapı sayesinde sınırlayıcı kutuların (bounding boxes) koordinatları, her bir nesneye ait güven skorları (confidence scores) ve sınıf olasılıkları eş zamanlı olarak tahmin edilebilmektedir. YOLO mimarisinin evrimsel gelişimi sonucunda ortaya çıkan YOLOv11 sürümü, derin öğrenme teknolojilerindeki yenilikleri bütünleşmiş olan daha derin ve kompleks bir yapıya sahiptir. Bu sürümde, özellik çıkarımı daha etkin bir biçimde gerçekleştirilmekte, gelişmiş tahminleme katmanları aracılığıyla daha doğru tespit sonuçları elde edilmektedir. Bu da özellikle gerçek zamanlı nesne algılama gerektiren uygulamalarda önemli bir avantaj sunmaktadır (Bochkovskiy et al., 2020).

YOLOv11, önceki sürümlerde karşılaşılan bazı yapısal ve performans kaynaklı sınırlamaları önemli ölçüde gidermektedir. Özellikle küçük boyutlu nesnelerin algılanmasında gösterdiği gelişmiş başarı oranı, farklı çözünürlüklerde hem eğitim hem de çıkarım yapabilme yeteneği ile desteklenmiştir. Bunun yanında, dikkat mekanizması (attention mechanism) gibi modern derin öğrenme tekniklerinin mimariye bütünleşmesi, modelin sınırlı bilgi içeren bölgelerde dahi etkili çıkarımlar yapabilmesini mümkün kılmaktadır (Lecun et al., 2015).

YOLO algoritması, giriş görüntüsünü $S \times S$ boyutunda hücrelere ayırmakta ve her hücre için B adet sınırlayıcı kutu (bounding box), her kutu için konum bilgileri: (x, y, w, h) , her kutuya ait bir güven skoru (confidence score) ve tüm olası sınıflar için tahmin edilen olasılık değerleri (class probabilities) çıktıları üretmektedir.

YOLOv11, yalnızca yüksek hızlı nesne tespiti sağlamakla kalmayıp aynı zamanda yüksek doğruluk oranlarına da ulaşarak hem akademik çalışmalarda hem de endüstriyel uygulamalarda güçlü bir çözüm olarak öne çıkmaktadır (W. Liu et al., 2016).

3.2.2. Yolo algoritmasının tarihsel gelişimi ve sürümleri

YOLO algoritması, ilk olarak 2016 yılında Joseph Redmon ve arkadaşları tarafından önerilen "You Only Look Once: Unified, Real-Time Object Detection" adlı çalışma ile literatüre girdi. Bu algoritma, nesne algılama problemini tek bir sinir ağı yapısı içinde çözerek, diğer geleneksel yöntemlerin aksine görüntüyü bir bütün olarak değerlendirerek nesne tespiti yapmaktadır. İlk sürümden itibaren YOLO algoritması, hız, doğruluk, verimlilik ve genel başarımlar açısından birçok sürümle güncellenmiştir (Redmon et al., 2016).

Tablo 3.1. YOLO Algoritmalarının Sürümlerine Göre Karşılaştırılması.


Sürüm	Yıl	mAP@0.5 (Yaklaşık)	FPS	Öne Çıkan Özellikler
YOLOv1	2016	%63.4 (VOC 2007)	45	İlk versiyon, tek geçişte hızlı tespit
YOLOv2	2017	%78.6 (VOC 2007)	40	Anchor box, BatchNorm, yüksek çözünürlükte eğitim
YOLOv3	2018	%33 (COCO@[.5:.95])	30–45	Multi-scale prediction, Darknet-53
YOLOv4	2020	%43.5 (COCO)	~62	CSPDarknet, Mish, SPP, PANet
YOLOv5	2020	%50+ (v5x - COCO)	30–60	PyTorch tabanlı, kolay eğitim, versiyon çeşitliliği
YOLOv6	2022	%52+ (COCO)	60+	Endüstriyel kullanım için optimize, düşük gecikme
YOLOv7	2022	%56.8 (COCO)	>160 (tiny)	E-ELAN yapısı, eğitim optimizasyonları
YOLOv8	2023	%53–56 (COCO)	60+	Segmentasyon, pose, ONNX ve EdgeAI destekli
YOLOv11	2025*	%58+ (tahmini)	50–70	Transformer bileşeni, attention, küçük nesnelerde yüksek başarı

3.2.3. YOLOv11 mimarsi

Yolov11, önceki sürümlerden farklı olarak hem CNN hem de Transformer bloklarını bütünleşmiş şekilde kullanan hibrit bir mimariye sahiptir. Bu yapı, hem yerel özellik çıkarımı hem de bağlamsal bilgi modellemesi açısından önemli avantajlar sunar (Z. Liu et al., 2021).

DEHB ile ilişkili el yazısı desenlerini otomatik olarak tespit etmek ve sınıflandırmak için YOLO tabanlı bir derin öğrenme modeli geliştirilmiş ve eğitilmiştir. Mimari, YOLO11 modeli üzerine inşa edilmiş ve özel modifikasyonlar yoluyla el yazısı alanına uyarlanmıştır. Girdi görüntüleri, her bir tablo hücresinin sınırlayıcı kutuları, güven puanlarını ve sınıf etiketlerini (DEHB veya sağlıklı) öngördüğü tablolara (20×20) bölünmüştür. Modelde kullanılan YOLO'nun yapısı Şekil 3.2' de verilmiştir. Bu çalışmada kullanılan derin öğrenme modeli, üç ana bileşen halinde yapılandırılmış özelleştirilmiş bir YOLO tarzı mimariye dayanmaktadır: Omurga, Boyun ve Baş. Bu mimari, DEHB tespitinin ikili sınıflandırma görevi için el yazısı görüntü girdilerini verimli bir şekilde işlemek üzere optimize edilmiştir. Omurga, giriş el yazısı görüntülerinden zengin görsel özelliklerin çıkarılmasından sorumludur. Bu aşama, veri kümesini, temel uzamsal ve anlamsal bilgileri korurken görüntüyü aşamalı olarak küçülten bir dizi konvolüsyonel katman ile besleyerek başlar. Konvolüsyon blokları, Çapraz Aşama Kısmi (CSP) modülünün bir çeşidi olan C3K2 olarak etiketlenen gelişmiş özellik çıkarma modülleri ile iç içe geçmiştir.

C3K2 modülü, nörogelişimsel farklılıkların göstergesi olabilecek el yazısındaki karmaşık vuruş seviyesi varyasyonlarını daha iyi yakalamak için gruplanmış konvolüsyon ve çekirdek boyutu ayarlamalarını entegre eder. Bu katmanlar, model karmaşıklığı ve temsil gücü arasında bir denge kurulmasına yardımcı olur. Omurga'nın sonunda, düşük, orta ve yüksek görüntü seviyeli soyutlamaları kodlayan çoklu özellik haritalarına dönüştürülür. Neck bileşeni, özellik çıkarma ve nihai algılama arasında bir köprü görevi görür. Çok ölçekli özellik toplamayı kolaylaştırır ve farklı çözünürlükler arasında özellik yayılımını geliştirir. Yapı C3K2 ve Concat içerir. Head modülü, birleştirilmiş özellikleri yorumlayarak ve sınıf olasılıkları çıktısı vererek nihai tahmini gerçekleştirir. Bu durumda, modelin ikili bir çıktısı vardır: bir düğüm DEHB ile ilişkili el yazısı desenlerini tespit etmeye adanmıştır ve diğeri tipik (DEHB olmayan) el yazısını temsil eder.



Şekil 3.2. Modelde Kullanılan YOLO Mimarisi.

Kontur eğriliği, basınç değişimleri ve karakter içi tutarsızlıklar gibi el yazısına özgü özellikleri daha iyi yakalamak için temel YOLO yapısına ek konvolüsyonel katmanlar entegre edilmiştir. Eğitim sırasında, sınırlayıcı kutunun lokalizasyon hatası, güven puanı kaybı ve sınıflandırma kaybını içeren bileşik bir kayıp fonksiyonu SGD veya Adam optimizier kullanılarak en aza indirilmiştir. Hiperparametreler, 0,001'lik bir başlangıç öğrenme oranı (zamanla azaltılmış), 16'lık bir grup boyutu ve 100 epoka kadar eğitim ile ampirik olarak belirlenmiş ve aşırı uyumu azaltmak için erken durdurma kullanılmıştır. Veri seti eğitim ve doğrulama setlerine bölünmüş ve model performansı doğruluk, kesinlik, geri çağırma ve F1 puanı gibi ölçütler kullanılarak izlenmiştir. ROC eğrileri ve karışıklık matrisleri de dahil olmak üzere ek analizler, modelin sınıflandırma yetenekleri hakkında ayrıntılı bilgi sağlamıştır. Sonuçların genelleştirilebilirliğini sağlamak için 5 kat çapraz doğrulama yapılmış ve tüm katlarda ortalama ölçümler raporlanmıştır.

Ayrıca, farklı veri artırma tekniklerinin, öğrenme hızı programlarının ve optimizasyon stratejilerinin etkisini değerlendirmek için karşılaştırmalı deneyler yapılmıştır. Bu değerlendirmeler, el yazısı stilleri arasında sağlamlığı korurken yüksek sınıflandırma doğruluğu elde etmek için en uygun yapılandırmanın belirlenmesine yardımcı olmuştur. Genel olarak, önerilen YOLO tabanlı mimari, DEHB'ye özgü el yazısı özelliklerini ayırt etmede umut verici bir performans göstermiş ve gelişimsel olmayan, görüntü tabanlı teşhis destek sistemleri için derin öğrenme yaklaşımlarının potansiyelini vurgulamıştır.

3.2.3.1. Backbone yapısı (girdinin bölünmesi)

YOLOv11, EfficientFormer benzeri bir yapı üzerine kurulmuştur. YOLOv11'in backbone bileşeni, giriş görüntüsünden hiyerarşik düzeyde öznitelik çıkarımı yapabilmek üzere tasarlanmış derin bir evrişimli sinir ağıdır (Wang et al., 2022). İlk olarak ardışık 3×3 konvolüsyon katmanları, görüntünün kenar, doku ve temel geometrik yapısını yakalayan düşük seviyeli öznitelikleri üretir. Daha sonra, kanal sayısını düşürerek hesaplama yükünü azaltan ve bilgi akışını zenginleştiren CSP (Cross Stage Partial) modülleri devreye girer; bu modüller, “bottleneck” konvolüsyonları ve residual bağlantıları sayesinde derinliği artırırken gradyan akışını iyileştirir. Farklı derinlik seviyelerinde oluşturulan öznitelik haritaları, küçükten büyüğe nesne algısını desteklemek amacıyla çok ölçekli bir yapı sergiler; bu haritalar daha sonra “neck” bileşeni tarafından birleştirilir. Backbone'un sonunda yer alan Spatial Pyramid Pooling (SPP) modülü ise çeşitli havuzlama boyutları uygulayarak sabit boyutlu, çok ölçekli öznitelik temsilleri üretir ve modelin değişken çözünürlüklü sahneler ve farklı boyutlardaki nesnelere karşı dayanıklılığını artırır (Wang et al., 2022). Tüm konvolüsyon katmanlarında Batch Normalization ve ReLU/SiLU aktivasyon fonksiyonlarının kullanımı, eğitim kararlılığını ve öğrenme hızını daha da iyileştirmektedir. Mimari yapı, bileşenlerin uyumlu çalışması YOLOv11'in hem gerçek zamanlı hız hem de yüksek doğruluk gerektiren nesne tespiti uygulamalarında üstün performans göstermesine imkân tanır.

Giriş görüntüsü, belirlenen grid boyutuna göre (örneğin, 20×20 hücre) bölünmüş; her hücre, belirli bir yazı parçasının varlığına dair tahminlerde bulunacak şekilde tasarlanmıştır (Wang et al., 2023).

3.2.3.2. Neck yapısı (öznitelik haritası çıkışı)

YOLOv11'in “neck” bileşeni, backbone'dan elde edilen çok ölçekli öznitelik haritalarını bir araya getirerek hem yerel hem de küresel bağlam bilgisini zenginleştirmeyi amaçlayan ara katmanlar dizisidir. Bu aşamada sıklıkla Path Aggregation Network (PANet) veya Bidirectional Feature Pyramid Network (BiFPN) benzeri yapılar kullanılır (S. Liu et al., 2018); her iki yaklaşım da farklı çözünürlükteki öznitelikleri yukarı ve aşağı yönlü örnekleme (upsampling/downsampling) işlemleriyle birleştirir. YOLOv11'de neck, önce yüksek seviyeli semantik bilgiyi içeren düşük çözünürlüklü haritaları yukarı örnekleyerek orta ve yüksek çözünürlüklü haritalarla birleştirir; ardından bu birleşik öznitelikler tekrar aşağı örneklenerek daha

derin katmanlarla kaynaştırılır (Tan et al., 2020). Bu çift yönlü akış, hem küçük nesnelerin detaylı tanınmasını sağlayacak ince özniteliklerin hem de büyük nesneler için gerekli küresel yapı bilgisinin ağırlıklı öğrenilmesine imkân tanır. Ayrıca, concatenation ve 1×1 konvolüsyon katmanlarıyla kanal boyutları düzenlenerek bilgi kaybı minimize edilir ve modelin genelleme kabiliyeti artırılır (Bochkovskiy et al., 2020). Sonuç olarak, YOLOv11'in neck yapısı, farklı ölçeklerdeki öznitelikleri etkin bir şekilde bütünleştirerek hem tespit doğruluğunu yükseltir hem de gerçek zamanlı işleme gereksinimlerini karşılayacak şekilde hesaplama verimliliğini korur.

Neck yapısı, her hücrede yazının varlığına dair güven skoru, sınıf tahmini (DEHB veya sağlıklı) ve bounding box koordinatlarını aynı anda belirleyecek biçimde kurgulanmıştır. Böylece, hem yazının yerini hem de sınıfı tespit edilmiştir.

3.2.3.3. Head yapısı (özelleştirilmiş katmanlar)

YOLOv11'in "head" bileşeni, çok ölçekli öznitelik haritalarından nesne konumu ve sınıf bilgisi üretmek üzere özel olarak tasarlanmış çıkış bloklarından oluşur. Her bir ölçek için ayrılmış başlıkta, önceki "neck" aşamasından gelen öznitelik haritaları, birbirini izleyen 1×1 ve 3×3 konvolüsyon katmanları aracılığıyla hem boyut hem de kanal sayısı açısından ön işleme tabi tutulur (Redmon & Farhadi, 2018). Ardından, modelin anchor-free tasarımına uygun şekilde, decoupled head mimarisi benimsenir: Nesne varlığı (objectness) ve sınıf tahmini (classification) için ayrı dallar ile konum ve boyut regresyonu (bounding box regression) için ayrılmış dallar bulunur (Ge et al., 2021). Nesne varlığı ve sınıf dallarında Sigmoid aktivasyon fonksiyonu kullanılarak her hücre için gerçek nesne olasılıkları ve sınıf olasılıkları elde edilir; regresyon dallarında ise doğrusal aktivasyon ile kutu merkez koordinatları (b_x, b_y, b_x, b_y) ve boyut (b_w, b_h, b_w, b_h) öznitelikleri tahmin edilir (Tian et al., 2019). Bu ayrıştırılmış yapı, sınıflandırma ve regresyon görevlerinin kendi özgü kayıp fonksiyonlarıyla (Cross-Entropy ve MSE) bağımsız olarak optimize edilmesine imkân tanır. Sonuç olarak, YOLOv11 head'i, hem yüksek doğruluk için detaylı sınıflandırma/regresyon yetenekleri hem de gerçek zamanlı uygulamalar için düşük gecikmeli işlem gereksinimlerini dengeler.

Temel YOLO mimarisi üzerine, el yazısına özgü ince detayları yakalamak için ek konvolüsyonel katmanlar eklenmiştir. Bu katmanlar, yazının kıvrım, basınç ve harf içi varyasyonlarını daha iyi öğrenebilmek amacıyla tasarlanmıştır.

3.2.4. YOLOv11 performans analizi ve ROC eğrisi

Algılama sistemlerinin doğruluk ve başarımı çeşitli metriklerle değerlendirilir. ROC (Receiver Operating Characteristic) eğrisi, bir sınıflandırıcının performansını görsel olarak ortaya koyan önemli bir araçtır. Bu bölümde, YOLOv11'in performansı ROC analizi bağlamında değerlendirilmektedir.

3.2.4.1. ROC eğrisinin temel kavramları

Receiver Operating Characteristic (ROC) eğrisi, bir sınıflandırma modelinin olasılık eşik değerleri değişikçe gösterdiği performansı karşılaştırmak için kullanılan temel bir görselleştirme tekniğidir (Fawcett, 2006). ROC eğrisinin dikey eksenini True Positive Rate (TPR; duyarlılık, sensitivity), yatay eksenini False Positive Rate (FPR; yanlış pozitif oranı) oluşturur.

ROC eğrisinin amacı, yüksek bir TPR (doğru pozitif oranı) ve düşük bir FPR (yanlış pozitif oranı) elde etmektir. ROC analizi klasik olarak ikili sınıflandırma problemlerinde kullanılsa da, nesne algılama uygulamalarına da uyarlanabilir. Bu tür uygulamalarda her tespit edilen nesne için şu dört durum tanımlanır:

True Positive (TP): Gerçekten pozitif olan ve model tarafından doğru sınıfa atanarak doğru konumlandırılan nesnelerin sayısını ifade eder. Yani, modelin hem varlığını hem de sınıfını hatasız tespit ettiği bileşenler TP olarak kabul edilir (Padilla et al., 2021).

False Positive (FP): Gerçekte nesne içermeyen bir bölgenin model tarafından yanlışlıkla nesne barındırdığı şeklinde sınıflandırıldığı hatalı tahminlerin toplam sayısını ifade eder (Padilla et al., 2021).

False Negative (FN): Modelin, gerçekte var olan nesneleri algılayamayarak yanlış bir şekilde negatif sınıfa atadığı örneklerin toplam sayısını ifade eder (Padilla et al., 2021).

True Negative (TN): Modelin, nesne içermeyen bir bölgeyi doğru biçimde negatif olarak sınıflandırdığı örneklerin sayısını ifade eder. Ancak nesne algılama problemlerinde, odak genellikle nesne tespiti üzerine olduğundan, TN değeri diğer ölçütlere kıyasla daha az öneme sahiptir (Padilla et al., 2021).

Bu değerler kullanılarak denklem (3.1) ve (3.2) deki oranlar oranlar elde edilir:

$$FPR = FP / (FP + TN) \quad (3.1)$$

$$TPR = TP / (TP + FN) \quad (3.2)$$

ROC eğrisinin altında kalan alan, yani AUC (Area Under the Curve) metriği, sınıflandırma modelinin genel başarı düzeyini özetleyen bütünsel bir göstergedir. AUC değeri teorik olarak 0 ile 1 arasında değişmekte olup, modelin ayırt edici gücünü nicel bir biçimde ifade eder. AUC değerinin 1'e yaklaşması, modelin pozitif ve negatif sınıfları yüksek doğrulukla ayırt edebildiğini ve dolayısıyla güçlü bir sınıflandırma performansına sahip olduğunu gösterir. Buna karşın, AUC'nin 0.5 civarında olması, modelin kararlarının rastgele tahmin düzeyine yakın olduğunu ve güvenilir bir ayırım gücü sunmadığını ortaya koyar (Fawcett, 2006).

YOLOv11'de her tespit için confidence eşiği (θ) üzerinde durulur: Model, bir bounding box'un confidence değeri $\geq \theta$ olduğunda “pozitif” karar verir. Farklı θ değerleri için TP, FP, FN ve TN şu şekilde hesaplanır:

1. TP: Gerçekte nesne içeren bir bölgede confidence $\geq \theta$.
2. FP: Nesne olmayan bir bölgede confidence $\geq \theta$.
3. FN: Gerçekte nesne içeren bir bölgede confidence $< \theta$.
4. TN: Nesne olmayan bölgede confidence $< \theta$.

Her θ değeri için TPR ve FPR hesaplanır, ROC eğrisi çizilir ve AUC skoru elde edilir. YOLOv11'in COCO ve Pascal VOC gibi zorlu veri setlerinde AUC değerleri genellikle 0.95'in üzerinde rapor edilmiştir; bu durum modelin yüksek duyarlılık ve düşük yanlış alarm oranı sunduğunu göstermektedir (Fawcett, 2006).

ROC eğrisi, uygulamanın gerektirdiği duyarlılık-özellik dengesine göre ideal eşik değerinin belirlenmesine yardımcı olur. Örneğin tıbbi teşhis veya güvenlik uygulamalarında yüksek duyarlılık (yüksek TPR) öncelikli iken, endüstriyel kalite kontrol sistemlerinde yanlış alarmların (FPR) minimize edilmesi tercih edilebilir. Bu sayede ROC analizi, YOLOv11'in hem gerçek zamanlı hız hem de istenen doğruluk kriterlerini karşılayacak biçimde ayarlanmasına imkân tanır (Powers, 2011).

3.2.4.2. Roc eğrisinin YOLOv11 üzerindeki etkileri

YOLOv11'in ROC analizini yapmak için aşağıdaki adımlar izlenebilir:

Modelin Test Edilmesi: YOLOv11 modelini bir test seti üzerinde çalıştırarak, her sınıf için algılanan nesneleri ve gerçek etiketleri karşılaştırır. Tespit edilen nesnelerin her biri için doğru pozitif, yanlış pozitif ve yanlış negatif sayıları hesaplanır (Redmon & Farhadi, 2018).

Farklı Eşik Değerleriyle Modelin Testi: ROC eğrisini oluşturmak için modelin farklı güven eşiği (confidence threshold) değerleri ile test edilmesi gerekir. Örneğin, modelin algıladığı nesnenin "kesinlikle nesne" olduğu kabul edilen güven değerini ayarlayarak (örneğin %50, %70, %90) farklı eşiklerde doğruluk oranları hesaplanabilir (Fawcett, 2006).

TPR ve FPR Hesaplama: Farklı eşik değerlerinde TPR ve FPR hesaplanır ve bu değerler ROC eğrisini oluşturmak için grafiğe dökülür. Her eşik değeri için TPR ve FPR hesaplanır ve ROC eğrisine eklenir (Hanley & McNeil, 1982).

AUC (Area Under the Curve) Hesaplaması: ROC eğrisinin altındaki alan (AUC), modelin genel performansını özetleyen bir değerdir. AUC değeri 0 ile 1 arasında değişir. AUC'nin 1'e yakın olması, modelin mükemmel sınıflandırma başarısı gösterdiğini gösterirken, 0.5'e yakın olması modelin rastgele tahminler yaptığını gösterir (Hanley & McNeil, 1982).


3.2.4.3. YOLOv11 ve diğer sürümler ile karşılaştırmalı ROC performansı

YOLOv11, özellikle küçük nesne tespitinde daha yüksek duyarlılık göstermektedir. Gelişmiş dikkat mekanizmaları ve anchor-free yapısı, ROC eğrisi altında kalan alanı artırmakta ve daha güvenilir bir algılama sağlamaktadır.

Tablo 3.2. YOLOv11'in Diğer Sürümlerle Karşılaştırmalı ROC Performansı.

Sürüm	AUC (ROC Eğrisi Altında Kalan Alan)	Doğruluk (%)	FPS (kare/saniye)
YOLOv5	0.91	89.7	120
YOLOv7	0.94	91.3	105
YOLOv8	0.945	92.0	98
YOLOv11	0.965	94.5	110

Şekil 3.3'de, YOLO algoritmasının farklı sürümleri olan YOLOv5m, YOLOv7, YOLOv8m ve YOLOv11m modelleri; sınıflandırma doğruluğu ve nesne tespiti başarımı açısından karşılaştırılmaktadır. Bu karşılaştırma, iki temel metrik üzerinden yapılmıştır: AUC (Area Under the Curve) ve mAP@0.5 (Mean Average Precision). AUC değeri, sınıflandırma performansını ROC eğrisi altında kalan alanla değerlendirirken; mAP@0.5 ise bir nesnenin belirli bir eşik doğrulukta ne kadar iyi tespit edildiğini gösterir. Grafik, bu iki metriği aynı eksenle, farklı renkli çizgilerle (AUC: mavi, mAP: kırmızı) ifade etmektedir.



Şekil 3.3. YOLOv11 ve ROC Karşılaştırması.

Sol dikey eksen (y-ekseni), modellerin AUC değerlerini 0.90 ile 0.96 aralığında göstermektedir. Bu değerlere bakıldığında, YOLOv5m modelinin yaklaşık 0.91 AUC ile en düşük değeri aldığı, YOLOv11m'nin ise yaklaşık 0.955 AUC ile en yüksek ayırt ediciliği sağladığı görülmektedir. Bu durum, YOLOv11m modelinin farklı sınıflar arasındaki ayrımı çok daha başarılı şekilde gerçekleştirdiğini ortaya koymaktadır (Fawcett, 2006).

Sağ dikey ekseninde ise modellerin mAP@0.5 değerleri 48 ile 53 arasında konumlandırılmıştır. Bu metrik açısından da YOLOv11m yaklaşık 52.3 değeriyle en yüksek performansı sergilemektedir. YOLOv7, yaklaşık 51.5 mAP değeriyle dikkat çekerken, YOLOv8m'de bu değerin biraz düştüğü ancak yine de önceki sürüm olan YOLOv5m'ye kıyasla daha iyi olduğu gözlemlenmektedir. Bu sonuçlar, YOLOv11m'nin hem sınıflandırma doğruluğunda hem de tespit kabiliyetinde önceki sürümlerden üstün olduğunu göstermektedir (Bochkovskiy et al., 2020).

Genel olarak değerlendirildiğinde, YOLOv11m sürümü grafik üzerinde hem **AUC** hem de **mAP** değerlerinde açık bir yükseliş trendi ile öne çıkmaktadır. Bu durum, YOLOv11m'nin yalnızca daha yüksek doğrulukla nesne tespiti yapmakla kalmayıp, aynı zamanda farklı sınıflar arasında daha isabetli ayırım yapabilme yeteneğine sahip olduğunu göstermektedir. Özellikle sınıflandırma başarımının kritik olduğu uygulamalarda, bu sürümün önceki modellere göre tercih edilme olasılığı önemli ölçüde artmaktadır (Redmon & Farhadi, 2018).

3.2.5. YOLOv11'in avantajları ve dezavantajları

YOLOv11, nesne algılama alanında performans geliştirmeleriyle dikkat çekmektedir.

YOLOv11'in diğer sürümler gibi bu sürümünde dezavantajları bulunmaktadır.

3.2.5.1. Avantajları

Gerçek zamanlı algılama YOLO algoritmasının en büyük avantajlarından biri, gerçek zamanlı performans sunmasıdır. Resim işleme ve nesne algılama uygulamalarında hız, özellikle video işleme ve otonom sistemler gibi uygulamalar için kritik öneme sahiptir. YOLOv11, mimarisindeki iyileştirmeler sayesinde, daha önceki sürümlere göre çok daha hızlı işlem yapabilmektedir. Bu, sadece tespit edilen nesnelerin doğru bir şekilde sınıflandırılmasını sağlamakla kalmaz, aynı zamanda sistemin geribildirim hızını artırarak gerçek zamanlı uygulamalarda daha verimli hale gelir (Bochkovskiy et al., 2020).

YOLOv11 algoritması, nesne tespiti görevlerinde yüksek doğruluk oranları elde etmesiyle dikkat çekmektedir. Model performansının değerlendirilmesinde ROC (Receiver Operating Characteristic) eğrisi ve AUC (Area Under the Curve) metriği sıklıkla kullanılmaktadır. YOLOv11, düşük yanlış pozitif (False Positive) ve yanlış negatif (False Negative) oranları ile yüksek doğru pozitif oranı (True Positive Rate - TPR) sağlayarak, tespit doğruluğunu artırmaktadır (Redmon et al., 2016). YOLOv11'in önceki sürümlerine göre AUC değeri daha yüksektir, bu da daha güvenilir sonuçlar ve daha düşük hata oranları sunar.

Anchor-Free Yapı ile geleneksel nesne tespiti algoritmaları, önceden tanımlanmış çeşitli oran ve boyutlardaki anchor kutuları (anchor boxes) kullanarak nesnelerin konumunu tahmin etmeye çalışır. Ancak bu yaklaşım, yüksek hesaplama maliyeti, hassas hiperparametre ayarı gereksinimi ve düşük genelleme kabiliyeti gibi çeşitli dezavantajlar içermektedir (S. Zhang et al., 2020). Bu sorunları aşmak amacıyla geliştirilen anchor-free (çapa tabansız) yöntemler, son yıllarda nesne tespiti alanında yükseliş göstermektedir. YOLO (You Only Look Once) ailesinin en son sürümlerinden biri olan YOLOv11, bu paradigma değişimini benimseyerek anchor-free yaklaşımı merkezine alan bir mimari sunmaktadır (Wang et al., 2022).

YOLOv11, önceki sürümlerde kullanılan anchor box'lara bağlı kalmadan nesne konumlandırmasını öğrenebilme yetisine sahiptir. Bu yapı: modelin öğrenme süresini kısaltır, hiperparametre ayarlarını azaltır, genel doğrulukta artış sağlar (Tian et al., 2019).

Anchor-free yapının el yazısına uygunluğu klasik YOLO mimarilerinde (YOLOv3 – YOLOv5), nesne tespiti anchor box adı verilen ön tanımlı boyutlardaki kutular ile yapılır. Ancak anchor box'ların optimize edilmesi hem zaman alıcıdır hem de çok

çeşitli boyutlara sahip el yazısı gibi düzensiz verilerde performans kaybına neden olabilir (Tian et al., 2019). YOLOv11, anchor-free tasarımı ile bu sınırlamayı ortadan kaldırır. Bu yaklaşım, her pikseli potansiyel bir nesne merkezi olarak değerlendirir ve kutu boyutlarını modelin kendisinin öğrenmesini sağlar. El yazısında karakterler; farklı boyut, stil, hizalama ve satır eğimi gibi çok sayıda varyasyona sahip olduğundan, anchor-free yapı bu tür doğal varyasyonlara karşı daha toleranslıdır. Harflerin satır dışına taşması (line deviation), kelimeler arası düzensiz boşluklar, harf yüksekliği ve genişliğinde tutarsızlık, yazım tekrarları ve motor kontrol bozukluğuna işaret eden titreşimli çizgiler gibi modellerin tanımlanmasında modelin başarımını artırır.

Donanım uyumluluğu ve esneklik konusunda YOLOv11'in sahip olduğu anchor-free yapı ve modüler mimari, onu CPU, GPU ve TPU gibi çeşitli donanım altyapılarına kolayca adapte edilebilir hale getirmektedir (Bochkovskiy et al., 2020). TensorRT, ONNX, OpenVINO gibi popüler çerçevelerle yüksek uyumluluk sağlayan YOLOv11, kenar cihazlardan bulut tabanlı platformlara kadar geniş bir sistem yelpazesinde uygulanabilmektedir (Wang et al., 2022).

Modelin eğitimi için iki farklı sınıf ile (DEHB'li ve DEHB'siz) bireylere ait el yazısı örnekleri kullanıldı. Eğitim sürecinde Görsel Ön İşleme ile el yazısı sayfaları dijital ortama aktarılır. Işık farkları, gölgeler ve parazitler temizlenir. Görüntüler normalize edilir ve sabit çözünürlüğe dönüştürülür (örneğin 640x640 px). Etiketleme ile harf hizası, harf büyüklüğü ve aralık bozuklukları gibi belirli görsel göstergeler için kutular çizilir. Her kutu bir etiket sınıfına ('dehb' veya 'kontrol') atanır. Etiketleme işlemi mümkünse uzman görüşleriyle desteklenerek yapılır (örneğin çocuk psikiyatristi ya da özel eğitim uzmanı). Model Eğitimi ile görüntü verisi veri kümesine bölünür (train/val/test). YOLOv11 modeline etiketli veriler beslenerek, modelin hem sınıf hem konum tahmini öğrenmesi sağlanır. Eğitim sırasında kayıp fonksiyonları (loss functions), konum, sınıf ve obje var/yok doğruluğu üzerinden optimize edilir. Veri artırma (Augmentation) ile yazı yönü değişimi, bulanıklaştırma, noise ekleme gibi yöntemlerle modelin farklı varyasyonlara karşı dayanıklılığı artırılır.

YOLOv11'in test edildiği güncel benchmark veri kümelerinde (örneğin COCO ve Pascal VOC), AUC değerinin genellikle 0.96–0.98 aralığında olduğu rapor edilmiştir. Bu değer, modelin farklı sınıflar arasında güçlü bir ayırım yapabildiğini ve pozitif–negatif örnekleri yüksek güvenle sınıflandırabildiğini göstermektedir. ROC eğrisinin yukarıya yakın seyrettiği bu yapı, YOLOv11'in yanlış pozitif (FPR) oranını minimize

ederken doğru pozitif oranını (TPR) yüksek tutabildiğini ortaya koymaktadır (Everingham et al., 2015).

mAP@0.5 ve mAP@0.5:0.95 gibi doğruluk ölçütlerinde de YOLOv11 küçük nesne tespitindeki gelişmiş başarı oranı, derinleştirilmiş özellik çıkarım katmanları ve dikkat (attention) mekanizmalarının entegrasyonu ile yüksek başarı göstermektedir. Modelin mAP@0.5 değeri %94–95 düzeyine ulaşırken, daha kapsamlı mAP@0.5:0.95 ölçütünde dahi %56–60 aralığında istikrarlı performans sunduğu gözlemlenmektedir (S. Liu et al., 2018). Yüksek ROC ve mAP performans değerleri, YOLOv11'in hem sınıf ayırım başarısı hem de konumlandırma doğruluğu açısından endüstri standardının üzerinde bir model olduğunu ortaya koymaktadır.

3.2.5.2. Dezavantajları

YOLOv11'in tam versiyonu oldukça yüksek sayıda parametre içerdiğinden, model büyüklüğü artmıştır. Bu durum eğitim sırasında daha fazla GPU belleği gerektirir ve depolama ve dağıtım açısından zorluk yaratabilir (Bochkovskiy et al., 2020).

Eğitim verisine bağımlılık ile yüksek doğruluk elde edebilmek için kaliteli ve dengeli etiketlenmiş veri setine ihtiyaç duyar. Özellikle az örnekli sınıflarda performans düşebilir (Lin et al., 2014).

Çok hızlı hareket eden nesnelerde, bulanıklık ve ardışık kareler arası konum kaymaları tespiti zorlaştırabilir. YOLOv11 bu konuda iyileştirilmiş olsa da tamamen çözülmüş değildir (Wang et al., 2023).

YOLOv11 küçük nesnelerde başarılı olsa da, ultra yüksek çözünürlüklü (4K ve üzeri) görüntülerde, çok küçük nesnelerin algılanmasında hâlâ eksiklikleri bulunmaktadır.

YOLOv11'in bazı versiyonları, karmaşık Non-Maximum Suppression (NMS) işlemleri gerektirdiği için çıkış sonrası hesaplama yükünü artırabilir. Bu durum düşük güçlü cihazlarda performans düşüşüne neden olabilir (Bodla et al., 2017).

3.2.6. El yazısını tanımada ROC analizi

YOLOv11 (You Only Look Once version 11), gerçek zamanlı nesne algılama amacıyla geliştirilen, anchor-free mimarisi sayesinde önceden tanımlı sınır kutularına ihtiyaç duymadan çalışabilen, düşük gecikmeli ve yüksek doğruluk oranı sunan derin öğrenme modelidir (Tian et al., 2019). Bu çalışmada, YOLOv11'in özellikle dikkat

eksikliği ve hiperaktivite bozukluğu (DEHB) tanısı konmuş bireylerin el yazılarındaki yapısal anormalliklerin tespitinde kullanılması hedeflendi.

Model, çocuklara ait el yazısı örnekleri üzerindeki bozuklukları otomatik olarak saptamak üzere yapılandırıldı. Harf hizalama düzensizlikleri (örneğin, satır dışına taşmalar), harf boyutunda tutarsızlıklar, kelimeler arası boşluklandırma sorunları, çizgi eğriliği ve sapmaları, tekrarlayan harf ya da kelime örüntülerindeki gibi bozuklukları saptamak amacı ile model geliştirildi.

YOLOv11, bu anomalileri belirlemek için el yazısı görüntülerini segmentlere ayırmakta ve her segmentteki yapısal bozulmaları, nesne tespiti perspektifiyle analiz etmektedir. Modelin anchor-free yaklaşımı, farklı boyut ve biçimdeki yazı karakterlerinin doğrudan değerlendirilmesine imkân tanıyarak genel tespit başarımını artırmaktadır.

Modelin öğrenme süreci, DEHB tanısı konmuş bireylerin el yazısı örnekleri ile sağlıklı bireylerin örnekleri arasında karşılaştırmalı bir biçimde gerçekleştirildi. Eğitimin ardından YOLOv11, yeni bir el yazısı görselini aşağıdaki sıralı işlemlerle değerlendirmektedir:


1. Görsel, backbone katmanında çok seviyeli öznitelik haritalarına dönüştürülür.
2. Neck bileşeni, bu öznitelikleri birleştirerek yüksek bilgi içeriğini korur.
3. Head kısmı, ilgili öznitelik haritası üzerinden yazısal anormalliklerin bulunduğu alanları analiz eder ve bu bölgeler için sınıf tahminleri ile birlikte sınır kutuları oluşturur.
4. Elde edilen sınıflandırma sonuçları, ROC analizi aracılığıyla istatistiksel olarak değerlendirilir.

YOLOv11'in el yazısı temelli sınıflandırma başarımı, özellikle ROC (Receiver Operating Characteristic) analizi ile değerlendirildi. ROC eğrisi, modelin farklı karar eşiklerinde (threshold) ne derece doğru sınıflandırma yaptığını gösteren grafiksel bir analiz tekniğidir. Bu analiz kapsamında True Positive Rate (TPR) / Duyarlılık (Sensitivity) ve False Positive Rate (FPR) / Gerçekte negatif olan örneklerin oranları hesaplanmaktadır. Bu iki değerin her bir eşik için hesaplanması ile oluşturulan ROC eğrisinin altında kalan alan, AUC (Area Under the Curve) olarak adlandırılır ve modelin genel sınıflandırma performansını yansıtır. AUC değeri için 1.0: Mükemmel

sınıflandırıcı, 0.9–1.0: Çok iyi, 0.8–0.9: İyi, 0.7–0.8: Orta düzey, 0.5–0.7: Zayıf sınıflandırıcı olarak kabul edilir (Fawcett, 2006).

Modelin genel ayırt edici yeteneği Alıcı İşletim Karakteristik Eğrisi Altındaki Alan (AUC-ROC) kullanılarak değerlendirildi ve 0,75 değeri elde edildi (Şekil 3). Bu sonuç, iki sınıf arasında ayırım yapmada tatmin edici bir performans düzeyine işaret etmekte ve modelin DEHB'li çocukları yalnızca el yazısı özelliklerine dayanarak bu rahatsızlığı olmayanlardan etkili bir şekilde ayırt edebildiğini göstermektedir.

Bu sonuçlar, çocuklarda DEHB'nin ön taramasında gelişimsel olmayan, destekleyici araçlar olarak el yazısı tabanlı yapay zeka modellerinin potansiyel faydasını göstermektedir. Ancak, modelin performansının doğrulanması ve genelleştirilmesi için daha büyük ve daha çeşitli veri kümeleriyle daha fazla test yapılması gerekmektedir.



Şekil 3.4. ROC Eğrisi.

El yazısı tanıma görevlerinde ROC analizi, yalnızca modelin genel başarımını ölçmekle kalmaz, aynı zamanda optimal karar eşiği değerlerinin belirlenmesine de olanak tanır. Modelin her bir tahmini için ürettiği güven skorları (confidence scores), belirlenen bir eşik değeri ile karşılaştırılarak sınıflandırma kararı verilir. ROC eğrisi sayesinde bu eşik değerinin sistematik biçimde optimize edilmesi sağlanır. Böylece, TPR artırılırken FPR minimize edilerek modelin genel başarımı iyileştirilir (Plamondon & Srihari, 2000).

Bu çalışmada gerçekleştirilen deneysel değerlendirme sonucunda, YOLOv11 tabanlı sistemin DEHB tanımlı bireyleri ayırt etme başarısı, Şekil 3.4’de ROC eğrisi altında elde edilen %75’in üzerindeki AUC değeri ile doğrulandı. Bu sonuç, modelin hem sınıf ayırt etme kapasitesinin hem de görsel anomali tespit yeteneğinin oldukça yüksek olduğunu göstermektedir.



4. UYGULAMA

Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB), çocukluk çağında sıkça karşılaşılan nörogelişimsel bir bozukluktur. Geleneksel tanı yöntemlerinin subjektif olması, tanı süreçlerinde gecikmelere yol açmaktadır. Bu nedenle, objektif ve hızlı tanı yöntemlerine olan ihtiyaç giderek artmaktadır. Görüntü işleme ve derin öğrenme tekniklerinin son yıllarda gelişmesiyle birlikte, biyobelirteçlerin veya davranışsal örüntülerin görüntü tabanlı analizleri DEHB gibi bozuklukların tanısında alternatif bir yol sunmaktadır (American Psychiatric Association, 2013).

YOLOv11 derin öğrenme algoritması kullanılarak çocukların el yazısı görsellerinden Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB) tanısı konulmasına yönelik bir model geliştirildi.

Bu model, el yazısı örnekleri iki farklı katılımcı grubundan toplandı: DEHB tanısı konmuş çocuklar ve yaş ve eğitim geçmişi açısından eşleştirilmiş sağlıklı bireylerden oluşan bir kontrol grubudur.

El yazısı verileri, bir dizi motor ve bilişsel özelliği yakalamak için tasarlanıp standartlaştırılıp yazma görevleri aracılığıyla elde edildi. Bu görevler, serbest yazma egzersizlerinin yanı sıra önceden belirlenmiş harfleri ve kelime kalıplarını yazma gibi kontrollü etkinlikleri de içeriyordu. Bu yapılandırılmış veri toplama, katılımcılar arasında tutarlılık sağlamayı ve karşılaştırmalı analiz için sağlam bir temel oluşturmayı amaçladı. El yazısı örneklerini dijitalleştirmek için her bir parça tarandı. Etiketleme süreci, verilerin makine öğrenimi uygulamaları için hazırlanmasında kritik bir adımdı. Deneyimli uzmanlar, DEHB ile yaygın olarak ilişkilendirilen ayırt edici el yazısı özelliklerini belirlemek için her bir görüntüyü görsel olarak inceledi.

Bu özellikler arasında harf şekillerindeki düzensizlikler, tutarsız basınç uygulaması ve kelimeler veya satırlar arasındaki olağandışı boşluklar yer alıyordu. Bu görsel değerlendirmelere dayanarak, ilgili el yazısı özelliklerini vurgulamak için ek açıklamalar yapıldı.

Uzman güdümlü görsel analizi modern açıklama teknikleriyle birleştiren bu metodoloji, klinik veya eğitim bağlamlarında otomatik el yazısı değerlendirmesi için kapsamlı bir temel oluşturmaktadır. Veri toplama ve etiketleme sürecinin dikkatli tasarımı, sonraki makine öğrenimi deneylerinin güvenilirliğini ve tekrarlanabilirliğini sağlarken, aynı zamanda el yazısının DEHB gibi nörogelişimsel durumlar için gelişimsel olmayan bir belirteç olarak potansiyelini vurgulamaktadır.

Veri ön işleme aşamasının bir parçası olarak, tutarlılığı sağlamak ve modelin genelleme yeteneklerini geliştirmek için toplanan el yazısı görüntülerine çeşitli standardizasyon ve büyütme teknikleri uygulandı. Farklı tarayıcı ve kameraların kullanımından kaynaklanan görüntü kalitesi ve formatındaki farklılıklar nedeniyle, her görüntü önce sabit bir boyutla (örneğin 640×640 piksel) yeniden boyutlandırıldı ve renk boşluğu açısından standartlaştırıldı. Analiz gereksinimlerine bağlı olarak RGB veya gri tonlamaya dönüştürüldü. Ek olarak, görsel netliği artırmak için gerektiğinde kontrast ve parlaklık ayarlamaları gibi temel normalleştirme prosedürleri gerçekleştirildi. Eğitim veri setini daha da zenginleştirmek ve el yazısı stili ve yönündeki değişikliklere karşı model sağlamlığını artırmak için bir dizi veri artırma tekniği kullanıldı. Bunlar arasında rastgele döndürmeler, yatay ve dikey çevirme, ölçeklendirme dönüşümleri, gürültü enjeksiyonu ve özellikle renkli el yazısı örnekleri için renk değişimleri yer alıyordu. Toplu olarak, bu ön işleme adımları daha düzgün ve çeşitli bir veri kümesine katkıda bulunmuş ve böylece derin öğrenme modeli tarafından daha etkili öğrenmeyi desteklemiştir.

Geliştirilen model, el yazısı görüntülerini DEHB ve kontrol grubu olarak sınıflandırmak üzere eğitildi. Modelin doğruluğunu ölçmek amacıyla ROC eğrisi analizi yapıldı ve TP, FP, TN, FN değerleri üzerinden modelin sınıflandırma performansı detaylı olarak incelendi. Bu yöntem, eğitim verisinin hazırlanmasından modelin eğitimi ve testine kadar detaylı bir çalışmayı kapsamaktadır.

4.1. Veri Toplama ve Etiketleme

Çalışmamız kapsamında, DEHB (Dikkat Eksikliği ve Hiperaktivite Bozukluğu) tanısı almış çocuklar ile yaş ve eğitim düzeyi benzerliği gösteren sağlıklı kontrol grubuna ait el yazısı örnekleri temin edildi. Örneklem gruplarındaki deneklerin el yazısı çalışmaları, standart yazım görevleri (Örneğin; serbest yazım, belli harf ve kelime kalıplarının yazımı) çerçevesinde toplandı.

Veri Kaynağı olarak el yazısı örnekleri, tarayıcı veya yüksek çözünürlüklü kamera kullanılarak dijital ortama aktarıldı. Toplanan her bir görüntü, dosya adı, hasta bilgisi (anonimleştirilmiş) ve etiket bilgileri (DEHB veya sağlıklı) ile birlikte veri tabanında saklandı. Toplanan veriler dataset images/train klasöründe yer almaktadır. Veri seti, “dataset” adlı ana klasör içerisinde organize edildi. Eğitilmek istenilen görüntüleri ‘dataset’ kalsörü içindeki ‘images’ klasörüne aktarıldı.

El yazısı görüntüleri ‘dataset/images/train’ dizinine yerleştirildi. Bu dizin içerisinde 63 DEHB ve 75 kontrol grubu örneği bulunmaktadır. Ayrıca ‘dataset/images/val’ dizininde model eğitim sürecinde test amaçlı 10 DEHB ve 15 Kontrol grubu bulunmaktadır.

Modelin eğitimi yapıldıktan sonra 38 DEHB ve 29 Kontrol grubu ile model testi başarı ile gerçekleştirilmiştir.

Tablo 4.1. Model Eğitiminde Kullanılan DEHB'li Veriler.

DEHB	KIZ	ERKEK	TOPLAM
1.SINIF	0	1	1
2.SINIF	11	12	23
3.SINIF	6	9	15
4.SINIF	3	10	13
5.SINIF	1	5	6
6.SINIF	0	6	6
7.SINIF	2	4	6
8.SINIF	0	3	3
TOPLAM	23	50	73

4.2. Görüntü Etiketleme

Görsellerin analizinde, öncelikli olarak el yazısının belirgin karakteristik özellikleri (harflerin şekli, yazı baskısı, kelime aralıkları vb.) dikkate alındı. Bu özellikler, deneyimli uzmanlar tarafından görsel olarak incelenip ve DEHB’ye özgü belirgin yazım bozuklukları / tutarsızlık örüntüleri not edildi. Ardından, etiketleme işlemi için bounding box’lar kullanılarak yazının farklı bölümleri YOLO tabanlı analiz için manuel olarak işaretlendi ve bu veriler dataset/labels/train klasöründe yer almaktadır.


El yazısı görüntülerinin sınıflandırılmasında kullanılacak verilerin hazırlanması amacıyla python ortamında görüntü etiketleme işlemi gerçekleştirildi. Etiketleme işlemi için açık kaynak kodlu bir araç olan *LabelImg* programı tercih edildi. Uygulamanın çalıştırılabilmesi için öncelikle ilgili bağımlılıkların yüklendiği Python

dosyası sistem ortamına dahil edildi. Terminal komut satırına Şekil 4.1’ deki ifadeler girilerek, LabelImg yazılımının gereksinim duyduğu kütüphaneler yüklenip ve program başlatıldı:


```
tezmodel> pip install -r labelImg-master\requirements\requirements-  
linux-python3.txt  
tezmodel> python labelImg.py
```

Şekil 4.1. LabelImg Kütüphanesi.

Şekil 4.1 LabelImg kütüphanesindeki adımlar tamamlandıktan sonra, program arayüzü aracılığıyla ‘dataset/images’ dizininde yer alan el yazısı görüntüleri manuel olarak etiketlendi. Etiketleme sürecinde, her bir görüntü dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) tanısı almış bireylere ait örnekler ile kontrol grubuna ait örnekler olarak iki temel sınıf altında etiketlendi. Bu sayede, modelin eğitimi için gerekli olan etiketli veri kümesi oluşturularak, sınıflandırma işlemi için uygun veri yapısı hazırlandı.



Şekil 4.2. Etiketleme İşlemi.



Şekil 4.3. Etiketleme İşlemi.

Şekil 4.2 ve 4.3'deki etiketleme işlemi tamamlandıktan sonra, her bir görüntüye karşılık oluşturulan '.txt' uzantılı etiket dosyaları, modelin eğitim aşamasında kullanılmak üzere 'dataset/labels/train' dizinine taşındı. Bu şekilde, YOLOv11 modeline uygun biçimde yapılandırılmış etiketli veri kümesi oluşturuldu.

4.3. Model Eğitimi

Loss Fonksiyonu ile eğitim sürecinde, YOLO'nun çoklu hedef fonksiyonları kullanılarak yer belirleme (bounding box koordinat hatası), güven skoru, sınıf tahmini kayıpları hesaplandı. Bu kayıpların, toplam ağırlıklı kayıp fonksiyonu altında minimize edilmesi hedeflenmiştir.

Öğrenme oranı: Başlangıçta 0.001, eğitim ilerledikçe azaltma stratejisi uygulanmıştır. Batch boyutu: 16, Epoch sayısı: 100, Modelin stabilizasyonu sağlanana kadar (örneğin, 50-100 epoch) eğitilmiştir.

Eğitim Süreci: Veri seti, eğitim ve doğrulama olarak ikiye ayrılmıştır. Eğitim sırasında her epoch sonunda doğrulama setinde elde edilen doğruluk, kayıp ve hata oranı gibi metrikler izlenmiş; aşırı öğrenmenin (overfitting) önlenmesi için erken durdurma (early stopping) gibi yöntemler uygulanmıştır.

YOLOv11 algoritmasına dayalı nesne algılama modelinin eğitimi Google Colab platformu kullanılarak gerçekleştirildi. Google Colab, GPU (Grafik İşlem Birimi) ve

TPU (Tensör İşlem Birimi) destekli bir çalışma ortamı sağlaması, derin öğrenme tabanlı modellerin eğitimi için erişilebilir, esnek güçlü bir çalışma ortamı sunmaktadır.

Modelin eğitimi için öncelikle oluşturulan veri seti (içerdiği eğitim ve doğrulama görüntüleri ile birlikte) Google Drive üzerine yüklendi. Modelin bu verilere erişimini ve sınıflandırma yapılandırmasını sağlayacak şekilde bir 'conf.yaml' dosyası hazırlandı. Bu dosyanın Şekil 4.4'deki 'conf.yaml' içeriği aşağıdaki gibidir:

```
train: /content/drive/MyDrive/projeler/tezmodel/dataset/images/train
val:   /content/drive/MyDrive/projeler/tezmodel/dataset/images/val
nc: 2
names: ['kontrol', 'dehb']
```

Şekil 4.4. Conf.yaml Dosyası.

train ve val: Eğitim ve doğrulama veri yollarını tanımlar.

nc: Sınıf sayısını belirtir; bu çalışmada kontrol ve dehb olmak üzere iki sınıf bulunmaktadır.

names: Sınıf adlarını belirtir.

Yukarıda belirtilen yapılandırmanın ardından model eğitimi için kullanılan donanım ortamı, Google Colab üzerinden T4 GPU olarak seçildi. Bu donanım yaklaşık 15 GB GPU belleği sağlamaktadır. Eğitim işleminin başlatılabilmesi için öncelikle Şekil 4.5'deki gerekli kütüphaneler yüklendi:

```
!pip install ultralytics
```

Şekil 4.5. Kütüphane Yükleme.

Daha sonra, Google Drive içeriğine erişim sağlamak amacıyla Şekil 4.6'da yer alan komut kullanıldı ve kullanıcı hesabı ile doğrulama gerçekleştirildi:

```
from google.colab import drive
drive.mount("/content/drive")
```

Şekil 4.6. Google Drive Bağlantısı.

Yapılandırma dosyasının yolunu kontrol etmek amacıyla ise Şekil 4.7'deki kod bloğu komutu çalıştırıldı:

```
!ls /content/drive/MyDrive/projeler/tezmodel/conf.yaml.
```

Şekil 4.7. Dosya Bağlantısı.

Model eğitimi için YOLOv11'in küçük (small) sürümü tercih edilmiş ve Şekil 4.8'deki gibi tanımlanmıştır:

```
from ultralytics import YOLO
model=YOLO("yolo11s.pt")
```

Şekil 4.8. YOLO Kütüphanesi.

Yapılandırma dosyasının yolu değişkene atanarak, eğitim işlemi Şekil 4.9'deki parametrelerle başlatılmıştır:

```
conf_dosya_konumu="/content/drive/MyDrive/projeler/tezmodel/conf.yaml"
sonuclar =model.train(
    data=conf_dosya_konumu,
    epochs=100,      (model görsel tekrarlar sıklığı)
    batch=16,        (her bir döngüde işlediği görsel sayısı)
    imgsz=640        (ortalama çözünürlük )
```

Şekil 4.9. Model Eğitimi.

Sistem dili ile ilgili oluşabilecek uyumsuzlukların önüne geçmek amacıyla, çalışma ortamı Şekil 4.10'daki gibi UTF-8 formatına çevrildi:

```
!apt-get install -y locales
!locale-gen en_US.UTF-8
!update-locale LANG=en_US.UTF-8
import os
os.environ["LANG"] = "en_US.UTF-8"
os.environ["LC_ALL"] = "en_US.UTF-8"
```

Şekil 4.10. UTF-8 Formatına Çevirme.

Eğitim tamamlandıktan sonra, model çıktılarının sıkıştırılarak indirilmesini sağlamak amacıyla Şekil 4.11'deki komut çalıştırıldı:

```
!zip -r zipmodel.zip /content/runs/
```

Şekil 4.11. Modeli *.zip Formatına Çevirme.

'conf.yaml' dosyası ile eğitim ve doğrulama dizinlerinin konumları ve sınıf etiketleri ('kontrol', 'dehb') belirlendi. Eğitim tamamlandıktan sonra 'best.pt' ve 'last.pt' adlı model ağırlıkları dosyaları elde edildi.

4.4. Model Testi

Eğitim sürecinde elde edilen 'last.pt' modeli, test görüntüleri üzerinde değerlendirildi. Python dili kullanılarak tüm test görüntüleri üzerinde tahmin işlemi gerçekleştirildi ve

her bir tahmin için sınıf (dehb veya kontrol) ve confidence (güven) skoru elde edildi. Bu veriler daha sonra 'kontrol.csv' dosyasına aktarıldı.

Eğitim sürecinin ardından, oluşturulan YOLOv11 tabanlı modelin performansını değerlendirmek amacıyla test işlemleri gerçekleştirildi. Modelin eğitimi sonucunda, tüm çıktılar 'runs/detect/train' dizini altında saklanmaktadır. Bu dizin içerisinde modelin eğitilmiş ağırlıkları 'best.pt' veya 'last.pt' eğitim sürecine ait metrikler, grafikler ve tahmin sonuçları yer almaktadır.

Modelin test edilmesi sürecinde, doğrulama veri seti veya daha önce modelin görmediği yeni test verileri kullanılarak, nesne algılama yetenekleri değerlendirilmektedir. Şekil 4.12'deki komut ile eğitilmiş model test modunda çalıştırıldı:

```
from ultralytics import YOLO
model = YOLO("runs/detect/train/weights/best.pt")
results =
model.predict(source="/content/drive/MyDrive/projeler/tezmodel/dataset/
images/test", imgsz=640, conf=0.25)
```

Şekil 4.12. Model Test.

best.pt: En iyi performans gösteren model ağırlıkları yüklenir.


source: Test verilerinin bulunduğu klasör belirtilir.

imgsz: Test sırasında kullanılacak giriş görüntülerinin çözünürlüğü tanımlanır.

conf: Algılama işlemi için güven skoruna ait eşik değeri ayarlanır.

Modelin çıktıları görsel olarak incelenebilmektedir. Ayrıca, test sonuçlarına ilişkin doğruluk oranı, hata oranı, precision, recall ve F1-score gibi performans metrikleri de değerlendirilebilir.

Şekil 4.13 incelendiğinde, F1 skoru ile güven seviyesi (confidence) arasındaki ilişki gösterilmektedir. F1 skoru, modelin doğruluğunu ve hatalarını dengeleyen bir metrik olup, özellikle sınıflandırma problemlerinde yaygın olarak kullanılır. Bu grafik, her iki sınıf (kontrol ve dehb) için F1 skorunun, güven seviyesiyle nasıl değiştiğini gösterir.



Şekil 4.13. F1 Skor.


Kontrol Grubu: Bu sınıfın F1 skoru, güven seviyesi arttıkça daha istikrarlı bir şekilde artmaktadır. Grafik, düşük güven seviyelerinde (0.0-0.4) kontrol sınıfının F1 skorunun oldukça düşük olduğunu ve güven seviyesi arttıkça performansın iyileştiğini gösteriyor.

DEHB Grubu: DEHB sınıfının F1 skoru ise güven seviyesi arttıkça artmakta ancak belli bir noktada (yaklaşık 0.7 civarında) sabitleniyor ve düşüş eğilimi göstermektedir. Bu, modelin yüksek güven seviyelerinde DEHB sınıfını tanımda daha başarılı olduğunu, ancak aşırı yüksek güven seviyelerinde yanlış sınıflandırmalar yapmaya başladığını gösterebilir.

Tüm Sınıflar : Mavi çizgi, tüm sınıflar için F1 skorunun genel eğilimini göstermektedir. Bu eğilim, sınıflandırmanın her iki sınıfı da kapsayacak şekilde genel başarısını yansıtmaktadır. F1 skoru, güven seviyesinin ortasında (yaklaşık 0.4) zirve yapmaktadır.

Şekil 4.13'de modelin genel performansı güven seviyesiyle karşılaştırmalı olarak incelenmektedir. Hem kontrol hem de DEHB sınıflarının doğruluğu güven seviyesine bağlı olarak değişmekte olup, aşırı yüksek güven seviyelerinin modelin geneli üzerinde olumsuz bir etkisi olabilmektedir.

Şekil 4.14 incelendiğinde , etiketlenmiş veri setine ilişkin sınıf dağılımı ve nesne konumlandırma bilgilerini içeren bir analiz sunmaktadır.



Şekil 4.14. Sınıf Dağılımı.

Sınıf Dağılımı (Üst Sol Grafik): Bu çubuk grafik, veri setinde yer alan iki sınıfın (kontrol ve DEHB) örnek sayısını göstermektedir. Kontrol grubu yaklaşık 90 örnekle veri setinde daha fazla temsil edilmektedir. DEHB grubu ise yaklaşık 73 örnek ile temsil edilmektedir. Bu dağılım, sınıflar arasında dengesizlik olduğunu ve bu durumun modelin sınıflar arası performansını etkileyebileceğini göstermektedir. Özellikle azınlık sınıfa ait örnek sayısının artırılması, sınıflandırma performansını artırabilir.


Kutu Dağılımı (Üst Sağ Grafik): Etiketlenen nesnelerin konumlarına ve boyutlarına göre oluşturulmuştur, her bir kutu bir örneği temsil etmektedir. Kutu yoğunluğunun merkezde yoğunlaştığı görülmektedir, bu da nesnelerin çoğunlukla görüntülerin merkezine yakın konumlandığını gösterir. Ayrıca kutuların büyük çoğunluğu benzer boyutlarda olup, veri setinde nesne boyutlarında aşırı bir varyasyon olmadığını göstermektedir.

Konum Dağılımı (Alt Sol Grafik – x ve y koordinatları): Bu dağılım grafiği, nesnelerin yatay (x) ve dikey (y) düzlemdeki pozisyonlarını göstermektedir. x ekseninde 0.4 ile 0.6 arasında yoğunluk gözlemlenirken, y ekseninde 0.1 ile 0.2 arasında yoğun bir yığılma bulunmaktadır. Bu da nesnelerin genellikle görüntünün ortasına yakın bölgelerde konumlandığını göstermektedir.

Boyut Dağılımı (Alt Sağ Grafik – genişlik ve yükseklik): Bu grafik, nesnelerin boyutlarını (genişlik ve yükseklik) analiz etmektedir. Nesne genişlikleri çoğunlukla 0.6-0.8 aralığında yoğunlaşmıştır. Yükseklik dağılımı ise 0.1 ila 0.2 arasında toplanmaktadır. Bu da nesnelerin genellikle geniş ancak nispeten daha kısa yapılar olduğunu göstermektedir. El yazısı karakterlerinin yatay yapısı bu sonucu desteklemektedir.

Şekil 4.14, YOLOv11 modeli için hazırlanan etiketli veri setinin dengesi, nesne konumları ve boyutları hakkında önemli bilgiler sağlamaktadır. Sınıf dengesizliği modeli etkileyebileceği için bu durumun göz önünde bulundurulması; ayrıca nesnelerin görüntüdeki konum ve boyut yoğunluğu, modelin öğrenme sürecini yönlendirmek açısından dikkate alınmalıdır.

Şekil 4.15 incelendiğinde, Recall-Confidence Curve (Duyarlılık-Güven Skoru Eğrisi) olarak adlandırılır ve modelin farklı güven skorlarındaki duyarlılık (recall) performansını sınıflara göre analiz eder.



Şekil 4.15. Duyarlılık-Güven Skoru Eğrisi.

Duyarlılık-Güven Skoru Eğrisi (Recall-Confidence Curve) YOLOv11 modelinin farklı güven skorlarına (confidence threshold) göre sınıf bazında ne kadar doğru pozitif (true positive) tespitte bulunduğunu gösteren duyarlılık (recall) metriklerinin değişimini sunmaktadır.

X Eksen (Confidence) modelin bir tahminine ne kadar güvendiğini gösterir. 0 ile 1 arasında değişir. Y Eksen (Recall) ise Gerçek nesnelerden kaçının model tarafından doğru şekilde tespit edildiğini gösterir. 1.0 değeri, tüm gerçek nesnelerin başarıyla tanındığı anlamına gelir.


DEHB Sınıfı : Düşük confidence seviyelerinde (0.0–0.2) oldukça yüksek bir recall değeri (~0.95) ile başlamaktadır. Bu, modelin düşük güven eşiğinde DEHB sınıfına ait birçok örneği tanıyabildiğini, ancak bu tahminlerin doğruluğunun düşük olabileceğini gösterir. Güven skoru arttıkça, özellikle 0.6 üzerindeki eşiklerde recall değeri hızla düşmekte ve 0.9’da neredeyse sıfırlanmaktadır. Bu durum, modelin yüksek güvenli tespitlerde daha az sayıda DEHB örneği tespit edebildiğini ortaya koymaktadır.

Kontrol Sınıfı : Tüm aralık boyunca DEHB sınıfına göre daha düşük bir recall değeri sergilemektedir. Bu durum, modelin kontrol sınıfını tanıma performansının görece zayıf olduğunu göstermektedir.

Tüm Sınıflar: Ortalama recall değeri, yaklaşık 0.49 düzeyindedir. En yüksek recall değeri, sıfır güven eşiğinde elde edilmiştir. Bu da modelin, çok düşük bir güven eşiğiyle çalıştırıldığında yüksek miktarda tespit yaptığını, ancak bu tespitlerin doğruluk oranının tartışmalı olabileceğini gösterir.

Model, DEHB sınıfını düşük güven eşiğinde başarılı şekilde tanıyabilmektedir, ancak yüksek güven değerlerinde performansı düşmektedir. Kontrol sınıfı için recall performansı genel olarak düşüktür, Bu durum sınıflar arasında dengesizlik veya modelin bu sınıfı ayırt etmede zorlandığı anlamına gelebilir. Uygulamada kullanılacak güven eşiği belirlenirken, yüksek duyarlılık mı yoksa yüksek doğruluk mu istendiği kararına göre Şekil 4.15 önemli bir referans niteliğindedir.

Şekil 4.16 "Precision-Confidence Curve" (Hassasiyet-Güven Skoru Eğrisi) olarak bilinir. Şekil 4.16, modelin tahmin güven skorları (confidence scores) arttıkça precision (kesinlik/hassasiyet) değerinin nasıl değiştiğini gösterir. Yani, modelin belirli bir güven seviyesinin üzerindeki tahminlerinin ne kadar doğru olduğunu analiz eder.



Şekil 4.16. Hassasiyet-Güven Skoru Eğrisi.

Şekil 4.16, modelin tahmin güven skorları (confidence scores) arttıkça precision (kesinlik/hassasiyet) değerinin nasıl değiştiğini gösterir. Yani, modelin belirli bir güven seviyesinin üzerindeki tahminlerinin ne kadar doğru olduğunu analiz eder. Güven skoru (0 ile 1 arasındadır). 1'e yaklaştıkça modelin o tahmini yaparken kendinden daha emin olduğunu gösterir. Precision (kesinlik), doğru pozitif tahminlerin tüm pozitif tahminlere oranıdır. Yani, model "bu görüntü DEHB" dediğinde gerçekten DEHB olma olasılığıdır.

Formül: $\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$

DEHB: DEHB sınıfına ait precision-confidence ilişkisini gösterir. Genellikle orta seviyelerde daha dengeli gider, ancak yüksek güven skorlarında veri azaldıkça precision dalgalanabilir (ani düşüş/yükselişler).


Kontrol: Kontrol grubunun (DEHB olmayan) precision değerlerini gösterir. Grafiklerde az veri varsa bu çizgi eksik veya düz olabilir.

Tüm Sınıflar: Tüm sınıfların birleşik precision ortalaması.

Şekilde tüm sınıflar (all classes) 1.00 at 0.941 yani güven skoru 0.941 ve üzerindeki tahminler %100 doğrulukla yapılmış. Precision değeri, düşük confidence skorlarında düşüktür. Bu beklenir çünkü modelden emin olmadığında yaptığı pozitif tahminler daha çok hata içerir. Confidence skoru yükseldikçe precision da artar. Bu, modelin kendinden emin olduğu tahminlerin daha doğru olduğunu gösterir. 0.941 güven

skorundan sonra modelin precision değeri 1.00, yani bu noktadan sonra modelin tüm pozitif tahminleri doğru (hiç yanlış pozitif yok).

Precision-confidence eğrisi, modelin güven skorlarını hangi eşikte keserek optimum doğrulukla tahminler yapabileceğini gösterir. Özellikle DEHB tespiti gibi kritik alanlarda, güven skorlarına dayalı karar verme süreçlerinde rehberlik eder.



Şekil 4.17. Model Eğitim Süreci.

Şekil 4.17 incelendiğinde; YOLO tabanlı nesne tespiti modelinin eğitim süreci boyunca izlenen çeşitli performans metriklerini içermektedir. Grafikler hem eğitim (train) hem de doğrulama (val) kümeleri üzerinden hesaplanan kayıpları (loss) ve metrikleri göstermektedir. Her bir alt grafik, belirli bir metriğin epoch bazında değişimini yansıtır:

train/box_loss & val/box_loss :Bu metrikler, modelin tahmin ettiği sınırlayıcı kutuların (bounding boxes) gerçek kutulara olan benzerliğini yansıtır. Gözlemlenen azalan eğilim, modelin konum tahmininde daha başarılı hale geldiğini göstermektedir. Eğitim ve doğrulama için benzer düşüşler, overfitting (aşırı öğrenme) riskinin düşük olduğunu gösterir.

train/cls_loss & val/cls_loss :Bu grafikler, sınıf tahminine ilişkin hataları göstermektedir. Modelin, sınıfları zamanla daha doğru şekilde tahmin etmeyi öğrendiği açıkça görülmektedir. Başlangıçta yüksek olan değerler, modelin başta zorlandığını ancak zamanla başarıyı artırdığını gösterir.

train/df_l_loss & val/df_l_loss: Distribüsyon odaklı lokalizasyon kaybı (DFL loss), özellikle kutu koordinatlarının doğruluğunu optimize etmeyi hedefler. Bu değerin azalması, kutu tahminlerinin giderek daha isabetli hale geldiğine işaret eder.

metrics/precision(B): Precision (kesinlik), modelin pozitif tahminlerinin ne kadarının doğru olduğunu gösterir. Değerin zamanla arttığı gözlemlenmektedir, bu da modelin yanlış pozitifleri azaltarak daha güvenilir hale geldiğini göstermektedir. Ancak zaman zaman yaşanan dalgalanmalar, modelin tutarsızlıklar yaşayabildiğini gösterebilir.

metrics/recall(B): Recall (duyarlılık), modelin tüm gerçek pozitifleri ne oranda doğru tespit ettiğini ölçer. Recall değerindeki kademeli artış, modelin zamanla daha fazla doğru tespit yaptığına işaret eder. Ancak eğitim sürecinin ilk safhalarında düşük kalması, modelin başta bazı nesneleri tanıyamadığını gösterir.

metrics/mAP50(B) & metrics/mAP50-95(B): Bu grafikler, ortalama Ortalama Doğruluk (mean Average Precision, mAP) değerlerini göstermektedir. mAP@50, Intersection over Union (IoU) eşik değeri %50 iken hesaplanırken; mAP@50-95, IoU eşikleri %50 ile %95 arasında değişen bir ortalama. Bu metrikler, modelin genel nesne tespiti başarısını özetlemektedir. Giderek yükselen eğriler, modelin genel doğruluğunun iyileştiğini ve daha sağlam hale geldiğini göstermektedir.

Bu grafikler doğrultusunda, modelin eğitim süreci boyunca önemli bir öğrenme ve iyileşme gerçekleştirdiği söylenebilir. Özellikle hem eğitim hem de doğrulama kümelerinde kayıpların düşmesi ve metriklerin yükselmesi, modelin genelleme yeteneğinin arttığını ve overfitting riskinin minimal düzeyde kaldığını ortaya koymaktadır. Dalgalanmalar modelin bazı durumlarda kararsız olabileceğini gösterse de genel eğilim başarılı bir eğitim sürecine işaret etmektedir.

Şekil 4.18 de yer alan kodumuzda YOLOv11 ile eğitilmiş bir modeli kullanarak yeni (eğitilmemiş) görüntüler üzerinde tahminler yapmayı ve bu tahminleri Excel (.csv) dosyasına aktarılmaktadır.

```

import os
from glob import glob
from ultralytics import YOLO

model = YOLO("last.pt")

# Görüntüleri al
resimler = glob("test/kontrol/*.jpg") +
glob("dataset/images/train/*.jpeg") +
glob("dataset/images/train/*.png")

# Sonuçları depolayacağımız liste
tum_sonuclar = []

# Her resim için tahmin yap
for resim in resimler:
    print(f"İşleniyor: {resim}")
    sonuclar = model.predict(resim, save=False)[0]

    # Her bir tespit için sınıf ve skorları al
    boxes = sonuclar.boxes
    class_ids = boxes.cls.cpu().numpy()      # sınıf ID'leri
    scores = boxes.conf.cpu().numpy()        # confidence skorları

    # Her nesneyi ayrı ayrı kaydet
    for cls, conf in zip(class_ids, scores):
        tum_sonuclar.append({
            "resim": os.path.basename(resim),
            "sinif": int(cls),
            "skor": round(float(conf), 4)
        })

# Sonuçları yazdır
for s in tum_sonuclar:
    print(s)

import pandas as pd

df = pd.DataFrame(tum_sonuclar)
df.to_csv("kontrol.csv", index=False)

```

Şekil 4.18. Yeni Görüntüler Üzerinde Tahminler Yapma.

Gerekli kütüphanelerin içe aktarılması için Şekil 4.19'daki kod blogu çalıştırıldı.

```

import os
from glob import glob
from ultralytics import YOLO

```

Şekil 4.19. Kütüphanelerin İçe Alınması.

os: Dosya sistemindeki yolları işlemek için kullanılır.

glob: Belirli uzantıya sahip dosyaları dizinler içinde aramak için kullanılır.

ultralytics: YOLO modellerinin eğitim ve tahmin işlemleri için kullanılan Python kütüphanesidir.

Eğitilmiş modelin sisteme yüklenmesi için Şekil 4.20'deki kod bloğu çalıştırıldı.

```
model = YOLO("last.pt")
```

Şekil 4.20. Eğitilmiş Modelin Sisteme Yüklenmesi.

"last.pt": Daha önce eğitilmiş ve kaydedilmiş olan YOLO model dosyası. Bu satır ile model belleğe yüklenmiş olur ve tahminler için hazır hale getirilir.

Test edilecek görsellerin sisteme yüklenmesi için Şekil 4.21'deki kod bloğu çalıştırıldı.

```
resimler = glob("test/kontrol/*.jpg") +  
glob("dataset/images/train/*.jpeg") +  
glob("dataset/images/train/*.png")
```

Şekil 4.21. Görsellerin Sisteme Yüklenmesi.

Bu satırda, farklı klasörlerdeki .jpg, .jpeg ve .png uzantılı tüm görseller alınır. Kodun amacı, hem test hem de eğitim dizinlerinde yer alan tüm görselleri model üzerinde test etmektir.

Tahmin sonuçlarını tutmak için liste oluşturulması Şekil 4.22'deki kod bloğu çalıştırıldı.

```
tum_sonucclar = []
```

Şekil 4.22. Tahmin Sonuçları.

Bu boş liste, her bir görsel üzerinde yapılan tahminlerin sonuçlarını saklamak için kullanılacaktır.

Her görsel için modelle tahmin yapılabilmesi için Şekil 4.23'deki kod bloğu çalıştırıldı.

```
for resim in resimler:  
    print(f"İşleniyor: {resim}")  
    sonucclar = model.predict(resim, save=False)[0]
```

Şekil 4.23. Modelle Tahmin Yapılması.

model.predict(resim, save=False): Her bir görsel için nesne tanıma işlemi yapılır.

save=False: Tahmin sonucunun görsel çıktısını diske kaydetmeden sadece sonuçların alınmasını sağlar.

[0]: Sadece ilk sonucu alır (YOLO çıktıları liste şeklindedir).

Tahminlerin güven skorlarının elde edilmesi için Şekil 4.24'deki kod bloğu çalıştırıldı.

```
boxes = sonuçlar.boxes
class_ids = boxes.cls.cpu().numpy()      # sınıf ID'leri
scores = boxes.conf.cpu().numpy()        # confidence skorları
```

Şekil 4.24. Tahminlerin Güven Skorları.

boxes: Modelin tahmin ettiği sınırlayıcı kutular (bounding boxes).

boxes.cls: Her tespitin sınıf etiketinin sayısal karşılığı (örneğin 0: kontrol, 1: dehb).

boxes.conf: Her tahminin güven skoru (0.0 - 1.0 arasında bir değer).

.cpu().numpy(): Tensor verisini NumPy dizisine çevirerek daha kolay işlenmesini sağlar.

Tahmin sonuçlarının listeye eklenmesi için Şekil 4.25'deki kod bloğu çalıştırıldı.

```
for cls, conf in zip(class_ids, scores):
    tum_sonucalar.append({
        "resim": os.path.basename(resim),
        "sinif": int(cls),
        "skor": round(float(conf), 4) })
```

Şekil 4.25. Tahminlerin Listeye Alınması.

Her bir görseldeki tüm tespitler için: Görsel adı, Tahmin edilen sınıf (etiket), Tahminin güven skoru bir sözlük (dictionary) formatında listeye eklenir.

Tüm tahminlerin terminale yazdırılması için Şekil 4.26'daki kod bloğu çalıştırıldı.

```
for s in tum_sonucalar:
    print(s)
```

Şekil 4.26. Tahminlerin Terminale Yazdırılması.

Her tahmin sonucu, terminal ekranında yazdırılır (örnek: {'resim': 'abc.jpg', 'sinif': 1, 'skor': 0.882}).

Tahmin sonuçlarının Excel (*.csv) formatında kaydedilmesi için Şekil 4.27'deki kod bloğu çalıştırıldı.

```
import pandas as pd
df = pd.DataFrame(tum_sonucilar)
df.to_csv("kontrol.csv", index=False)
```

Şekil 4.27. Tahmin sonuçların .csv formatına kaydedilmesi.

pandas: Veri işleme ve dışa aktarma için kullanılan bir kütüphanedir.

pd.DataFrame(...): Liste halindeki tahminler tabloya dönüştürülür.

to_csv(...): Tabloyu kontrol.csv adlı bir dosyaya yazar. index=False parametresi, satır numaralarının dosyaya yazılmamasını sağlar.

Şekil 4.18 de yer alan kodumuz önceden eğitilmiş bir YOLO modeli kullanarak test verileri üzerinde nesne tespiti işlemi gerçekleştirir. Her bir tespitin görsel adı, sınıf etiketi ve tahmin güven skoru kaydedilir. Sonuçlar analiz edilebilmesi amacıyla .csv formatında dışa aktarılır. Bu işlem, modelin gerçek dünya verileri üzerindeki performansını değerlendirme ve istatistiksel analizler yapabilme açısından önemlidir.

4.5. ROC Analizi

Modelin sınıflandırma başarısı ROC (Receiver Operating Characteristic) analizi ile değerlendirilmiştir. 'veriler.xlsx' dosyasından elde edilen tahmin skorları ve gerçek sınıf etiketleri kullanılarak ROC eğrisi çizilmiş, modelin AUC (Area Under Curve) değeri hesaplanmıştır.

```
import pandas as pd
from sklearn.metrics import roc_curve, roc_auc_score
import matplotlib.pyplot as plt
# Excel'den veri oku
df = pd.read_excel('veriler.xlsx', sheet_name='Sayfa1')
df.columns = df.columns.str.strip() # sütun adlarını temizle
# Sütunları ata
y_true = df['sinif']
y_scores = df['skor']
# ROC analizini yap
fpr, tpr, thresholds = roc_curve(y_true, y_scores)
auc_score = roc_auc_score(y_true, y_scores)
# ROC grafiğini çiz
plt.plot(fpr, tpr, label=f"ROC Curve (AUC = {auc_score:.2f})")
plt.plot([0, 1], [0, 1], 'k--') # rastgele tahmin çizgisi
plt.xlabel("False Positive Rate")
plt.ylabel("True Positive Rate")
plt.title("ROC Curve")
plt.legend(loc="lower right")
plt.grid()
plt.show()
```

Şekil 4.28. ROC Analizi.

Şekil 4.28 de yer alan Python kodu, YOLOv11 modelinden elde edilen sınıf ve skorlara dayanarak ROC (Receiver Operating Characteristic) analizini gerçekleştirmekte ve grafiğini çizmektedir. Sınıflandırma modelinin doğruluk performansını ölçmek için ROC eğrisini ve AUC (Area Under Curve) değerini üretir.

Gerekli kütüphanelerin içe alınması için Şekil 4.29'daki kod bloğu çalıştırıldı.

```
import pandas as pd
from sklearn.metrics import roc_curve, roc_auc_score
import matplotlib.pyplot as plt
```

Şekil 4.29. Kütüphanelerin İçe Alınması.

pandas: Excel dosyasından veri okumak ve veri işlemek için kullanılır.

roc_curve: Gerçek etiketler ile modelin tahmin skorlarına göre ROC eğrisinin noktalarını hesaplar.

roc_auc_score: ROC eğrisi altındaki alanı (AUC) hesaplar, bu skor modelin sınıflandırma başarısını özetler.

matplotlib.pyplot: ROC eğrisini görselleştirmek için grafik çizer.

Excel dosyasından verilerin okunabilmesi için Şekil 4.30'daki kod bloğu çalıştırıldı.

```
df = pd.read_excel('veriler.xlsx', sheet_name='Sayfa1')
df.columns = df.columns.str.strip() # sütun adlarını temizle
```

Şekil 4.30. Excel dosyaların İçe alınması.

'veriler.xlsx': Önceden dışa aktarılmış skor ve sınıf etiketlerinin bulunduğu dosya.

sheet_name='Sayfa1': Excel dosyasındaki hedef sayfa.

.str.strip(): Sütun adlarında varsa baştaki veya sondaki boşlukları temizler (örneğin " skor " → "skor").

Değişkenlerin hazırlanması için Şekil 4.31'deki kod bloğu çalıştırıldı.

```
y_true = df['sinif']
y_scores = df['skor']
```

Şekil 4.31. Değişkenlerin Hazırlanması.

y_true: Gerçek sınıf etiketleri (örn. 0: kontrol, 1: DEHB).

y_scores: Modelin tahmin ettiği confidence score değerleri.

Bu iki değişken, ROC analizinin temel girdilerini oluşturur.

ROC Eğrisi İçin FPR, TPR ve Threshold değerlerinin hesaplanması için Şekil 4.32'deki kod bloğu çalıştırıldı.

```
fpr, tpr, thresholds = roc_curve(y_true, y_scores)
```

Şekil 4.32. ROC Eğrisi için Değerlerin Hesaplanması.

fpr (False Positive Rate): Yanlış pozitiflerin oranı.

tpr (True Positive Rate): Doğru pozitiflerin oranı (aynı zamanda "Recall").

thresholds: Farklı eşik değerleri için bu oranların nasıl değiştiğini gösteren eşik değerleridir. Bu değerler ROC eğrisini oluşturmak için gereklidir.

AUC skorunun hesaplanabilmesi için Şekil 4.33'deki kod bloğu çalıştırıldı.

```
auc_score = roc_auc_score(y_true, y_scores)
```

Şekil 4.33. AUC Skorunun Hesaplanması.

AUC (Area Under the Curve): ROC eğrisinin altındaki alandır ve modelin genel sınıflandırma performansını tek bir sayı ile özetler.

AUC değeri 0.5'e yakınsa model rastgele tahmin yapıyor demektir; 1.0'a yakınsa mükemmel sınıflandırma anlamına gelir.

ROC eğrisinin görselleştirilmesi için Şekil 4.34'deki kod bloğu çalıştırıldı.

```
plt.plot(fpr, tpr, label=f"ROC Curve (AUC = {auc_score:.2f})")  
plt.plot([0, 1], [0, 1], 'k--') # rastgele tahmin çizgisi
```

Şekil 4.34. AUC Skorunun Hesaplanması.

plt.plot(fpr, tpr, ...): ROC eğrisi çizilir.

plt.plot([0, 1], [0, 1], 'k--'): $Y = X$ doğrusu (rastgele tahmin referansı). Modelin bu doğrunun üzerinde kalması beklenir.

Grafik Etiketleme ve Gösterim (ROC ANALİZİ) için Şekil 4.35'deki kod bloğu çalıştırıldı.

Modelin sınıflandırma başarısı ROC (Receiver Operating Characteristic) analizi ile değerlendirilmiştir. 'veriler.xlsx' dosyasından elde edilen tahmin skorları ve gerçek sınıf etiketleri kullanılarak ROC eğrisi çizilmiş, modelin AUC (Area Under Curve) değeri hesaplanmıştır.

```
plt.xlabel("False Positive Rate")
plt.ylabel("True Positive Rate")
plt.title("ROC Curve")
plt.legend(loc="lower right")
plt.grid()
plt.show()
```

Şekil 4.35. AUC Skorunun Hesaplanması.

Grafik eksenleri ve başlık etiketlenir.

legend: AUC değeri ile birlikte ROC eğrisi açıklanır.

grid(): Grafiğe yardımcı çizgiler eklenir.

show(): ROC eğrisi görselleştirilir.

Şekil 4.35 de yer alan kodumuz, YOLOv11 modeli ile elde edilen sınıflandırma çıktılarının ROC analizini yaparak modelin doğru pozitif ve yanlış pozitif oranlarını çeşitli eşik değerlerinde nasıl değiştirdiğini gösterir. ROC eğrisi ile birlikte hesaplanan AUC değeri, modelin genel sınıflandırma performansını sayısal olarak özetler. Özellikle tıbbi tanı sistemlerinde (örneğin DEHB tespiti gibi) ROC eğrisi, modelin hata toleranslarını anlamak için oldukça önemli bir ölçüttür.

4.6. Model Değerlendirmesi

Önerilen makine öğrenimi modelinin el yazısı örneklerine dayalı olarak DEHB'li çocuklar ile sağlıklı kontrolleri ayırt etmedeki performansını değerlendirmek için kapsamlı bir değerlendirme ölçütleri seti kullanılmıştır. Model özel bir veri kümesi üzerinde eğitilmiş ve 67 örnekten oluşan ayrı bir küme kullanılarak test edilmiştir. Karışıklık matrisi Tablo 4.2'de verilmiştir.

Tablo 4.2. Test Edilen Modelin Karışıklık Matrisi.

	Confusion Matrix Of Tested Model	
	Predicted	
	ADHD	Healthy
ADHD	29	9
Healthy	10	19

Karışıklık matrisine dayalı olarak, modelin tanısal doğruluğunu değerlendirmek için çeşitli temel performans göstergeleri hesaplanmıştır:

Doğruluk: Tüm test örnekleri arasında doğru sınıflandırılmış örneklerin oranı olarak tanımlanan genel doğruluk %72'dir (Denklem 4.3).

$$(TP+TN)/(TP+TN+FP+FN)=(29+19)/67=0,72 \quad (4.3)$$

Duyarlılık (Hatırlama veya Doğru Pozitif Oranı): Bu metrik, modelin DEHB vakalarını doğru bir şekilde tespit etme kabiliyetini göstermektedir. Duyarlılık %76 olarak hesaplanmıştır (Denklem 4.4).

$$TP/(TP+FN)=29/(29+9)=0,76 \quad (4.4)$$

Özgüllük (Doğru Negatif Oranı): Modelin sağlıklı bireyleri doğru bir şekilde tanımlama yeteneğini ölçen özgüllük %66'dır (Denklem 4.5)

$$TN/(TN+FP)=19/(19+10)=0.66 \quad (4.5)$$

Kesinlik (Pozitif Tahmin Değeri): DEHB olarak tahmin edilen tüm örnekler arasında gerçek DEHB vakalarının oranını temsil eden kesinlik %74'tür (Denklem 4.6).

$$TP/(TP+FP)=29/(29+10)=0,74 \quad (4.6)$$

Yanlış Pozitif Oranı (FPR): Yanlışlıkla DEHB olarak sınıflandırılan sağlıklı vakaların oranını gösteren FPR %34 olarak hesaplanmıştır. (Denklem 4.7).

$$FP/(FP+TN)=10/(10+19)=0,34 \quad (4.7)$$

Bu standart ölçütlere ek olarak, modelin genel ayırt edici yeteneği Alıcı İşletim Karakteristik Eğrisi Altındaki Alan (AUC-ROC) kullanılarak değerlendirilmiş ve 0,75 değeri elde edilmiştir. Bu sonuç, iki sınıf arasında ayırım yapmada tatmin edici bir performans düzeyine işaret etmekte ve modelin DEHB'li çocukları yalnızca el yazısı özelliklerine dayanarak bu rahatsızlığı olmayanlardan etkili bir şekilde ayırt edebildiğini göstermektedir.

Çocuklarda DEHB'nin ön taramasında gelişimsel olmayan, destekleyici araçlar olarak el yazısı tabanlı yapay zeka modellerinin potansiyel faydasını göstermektedir. Ancak, modelin performansının doğrulanması ve genelleştirilmesi için daha büyük ve daha çeşitli veri kümeleriyle daha fazla test yapılması gerekmektedir.

Performans Metrikleri: Geliştirilen modelin başarısı, doğruluk oranı (accuracy), hassasiyet (precision), çağrı (recall) ve F1 skoru metrikleri üzerinden değerlendirildi.

Ayrıca, ROC eğrileri ve confusion matrix analizleri, modelin DEHB ve sağlıklı sınıflandırmadaki performansını detaylandırmak amacıyla kullanıldı.

Kros Doğrulama: Elde edilen sonuçların genellenebilirliğini artırmak amacıyla, k-fold çapraz doğrulama (örneğin, k=5) yöntemi uygulanmış ve her fold için elde edilen sonuçlar ortalama performans değerleri ile raporlanmıştır.

Karşılaştırmalı Deneyler: Çeşitli deneysel senaryolar (örneğin, farklı veri artırımı teknikleri, farklı optimizasyon algoritmaları ve öğrenme oranı planları) uygulanarak, en iyi sonuç veren parametreler ve model konfigürasyonu belirlendi.

```
from sklearn.metrics import confusion_matrix
# Gerçek etiketler ve modelin tahmin ettiği etiketler
y_pred = (y_scores > 0.5).astype(int) # Örneğin, skoru 0.5'in üstü
pozitif, altı negatif olarak sınıflandır
# Karışıklık matrisi oluştur
cm = confusion_matrix(y_true, y_pred)

# TP, TN, FP, FN'yi al
TP = cm[1, 1] # Gerçek pozitif ve tahmin de pozitif
TN = cm[0, 0] # Gerçek negatif ve tahmin de negatif
FP = cm[0, 1] # Gerçek negatif ama tahmin pozitif
FN = cm[1, 0] # Gerçek pozitif ama tahmin negatif

# TPR (True Positive Rate) Hesapla
TPR = TP / (TP + FN)
print(f"True Positive Rate (TPR): {TPR:.2f}")
# FPR (False Positive Rate) Hesapla
FPR = FP / (FP + TN)
print(f"False Positive Rate (FPR): {FPR:.2f}")
print("True Positive (TP):", TP)
print("False Positive (FP):", FP)
print("True Negative (TN):", TN)
print("False Negative (FN):", FN)
```

Şekil 4.36. Karışıklık Matrisinin Hesaplanması.

Bir sınıflandırma modeli için karışıklık matrisi (confusion matrix) oluşturur ve bu matrise dayalı olarak TP (True Positive), TN (True Negative), FP (False Positive) ve FN (False Negative) değerlerini hesaplar. Ayrıca bu değerlere dayanarak TPR ve FPR oranlarını da çıkarır. Sınıflandırma modelinin tahmin sonuçlarını değerlendirerek, başarı oranlarını (TPR, FPR) karışıklık matrisi üzerinden analiz etmek.

Gerekli kütüphane karışıklık matrisi üretimini yapmak için gerekli kütüphanenin sisteme yüklenebilmesi için Şekil 4.37'deki kod bloğu çalıştırıldı.

```
from sklearn.metrics import confusion_matrix
```

Şekil 4.37. Karışıklık Matrisi Üretimi.

confusion_matrix: Gerçek etiketler ile modelin tahmin ettiği etiketler arasındaki karşılaştırmayı yaparak bir karışıklık matrisi (confusion matrix) üretir.

Tahmin etiketlerinin oluşturulması için Şekil 4.38'deki kod bloğu çalıştırıldı.

```
y_pred = (y_scores > 0.5).astype(int) # Örneğin, skoru 0.5'in üstü  
pozitif, altı negatif olarak sınıflandır
```

Şekil 4.38. Skor'un Hesaplanması.

Bu satırda, modelin verdiği skor değerleri bir eşik değeri olan 0.5 ile karşılaştırılarak ikili (binary) sınıflar elde edilir. skor > 0.5 ise sınıf 1 (pozitif) olarak etiketlenir, skor <= 0.5 ise sınıf 0 (negatif) kabul edilir.

.astype(int): Boolean sonucu tamsayıya çevirerek 0 ve 1 etiketleri oluşturur.

Karışıklık matrisi oluşturulması için Şekil 4.39'daki kod bloğu çalıştırıldı.

Modelin tahmin çıktıları kullanılarak karışıklık matrisi oluşturulmuş, buradan TP (True Positive), FP (False Positive), TN (True Negative), FN (False Negative) değerleri hesaplanmıştır. Bu değerler üzerinden TPR (True Positive Rate) ve FPR (False Positive Rate) gibi metrikler elde edildi.

```
cm = confusion_matrix(y_true, y_pred)
```

Şekil 4.39. Karışıklık Matrisi Oluşumu.

y_true: Gerçek sınıf etiketleri (örneğin DEHB tanısı olup olmaması).

y_pred: Modelin 0.5 eşik değerine göre ürettiği tahmin etiketleri.

cm: 2x2 boyutunda bir matristir:

Tablo 4.3. Karışıklık Matrisi Oluşumu.

	Tahmin Pozitif (1)	Tahmin Negatif (0)
Gerçek Pozitif (1)	TP	FN
Gerçek Negatif (0)	FP	TN

sklearn'in confusion_matrix fonksiyonu sırayla [0, 1] sınıfına göre matris sıralar. Yani:

TP = cm[1, 1] , TN = cm[0, 0] , FP = cm[0, 1] , FN = cm[1, 0]

Temel değişkenlerin hesaplanabilmesi için Şekil 4.40'daki kod bloğu çalıştırıldı.

```
# TP, TN, FP, FN'yi al
TP = cm[1, 1] # Gerçek pozitif ve tahmin de pozitif
TN = cm[0, 0] # Gerçek negatif ve tahmin de negatif
FP = cm[0, 1] # Gerçek negatif ama tahmin pozitif
FN = cm[1, 0] # Gerçek pozitif ama tahmin negatif
```

Şekil 4.40. Değişkenlerin Tanımlanması.

TP = cm[1, 1] # Gerçek pozitif & doğru tahmin edilmiş

TN = cm[0, 0] # Gerçek negatif & doğru tahmin edilmiş

FP = cm[0, 1] # Gerçek negatif & yanlışlıkla pozitif tahmin edilmiş

FN = cm[1, 0] # Gerçek pozitif & yanlışlıkla negatif tahmin edilmiş

Bu dört değer sınıflandırma modelinin başarısını yorumlamak için temel girdilerdir.

TPR (True Positive Rate / Duyarlılık) değerinin hesaplanabilmesi için Şekil 4.41'deki kod bloğu çalıştırıldı.

```
# TPR (True Positive Rate) Hesapla
TPR = TP / (TP + FN)
print(f"True Positive Rate (TPR): {TPR:.2f}")
```

Şekil 4.41. TPR Değerinin Hesaplanması.

TPR (Recall veya Sensitivity): Gerçek pozitiflerin ne kadarının doğru şekilde tahmin edildiğini gösterir. Formül: $TPR = TP / (TP + FN)$

Tıbbi tanı sistemlerinde kritik bir metriktir. Örneğin DEHB gibi hastalıkların doğru saptanması için yüksek TPR önemlidir.

FPR (False Positive Rate) değerinin hesaplanabilmesi için Şekil 4.42'deki kod bloğu çalıştırıldı.

```
# FPR (False Positive Rate) Hesapla
FPR = FP / (FP + TN)
print(f"False Positive Rate (FPR): {FPR:.2f}")
```

Şekil 4.42. FPR Değerinin Hesaplanması.

FPR: Gerçekte negatif olan bireylerin ne kadarının yanlışlıkla pozitif sınıflandırıldığını gösterir. Formül: $FPR = FP / (FP + TN)$

Bu oran ne kadar düşükse model o kadar az "yanlış alarm" veriyor demektir.

Sonuçların yazdırılması, çıktıların alınabilmesi için Şekil 4.43'deki kod bloğu çalıştırıldı.

```
print("True Positive (TP):", TP)
print("False Positive (FP):", FP)
print("True Negative (TN):", TN)
print("False Negative (FN):", FN)
```

Şekil 4.43. Sonuçların Çıktılarının Alınması.

Her bir metriğin sayısal değeri terminal ekranına yazdırılır. Bu sayede kullanıcı modelin hangi sınıflandırma hatalarını daha sık yaptığını görsel olarak takip edebilir.

Bu analiz yöntemi, derin öğrenme tabanlı sınıflandırma sistemlerinin (örneğin YOLOv11 ile yapılan DEHB tespiti) doğruluk ve hata oranlarını ölçmek için yaygın olarak kullanılmaktadır. Karışıklık matrisi, sadece doğruluk (accuracy) değil aynı zamanda duyarlılık (sensitivity), özgüllük (specificity) ve hata oranları gibi kritik değerlendirme metriklerinin hesaplanmasını sağlar. Özellikle tıbbi görüntüleme gibi alanlarda TPR ve FPR oranları, modelin klinik anlamda güvenilirliğini değerlendirmek için anahtar metriklerdir.

Modelin eğitim, test ve değerlendirme süreçleri, Python programlama dilinde, Google COLAB üzerinden, sanal RAM ve Disk kapasitesi oluşturmaktadır. Ultralytics Python paketi sayesinde açık kaynaklı ve kullanımı kolay bir bilgisayarla nesne tespiti, görüntü sınıflandırma, segmentasyon ve poz tahmini (pose estimation) gibi görevlerde derin öğrenme modelleri eğitmek ve çalıştırmak için kullanılır.

Eğitim süreci, yüksek kapasiteli T4 GPU (NVIDIA CUDA desteği) kullanılarak hızlandırılmıştır.

4.7. YOLOv11 ile Geliştirilen Modelin Forest CNN ile Karşılaştırılması

Amaç (Purpose): Forest CNN temel olarak görüntü sınıflandırma yaparken, YOLO nesne tespiti yapıyor(Krizhevsky et al., 2017). Yani Forest CNN, bir görüntünün hangi sınıfa ait olduğunu tahmin ederken, YOLO görüntüdeki nesnelerin yerini (konumunu) da belirler (Redmon et al., 2016).

Girdi (Input): Forest CNN tek bir görüntü ile çalışırken, YOLO aynı görüntü içindeki birden fazla nesne ve bu nesnelerin konumlarını alır(Krizhevsky et al., 2017).

Çıktı (Output): Forest CNN sadece tek bir sınıf tahmini yaparken, YOLO birden fazla nesneyi ve bu nesnelerin koordinatlarını verir (Krizhevsky et al., 2012).

Çıktı Sayısı: Forest CNN 1 sınıf tahmini yaparken, YOLO çok sayıda nesne ve konum bilgisi çıkartıyor. Bu da YOLO'yu gerçek zamanlı nesne algılama için daha uygun hale getiriyor (Redmon et al., 2016).

Eğitim Veri Tipi: Forest CNN sadece görüntü ve sınıf etiketiyle eğitilirken, YOLO hem görüntü, bounding box (nesnenin koordinatları) hem de sınıf etiketi gerektiriyor. Bu, YOLO'nun daha ayrıntılı ve karmaşık eğitim verisi ihtiyacı olduğunu gösteriyor (Redmon et al., 2016).

Kullanım Alanı: Forest CNN genelde görüntü sınıflandırma, sağlık verileri ve yüz tanıma gibi uygulamalarda kullanılırken (Krizhevsky et al., 2012), YOLO nesne tespiti, video analizi, otonom araçlar ve güvenlik gibi gerçek zamanlı nesne takibi gereken alanlarda tercih ediliyor (Redmon et al., 2016).

Tablo 4.4. Forest CNN ile YOLO Özelliklerinin Karşılaştırılması.

Özellik	Forest CNN (Krizhevsky ve ark. (2012))	YOLO (You Only Look Once) (Redmon ve ark. (2016))
Amaç	Görüntü sınıflandırma (classification)	Nesne tespiti (object detection)
Girdi	Tek bir görüntü (etiketli)	Görüntü içindeki tüm nesneler ve konumları
Çıktı	Bir sınıf tahmini (örneğin “DEHB” veya “Kontrol”)	Her nesne için: sınıf + bounding box (x, y, w, h)
Çıktı Sayısı	1 sınıf	Çok sayıda nesne ve koordinat
Eğitim Veri Tipi	Görsel + sınıf etiketi (label)	Görsel + bounding box + sınıf etiketi
Kullanım Alanı	Görüntü sınıflandırma, sağlık verileri, yüz tanıma	Nesne tespiti, video analizi, otonom araçlar, güvenlik

4.7.1. Mimari ve İşleyiş Farkları

Yapı: Forest CNN’de CNN ile çıkarılan özellikler, sonrasında bir karar ağacı (ör. random forest) gibi modellerle sınıflandırılır. Bu yapı, hibrit (karma) bir modeldir (Sermanet & Lecun, 2011).YOLO’da ise End-to-end bir yapıya sahiptir. Yani, girdiden çıktıya kadar tüm işlemler tek bir sinir ağı içinde gerçekleşir (Z. Zhang & Sabuncu, 2018). Forest CNN modüler ve esnek olabilir, ancak YOLO’nun uçtan uca yapısı daha hızlı ve optimize bir çözüm sunar, özellikle gerçek zamanlı uygulamalarda.

Karar Verme: Forest CNN’de Özellikler CNN ile çıkarılır, sınıflandırma işlemi ensemble (ör. random forest) yöntemiyle yapılır (Sermanet & Lecun, 2011).YOLO’da ise tüm karar süreci tek bir CNN ağı içinde tamamlanır (Z. Zhang & Sabuncu, 2018). Forest CNN karar verme sürecini ikiye ayırırken (özellik çıkarımı ve karar), YOLO bu süreci entegre eder. Bu da YOLO'yu daha hızlı hale getirir.

Özellik Çıkarımı: Forest CNN’de CNN katmanları ile çıkarılan feature vector'ler daha sonra karar ağaçlarına verilir (Sermanet & Lecun, 2011). YOLO’da CNN katmanları nesne konumlarını (bounding box) doğrudan tahmin eder (Z. Zhang & Sabuncu, 2018). YOLO, sadece özellik çıkarımı yapmaz, aynı zamanda bu özelliklerden direkt nesne koordinatlarını çıkarır. Bu, onu nesne tespiti için daha özel ve optimize kılar.

Veri İhtiyacı: Forest CNN’de daha az veriyle çalışabilir, çünkü karar ağaçları küçük veri kümelerinde bile etkili olabilir (Breiman, 2001). YOLO’da doğru çalışması için büyük ve iyi etiketlenmiş veri setleri gerektirir (Redmon et al., 2016). Veri miktarı ve etiket kalitesi açısından YOLO daha yüksek bir baraj ister. Küçük veri setleriyle çalışacak projeler için Forest CNN daha uygun olabilir.


Donanım Gereksinimi: Forest CNN’de CPU ile de çalışabilir, düşük-orta seviye donanımlarda yeterlidir (Han J, 2011). YOLO’da özellikle GPU ile çalıştırıldığında yüksek performans verir; aksi halde yavaş olabilir (Redmon et al., 2016). YOLO, özellikle gerçek zamanlı uygulamalarda GPU gerektirirken, Forest CNN daha donanım-dostudur.

Tablo 4.5. Forest CNN-YOLO Mimari ve İşleyiş Farkları.

Özellik	Forest CNN	YOLO
Yapı	CNN + karar ağacı benzeri yapılar	Tek bir CNN mimarisi (end-to-end)
Karar Verme	Özellikler CNN ile çıkarılır, karar kısmı orman/ensemble yapar	Tüm işlem tek bir ağda yapılır
Özellik Çıkarımı	CNN katmanları + feature vector	CNN katmanları, doğrudan kutu tahmini yapar
Veri İhtiyacı	Görece daha az veri ile çalışabilir	Doğru çalışması için bol ve iyi etiketlenmiş veri gerekir
Donanım Gereksinimi	Düşük – orta seviye	GPU ile çalışması daha verimli

4.7.2. Forest CNN ile ROC Eğrisi ve Karışıklık Matrisi:

AUC değeri 0.64 çıkmaktadır. Bu AUC değeri 0.5 ile 1.0 arasında bir değerdir. Modelinizin sınıflar arasında ayırt etme gücünün orta düzeyde olduğunu gösterir. Rastgele bir model de $AUC = 0.5$ iken, bu model rastgele tahminden daha iyi ama mükemmel değil. Bu AUC değeri ile modelin tahminleri anlamlı, ama hâlâ iyileştirme yapılabilir.


**Şekil 4.44.** Forest CNN Algoritması ile ROC Eğrisi.

Turuncu Kesikli Çizgi: Rastgele tahmin eden modelin referans çizgisidir.

Mavi Eğri: Modelinizin çeşitli eşiklerdeki performansını gösteriyor.

Eğri genel olarak rastgele çizginin üzerinde kalıyor, bu da sınıfları ayırmada başarılı olduğunu gösterir

Yolo algoritmasında AUC değerimizi 0.75 olarak bulunmuştu. Bu durum Yolo algoritmasının daha hassas ve doğru çalıştığını göstermektedir.



Şekil 4.45. Forest CNN Algoritması ile Karışıklık Matrisi.

Karışıklık Matrisini incelediğimizde;

Test Doğruluk Oranı yaklaşık %68.75 Yolo Algoritmasında %72 çıkmıştı, Bu durum bizim Forest Algoritmasında modelimizin genel başarı oranının daha düşük Yolo algoritmasının daha yüksek olduğunu göstermektedir.

Hassasiyet Forest Algoritmamızda yaklaşık 0.508 gibi bir değer çıkmaktadır. Yolo algoritmamızda ise bu değer 0.74 çıkmaktadır. Bu durum Yolo algoritmasının daha hassas bir yapıya sahip olduğunu göstermektedir. Forest algoritmasına göre DEHB teşhisi konulanların yarısının aslında kontrol olduğunu göstermektedir.



5. SONUÇ VE ÖNERİLER

Bu çalışma, yapay zeka ve görüntü işleme tekniklerini kullanarak el yazılarını analiz ederek çocuklarda Dikkat Eksikliği Hiperaktivite Bozukluğunun (DEHB) ön teşhisini desteklemek için yeni ve pratik bir yaklaşım sunmaktadır. Genellikle öznel değerlendirmelere veya çocuk hastalar için zaman alıcı, pahalı ve zorlayıcı olabilen gelişmiş nörogörüntüleme teknolojilerine dayanan mevcut tanı uygulamalarının sınırlılıklarını kabul eden bu araştırma, düşük maliyetli, gelişimsel olmayan ve kolay uygulanabilir bir alternatif önermektedir.

Önerilen sistem, her çocuğun el yazısıyla yazdığı kısa bir cümleden yararlanarak erişilebilirlik ve uygulama kolaylığı açısından önemli bir ilerleme sağlamaktadır. Veri toplama sürecinin basitliği, geleneksel teşhis araçlarının pratik olmadığı veya kullanılmadığı okullarda, kliniklerde veya diğer çocuk merkezli ortamlarda kullanım için özellikle uygun hale getirmektedir. Model sadece uzman güdümlü analize olan bağımlılığı azaltmakla kalmayıp, aynı zamanda daha fazla profesyonel değerlendirme gerektirebilecek çocukları işaret eden bir erken uyarı sistemi olarak hizmet etme potansiyeline sahiptir.

El yazısının tanısasal bir ipucu olarak kullanılması, DEHB'li çocuklar tarafından sıklıkla sergilenen motor koordinasyon, dikkat düzenleme ve yürütücü işlevlerdeki gözlemlenebilir farklılıklara dayanmaktadır.

Bu ince ipuçlarını hesaplamalı analiz yoluyla yakalayan sistem, teşhis sürecine değerli bir nesnellik katmanı ekliyor. Ayrıca, el yazısı örneklerini hızlı bir şekilde işleme yeteneği, büyük ölçekli tarama ve erken müdahale stratejileri için yeni olanaklar sunmaktadır.

El yazısının tanısasal bir ipucu olarak kullanılması, DEHB'li çocuklar tarafından sıklıkla sergilenen motor koordinasyon, dikkat düzenleme ve yürütücü işlevlerdeki gözlemlenebilir farklılıklara dayanmaktadır. Bu ince ipuçlarını hesaplamalı analiz yoluyla yakalayan sistem, teşhis sürecine değerli bir nesnellik katmanı ekliyor. Ayrıca, el yazısı örneklerini hızlı bir şekilde işleme yeteneği, büyük ölçekli tarama ve erken müdahale stratejileri için yeni olanaklar sunmaktadır.

Mevcut bulgular umut verici olmakla birlikte, bu yaklaşım gelecekteki arařtırmalar için de zemin hazırlamaktadır. Daha büyük ve daha çeřitli veri kümeleri modelin saęlamlığını ve genelleřitirilebilirliğini daha da geliřtirebilir. Ayrıca, bu yöntemin dięer davranıřsal veya fizyolojik göstergelerle entegre edilmesi, tanısal doęruluęunu ve güvenilirliğini artırabilir.

Sonu olarak, bu alıřma DEHB'nin erken teřhisinde tamamlayıcı bir araç olarak yapay zeka destekli el yazısı analizinin potansiyelini vurgulamaktadır. Klinik iř akıřlarını arttırabilecek ve etkilenen bireylerin performansı için daha zamanında ve etkili müdahalelere katkıda bulunabilecek öleklenebilir, ocuk dostu bir özüm sunmaktadır.



KAYNAKÇA

- Aljalal, M., Aldosari, S. A., Molinas, M., AlSharabi, K., & Alturki, F. A. (2022). Detection of Parkinson's disease from EEG signals using discrete wavelet transform, different entropy measures, and machine learning techniques. *Scientific Reports*, 12(1). <https://doi.org/10.1038/S41598-022-26644-7>,
- Alsharif, N., Al-Adhaileh, M. H., Al-Yaari, M., Alsharif, N., Al-Adhaileh, M. H., & Al-Yaari, M. (2024). Diagnosis of attention deficit hyperactivity disorder: A deep learning approach. *AIMS Mathematics* 2024 5:10580, 9(5), 10580–10608. <https://doi.org/10.3934/MATH.2024517>
- American Psychiatric Association. (2013). Diagnostic and Statistical Manual of Mental Disorders. *Diagnostic and Statistical Manual of Mental Disorders*. <https://doi.org/10.1176/APPI.BOOKS.9780890425596>
- Andrews, H. C. ., & Hunt, B. R. (1977). *Digital image restoration*. 238.
- Asherson, P., Buitelaar, J., Faraone, S. V., & Rohde, L. A. (2016). Adult attention-deficit hyperactivity disorder: key conceptual issues. *The Lancet Psychiatry*, 3(6), 568–578. [https://doi.org/10.1016/S2215-0366\(16\)30032-3](https://doi.org/10.1016/S2215-0366(16)30032-3)
- Asil, E., & Rakıcıoğlu, N. (2013). Dikkat Eksikliği Hiperaktivite Bozukluğu ve Beslenme. *Beslenme ve Diyet Dergisi*, 41(2), 149–155.
- Asselborn, T., Gargot, T., Kidziński, Ł., Johal, W., Cohen, D., Jolly, C., & Dillenbourg, P. (2018). Automated human-level diagnosis of dysgraphia using a consumer tablet. *Npj Digital Medicine*, 1(1). <https://doi.org/10.1038/S41746-018-0049-X>,
- Aysev, A., & Öner, P. (2002). Çocuklukta Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısı Almış Olguların Ergenlik Dönemindeki Psikiyatrik Durumlarının İncelenmesi. *Kriz Dergisi*, 10(2), 41–48. https://doi.org/10.1501/Kriz_0000000181
- Azuma, R. T. (1997). A survey of augmented reality. *Presence: Teleoperators and Virtual Environments*, 6(4), 355–385. <https://doi.org/10.1162/PRES.1997.6.4.355>
- Barkley. (1997). *Barkley, R. A. (1997). ADHD and the nature of self-control*. New York Guilford Press. - References - Scientific Research Publishing. <https://www.scirp.org/reference/referencespapers?referenceid=534524>
- Barkley, R. A. (2015). *Attention-Deficit Hyperactivity Disorder A Handbook for Diagnosis and Treatment*. 4th Edition, The Guilford Press, New York. Scientific Research Publishing.
- Barry, R. J., Clarke, A. R., & Johnstone, S. J. (2003). A review of electrophysiology in attention-deficit/hyperactivity disorder: I. Qualitative and quantitative electroencephalography. *Clinical Neurophysiology*, 114(2), 171–183.

- Barry, R. J., Johnstone, S. J., & Clarke, A. R. (2003). A review of electrophysiology in attention-deficit/hyperactivity disorder: II. Event-related potentials. *Clinical Neurophysiology*, 114(2), 184–198.
- Baş, Ö., Tuncay, A. A., Şahin, A. E., & Gök, B. (2020). An Investigation Into Attention Deficit Hyperactivity Disorder-Diagnosed Elementary Students' Cursive Handwriting Skills. *Education and Science*, 45(201), 393–410. <https://doi.org/10.15390/EB.2019.8161>
- Berninger, V., Abbott, R., Cook, C. R., & Nagy, W. (2017). Relationships of Attention and Executive Functions to Oral Language, Reading, and Writing Skills and Systems in Middle Childhood and Early Adolescence. *Journal of Learning Disabilities*, 50(4), 434–449. <https://doi.org/10.1177/0022219415617167>,
- Berninger, V. W., Abbott, R. D., Abbott, S. P., Graham, S., & Richards, T. (2002). Writing and reading: Connections between language by hand and language by eye. *Journal of Learning Disabilities*, 35(1), 39–56. <https://doi.org/10.1177/002221940203500104>,
- Bilim Teknik*. (n.d.). Retrieved June 28, 2025, from https://bilimteknik.tubitak.gov.tr/makale/dikkat-eksikligi-ve-hiperaktivite-bozuklugu?utm_source=chatgpt.com
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. <https://arxiv.org/pdf/2004.10934>
- Bodla, N., Singh, B., Chellappa, R., & Davis, L. S. (2017). Soft-NMS - Improving Object Detection with One Line of Code. *Proceedings of the IEEE International Conference on Computer Vision, 2017-October*, 5562–5570. <https://doi.org/10.1109/ICCV.2017.593>
- Bovik. (2010). *Bovik, A.C. (2010) Handbook of Image and Video Processing. Academic Press, Massachusetts. - References - Scientific Research Publishing.* <https://www.scirp.org/reference/referencespapers?referenceid=2443069>
- Bovik, A. (2005). *Handbook of Image and Video Processing, Second Edition. Handbook of Image and Video Processing, Second Edition*, 1–1372. <https://doi.org/10.1016/B978-0-12-119792-6.X5062-1>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324/METRICS>
- Brookes, K. J., Mill, J., Guindalini, C., Curran, S., Xu, X., Knight, J., Chen, C. K., Huang, Y. S., Sethna, V., Taylor, E., Chen, W., Breen, G., & Asherson, P. (2006). A Common Haplotype of the Dopamine Transporter Gene Associated With Attention-Deficit/Hyperactivity Disorder and Interacting With Maternal Use of Alcohol During Pregnancy. *Archives of General Psychiatry*, 63(1), 74–81. <https://doi.org/10.1001/ARCHPSYC.63.1.74>
- Bush, G. (2011). Cingulate, Frontal and Parietal Cortical Dysfunction in Attention-Deficit/Hyperactivity Disorder. *Biological Psychiatry*, 69(12), 1160. <https://doi.org/10.1016/J.BIOPSYCH.2011.01.022>
- Bush, G., Valera, E. M., & Seidman, L. J. (2005). Functional Neuroimaging of Attention-Deficit/Hyperactivity Disorder: A Review and Suggested Future Directions. *Biological Psychiatry*, 57(11), 1273–1284. <https://doi.org/10.1016/J.BIOPSYCH.2005.01.034>

- Çak, H. T., Karaokur, R., Atasavun Uysal, S., Artik, A., Kabak, V. Y., Karakök, B., Şahan, N., Karaer, Y., Karabucak, B., Özusta, Ş., & Çengel Kültür, E. (2018). Motor proficiency in children with attention deficit hyperactivity disorder: Associations with cognitive skills and symptom severity. *Türk Psikiyatri Dergisi*, 29(2). <https://doi.org/10.5080/U22884>
- Carlat. (2014). *The New FDA-Approved EEG Test for ADHD: Should You Order It?* | 2014-12-01 | CARLAT PUBLISHING. <https://www.thecarlatreport.com/articles/2308-the-new-fda-approved-eeeg-test-for-adhd-should-you-order-it->
- Castellanos, F. X., Giedd, J. N., Marsh, W. L., Hamburger, S. D., Vaituzis, A. C., Dickstein, D. P., Sarfatti, S. E., Vauss, Y. C., Snell, J. W., Lange, N., Kaysen, D., Krain, A. L., Ritchie, G. F., Rajapakse, J. C., & Rapoport, J. L. (1996). Quantitative Brain Magnetic Resonance Imaging in Attention-Deficit Hyperactivity Disorder. *Archives of General Psychiatry*, 53(7), 607–616. <https://doi.org/10.1001/ARCHPSYC.1996.01830070053009>
- Castellanos, F. X., & Proal, E. (2012). Large-scale brain systems in ADHD: Beyond the prefrontal-striatal model. *Trends in Cognitive Sciences*, 16(1), 17–26. <https://doi.org/10.1016/j.tics.2011.11.007>
- Catherine Joy, R., Thomas George, S., Albert Rajan, A., & Subathra, M. S. P. (2022). Detection of ADHD From EEG Signals Using Different Entropy Measures and ANN. *Clinical EEG and Neuroscience*, 53(1), 12–23.
- Çelebi, F., & Ünal, D. (2019). KLİNİK BİR ÇOCUK-ERGEN ÖRNEKLEMİNDE DEHB İLİŞKİLİ YAŞAM KALİTESİNİN DEĞERLENDİRİLMESİ. *Zeynep Kamil Tıp Bülteni*, 50(2), 35–38. <https://doi.org/10.16948/ZKTIPB.495103>
- Chang, S. H., & Yu, N. Y. (2010). Characterization of motor control in handwriting difficulties in children with or without developmental coordination disorder. *Developmental Medicine and Child Neurology*, 52(3), 244–250.
- Cortese, S., Faraone, S. V., Konofal, E., & Lecendreux, M. (2009). Sleep in Children With Attention-Deficit/Hyperactivity Disorder: Meta-Analysis of Subjective and Objective Studies. *Journal of the American Academy of Child & Adolescent Psychiatry*, 48(9), 894–908. <https://doi.org/10.1097/CHI.0B013E3181AC09C9>
- Cutting, L. E., & Denckla, M. B. (2001). The relationship of rapid serial naming and word reading in normally developing readers: An exploratory model. *Reading and Writing*, 14(7–8), 673–705.
- De Silva, S., Dayarathna, S., Ariyaratne, G., Meedeniya, D., Jayarathna, S., Michalek, A. M. P., & Jayawardena, G. (2019). A Rule-Based System for ADHD Identification using Eye Movement Data. *MERCon 2019 - Proceedings, 5th International Multidisciplinary Moratuwa Engineering Research Conference*, 538–543. <https://doi.org/10.1109/MERCON.2019.8818865>
- Doğru, H. & Dursun, O. B. (2023). Dikkat Eksikliği ve Hiperaktivite Bozukluğu'nda Fonksiyonel Görüntülemenin Yeri. *CogEP Dergisi*, 153–159.

- Drotár, P., Mekyska, J., Rektorová, I., Masarová, L., Smékal, Z., & Faundez-Zanuy, M. (2016). Evaluation of handwriting kinematics and pressure for differential diagnosis of Parkinson's disease. *Artificial Intelligence in Medicine*, 67, 39–46.
- Durston, S., Tottenham, N. T., Thomas, K. M., Davidson, M. C., Eigsti, I. M., Yang, Y., Ulug, A. M., & Casey, B. J. (2003). Differential patterns of striatal activation in young children with and without ADHD. *Biological Psychiatry*, 53(10), 871–878. [https://doi.org/10.1016/S0006-3223\(02\)01904-2](https://doi.org/10.1016/S0006-3223(02)01904-2)
- Erdoğan, A. A. (2021). *Derin Öğrenme Yöntemi ile El Yazısı Tanıma*. Fen Bilimleri Enstitüsü. <https://hdl.handle.net/20.500.12452/7988>
- Everingham, M., Eslami, S. M. A., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2015). The Pascal Visual Object Classes Challenge: A Retrospective. *International Journal of Computer Vision*, 111(1), 98–136. <https://doi.org/10.1007/S11263-014-0733-5>/METRICS
- Faraone, S. V., Asherson, P., Banaschewski, T., Biederman, J., Buitelaar, J. K., Ramos-Quiroga, J. A., Rohde, L. A., Sonuga-Barke, E. J. S., Tannock, R., & Franke, B. (2015). Attention-deficit/hyperactivity disorder. *Nature Reviews Disease Primers*, 1. <https://doi.org/10.1038/NRDP.2015.20>
- Faraone, S. V., Larsson, • Henrik, & Org, S. (2018). Genetics of attention deficit hyperactivity disorder. *Molecular Psychiatry* 2018 24:4, 24(4), 562–575.
- Faraone, S. V., Sergeant, J., Gillberg, C., & Biederman, J. (2003). The worldwide prevalence of ADHD: is it an American condition? *World Psychiatry: Official Journal of the World Psychiatric Association (WPA)*, 2(2), 104–113. <http://www.ncbi.nlm.nih.gov/pubmed/16946911>%0Ahttp://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC1525089
- Faraone, S. V., SERGEANT, J., GILLBERG, C., & BIEDERMAN, J. (2003). The worldwide prevalence of ADHD: is it an American condition? *World Psychiatry*, 2(2), 104. <https://pmc.ncbi.nlm.nih.gov/articles/PMC1525089/>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/J.PATREC.2005.10.010>
- Fletcher, J. M., Lyon, G. R., Fuchs, L. S., & Barnes, M. A. (2018). Learning Disabilities: From Identification to Intervention. Second Edition. *Guilford Press*, 418. <https://www.guilford.com/books/Learning-Disabilities/Fletcher-Lyon-Fuchs-Barnes/9781462536375?srsId=AfmBOoo5t2abcsF0OZwHNbHzFu6JMoWjX3cChFM7yE4pQ3UgCzALK9nw>
- Franke, B., Michelini, G., Asherson, P., Banaschewski, T., Bilbow, A., Buitelaar, J. K., Cormand, B., Faraone, S. V., Ginsberg, Y., Haavik, J., Kuntsi, J., Larsson, H., Lesch, K. P., Ramos-Quiroga, J. A., Réthelyi, J. M., Ribases, M., & Reif, A. (2018). Live fast, die young? A review on the developmental trajectories of ADHD across the lifespan. *European Neuropsychopharmacology*, 28(10), 1059–1088. <https://doi.org/10.1016/J.EURONEURO.2018.08.001>
- Franke, B., Neale, B. M., & Faraone, S. V. (2009). Genome-wide association studies in ADHD. *Human Genetics*, 126(1), 13–50. <https://doi.org/10.1007/S00439-009-0663-4>,

- Fukunaga. (1990). *Fukunaga, K. (1990) Introduction to Statistical Pattern Recognition. 2nd Edition, Academic Press. - References - Scientific Research Publishing.*
<https://www.scirp.org/reference/referencespapers?referenceid=1611254>
- Ge, Z., Liu, S., Wang, F., Li, Z., & Sun, J. (2021). *YOLOX: Exceeding YOLO Series in 2021*. 5, 12. <https://arxiv.org/pdf/2107.08430>
- Geary, D. C. (2010). Mathematical disabilities: Reflections on cognitive, neuropsychological, and genetic components. *Learning and Individual Differences*, 20(2), 130–133. <https://doi.org/10.1016/J.LINDIF.2009.10.008>
- Ghanizadeh, A. (2010). Predictors of different types of developmental coordination problems in ADHD: The effect of age, gender, ADHD symptom severity and comorbidities. *Neuropediatrics*, 41(4), 176–181. <https://doi.org/10.1055/S-0030-1267962/ID/14/BIB>
- Gonzales, R.C, & Woods, R. . (2018). Digital Image Processing Digital Image Fundamental. *Radiologic Technology*.
- Goulardins, J. B., Marques, J. C. B., & De Oliveira, J. A. (2017). Attention Deficit Hyperactivity Disorder and Motor Impairment: A Critical Review. *Perceptual and Motor Skills*, 124(2), 425–440. <https://doi.org/10.1177/0031512517690607>,
- Graham, S., & Harris, K. R. . (2005). Writing Better: Effective Strategies for Teaching Students with Learning Difficulties. *Brookes Publishing Company*, 177.
- Hamdi, Y., Akouaydi, H., Boubaker, H., & Alimi, A. (2020). *Handwriting Quality Analysis using Online-Offline Models*. <https://doi.org/10.36227/TECHRXIV.13058366.V2>
- Hamstra-Bletz, L., & Blöte, A. W. (1993). A longitudinal study on dysgraphic handwriting in primary school. *Journal of Learning Disabilities*, 26(10), 689–699. <https://doi.org/10.1177/002221949302601007>,
- Han J, K. M. (2011). *Data Mining: Concepts and Techniques - Jiawei Han, Micheline Kamber, Jian Pei - Google Kitaplar*. https://books.google.com.tr/books/about/Data_Mining_Concepts_and_Techniques.html?id=pQws07tdpjoC&redir_esc=y
- Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29–36. <https://doi.org/10.1148/radiology.143.1.7063747>
- Hinshaw, S. P. (2017). Developmental Psychopathology as a Scientific Discipline. *Child and Adolescent Psychopathology, Third Edition*, 3–32. <https://doi.org/10.1002/9781394258932.ch1>
- Jähne, B. (2005). Digital image processing: 6th revised and extended edition. *Digital Image Processing: 6th Revised and Extended Edition*, 1–607.
- Jain, A. K. (1989). Fundamentals of digital image processing. Anil K. Jain. *Vision*, November, 569. https://books.google.com/books/about/Fundamentals_of_Digital_Image_Processing.html?hl=tr&id=GANSAAAAMAAJ
- Jain, R., Kasturi, R., & Schunck, B. G. . (1995). *Machine vision*. 549.

- Kalkanlı, Z. G., Ünübol, H., & Ülker, S. V. (2024). Use of Distraction Continuous Performance Test and Eye Tracking Integration in the Evaluation of Attention Deficit Hyperactivity Disorder. *Cyprus Turkish Journal of Psychiatry and Psychology*, 6(4), 303–312. <https://doi.org/10.35365/ctjpp.24.4.01>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/J.COMPAG.2018.02.016>
- Kaplan Kılıç, B., Bumin, G., & Öğütü, H. (2025). Effect of Telerehabilitation on Handwriting Performance in Children With Attention Deficit Hyperactivity Disorder: Randomized Controlled Trial. *Child: Care, Health and Development*, 51(2). <https://doi.org/10.1111/CCH.70055>,
- Kara, H. (2014). Dikkat Eksikliği Hiperaktivite Bozukluğu olan çocuklarda karşıt olma karşı gelme bozukluğu binişikliğinin duygusal yüz ifadelerinin tanınması ile ilişkisi. *Yüksek Lisans Tezi, GATA*.
- Khosla, M., Jamison, K., Ngo, G. H., Kuceyeski, A., & Sabuncu, M. R. (2019). Machine learning in resting-state fMRI analysis. *Magnetic Resonance Imaging*, 64, 101–121. <https://doi.org/10.1016/J.MRI.2019.05.031>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25. <http://code.google.com/p/cuda-convnet/>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/NATURE14539>
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8693 LNCS(PART 5), 740–755.
- Linnet, K. M., Dalsgaard, S., Obel, G., Wisborg, K., Henriksen, T. B., Rodriguez, A., Kotimaa, A., Moilanen, I., Thomsen, P. H., Olsen, J., & Jarvelin, M. R. (2003). Maternal lifestyle factors in pregnancy risk of attention deficit hyperactivity disorder and associated behaviors: Review of the current evidence. *American Journal of Psychiatry*, 160(6), 1028–1040. <https://doi.org/10.1176/APPI.AJP.160.6.1028>
- Lisa L Weyandt. (2007). Book Review: Barkley, R. A. (2006). Attention-Deficit Hyperactivity Disorder: A Handbook for Diagnosis and Treatment (3rd ed.). New York: Guilford. *Journal of Attention Disorders*, 11(2), 179–180. <https://doi.org/10.1177/1087054707305334>
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path Aggregation Network for Instance Segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 8759–8768.

- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9905 LNCS, 21–37. https://doi.org/10.1007/978-3-319-46448-0_2
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. *Proceedings of the IEEE International Conference on Computer Vision*, 9992–10002. <https://doi.org/10.1109/ICCV48922.2021.00986>
- Lohani, D. C., Chawla, V., & Rana, B. (2025). A systematic literature review of machine learning techniques for the detection of attention-deficit/hyperactivity disorder using MRI and/or EEG data. *Neuroscience*, 570, 110–131.
- Lyon, G. R., Shaywitz, S. E., & Shaywitz, B. A. (2003). A Definition of Dyslexia. *Annals of Dyslexia*, 53, 1–14. <https://doi.org/10.1007/S11881-003-0001-9>
- Mao, Y., Qi, X., He, L., Wang, S., Wang, Z., & Wang, F. (2025). Advanced machine learning techniques reveal multidimensional EEG abnormalities in children with ADHD: a framework for automatic diagnosis. *Frontiers in Psychiatry*, 16, 1475936. <https://doi.org/10.3389/FPSYT.2025.1475936>
- Marr, D., & Hildreth, E. (1980). Theory of edge detection. *Proceedings of the Royal Society of London - Biological Sciences*, 207(1167), 187–217. <https://doi.org/10.1098/RSPB.1980.0020>
- Mash, E. J. ., & Barkley, R. A. . (2003). *Child Psychopathology, Second Edition*. 802.
- Meyer, A., & Sagvolden, T. (2006). Fine motor skills in South African children with symptoms of ADHD: Influence of subtype, gender, age, and hand dominance. *Behavioral and Brain Functions*, 2(1), 1–13. <https://doi.org/10.1186/1744-9081-2-33/TABLES/3>
- Millichap, J. G., & Yee, M. M. (2012). The Diet Factor in Attention-Deficit/Hyperactivity Disorder. *Pediatrics*, 129(2), 330–337. <https://doi.org/10.1542/PEDS.2011-2199>
- Mohammadi, M. R., Khaleghi, A., Nasrabadi, A. M., Rafieivand, S., Begol, M., & Zarafshan, H. (2016). EEG classification of ADHD and normal children using non-linear features and neural network. *Biomedical Engineering Letters*, 6(2), 66–73. <https://doi.org/10.1007/S13534-016-0218-2/METRICS>
- Munoz, D. P., Armstrong, I. T., Hampton, K. A., & Moore, K. D. (2003). Altered control of visual fixation and saccadic eye movements in attention-deficit hyperactivity disorder. *Journal of Neurophysiology*, 90(1), 503–514. <https://doi.org/10.1152/JN.00192.2003>,
- Nobukawa, S., Shirama, A., Takahashi, T., Takeda, T., Ohta, H., Kikuchi, M., Iwanami, A., Kato, N., & Toda, S. (2021). Identification of attention-deficit hyperactivity disorder based on the complexity and symmetricity of pupil diameter. *Scientific Reports*, 11(1), 1–14.
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & Da Silva, E. A. B. (2021). A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics* 2021, Vol. 10, Page 279, 10(3), 279. <https://doi.org/10.3390/ELECTRONICS10030279>

- Petrou, M., & Petrou, C. (2011). Image Processing: The Fundamentals: Second Edition. *Image Processing: The Fundamentals: Second Edition*. <https://doi.org/10.1002/9781119994398>
- Piek, J. P., Pitcher, T. M., & David A, H. (1999). Motor coordination and kinaesthesia in boys with attention deficit-hyperactivity disorder. *Developmental Medicine and Child Neurology*, 41(3), 159–165. <https://doi.org/10.1017/S0012162299000341>,
- Pitas, I. (2000). *Digital image processing algorithms and applications*. 419.
- Plamondon, R., & Srihari, S. N. (2000). On-line and off-line handwriting recognition: A comprehensive survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1), 63–84. <https://doi.org/10.1109/34.824821>
- Pliszka, S. R. (2007). Pharmacologic treatment of attention-deficit/hyperactivity disorder: Efficacy, safety and mechanisms of action. *Neuropsychology Review*, 17(1), 61–72. <https://doi.org/10.1007/S11065-006-9017-3>
- Powers, D. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63. <https://researchnow.flinders.edu.au/en/publications/evaluation-from-precision-recall-and-f-measure-to-roc-informednes>
- Pratt, W. K. . (2007). *Digital image processing : PIKS Scientific inside*. 782.
- Puyjarinet, F., Chaix, Y., & Biotteau, M. (2024). Is There a Deficit in Product and Process of Handwriting in Children with Attention Deficit Hyperactivity Disorder? A Systematic Review and Recommendations for Future Research. *Children*, 11(1). <https://doi.org/10.3390/CHILDREN11010031>,
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*. <https://arxiv.org/pdf/1804.02767>
- Rehman, A., Heldal, I., & Lin, J. C.-W. (2025). *SSRepL-ADHD: Adaptive Complex Representation Learning Framework for ADHD Detection from Visual Attention Tasks*. <https://arxiv.org/pdf/2502.00376>
- Riaz, A., Asad, M., Alonso, E., & Slabaugh, G. (2020). DeepFMRI: End-to-end deep learning for functional connectivity and classification of ADHD using fMRI. *Journal of Neuroscience Methods*, 335.
- Richards, J. A., & Jia, X. (2006). Remote sensing digital image analysis: An introduction. *Remote Sensing Digital Image Analysis: An Introduction*, 1–439. <https://doi.org/10.1007/3-540-29711-1>
- Rosenblum, S., Aloni, T., & Josman, N. (2010). Relationships between handwriting performance and organizational abilities among children with and without dysgraphia: A preliminary study. *Research in Developmental Disabilities*, 31(2), 502–509. <https://doi.org/10.1016/J.RIDD.2009.10.016>

- Rosenblum, S., & Livneh-Zirinski, M. (2008). Handwriting process and product characteristics of children diagnosed with developmental coordination disorder. *Human Movement Science*, 27(2), 200–214. <https://doi.org/10.1016/j.humov.2008.02.011>
- Rosenblum, S., Parush, S., & Weiss, P. L. (2003). Computerized temporal handwriting characteristics of proficient and non-proficient handwriters. *American Journal of Occupational Therapy*, 57(2), 129–138. <https://doi.org/10.5014/AJOT.57.2.129>,
- Rubia, K. (2018). Cognitive Neuroscience of Attention Deficit Hyperactivity Disorder (ADHD) and Its Clinical Translation. *Frontiers in Human Neuroscience*, 12, 100. <https://doi.org/10.3389/FNHUM.2018.00100>
- Sally E. Shaywitz. (n.d.). *Overcoming Dyslexia : A New and Complete Science-Based Program for Reading Problems at Any Level / S. Shaywitz*. Retrieved June 23, 2025,
- Sarigedik, E. (2024). Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısının Makine Öğrenimi Yöntemleri ile Konulması: Sistemik Bir Derleme. *Turkish Journal of Child and Adolescent Mental Health*, 31(3), 179–185. <https://doi.org/10.4274/TJCAMH.GALENOS.2022.02486>
- Sergeant, J. A., Geurts, H., & Oosterlaan, J. (2002). How specific is a deficit of executive functioning for attention-deficit/hyperactivity disorder? *Behavioural Brain Research*, 130(1–2), 3–28. [https://doi.org/10.1016/S0166-4328\(01\)00430-2](https://doi.org/10.1016/S0166-4328(01)00430-2)
- Sermanet, P., & Lecun, Y. (2011). Traffic sign recognition with multi-scale convolutional networks. *Proceedings of the International Joint Conference on Neural Networks*, 2809–2813. <https://doi.org/10.1109/IJCNN.2011.6033589>
- Serra, J. (1988). *Image Analysis and Mathematical Morphology, Vol. 1(1982) & Vol. 2 (1988)*. https://books.google.com/books/about/Image_Analysis_and_Mathematical_Morphology.html?hl=tr&id=QJMoAQAAMAAJ
- Shaw, P., Eckstrand, K., Sharp, W., Blumenthal, J., Lerch, J. P., Greenstein, D., Clasen, L., Evans, A., Giedd, J., & Rapoport, J. L. (2007). Attention-deficit/hyperactivity disorder is characterized by a delay in cortical maturation. *Proceedings of the National Academy of Sciences of the United States of America*, 104(49), 19649–19654. <https://doi.org/10.1073/PNAS.0707741104>
- Shaw, P., Stringaris, A., Nigg, J., & Leibenluft, E. (2014). Emotion dysregulation in attention deficit hyperactivity disorder. *American Journal of Psychiatry*, 171(3), 276–293. <https://doi.org/10.1176/APPI.AJP.2013.13070966>,
- Shin, J., Maniruzzaman, M., Uchida, Y., Hasan, M. A. M., Megumi, A., & Yasumura, A. (2023). Handwriting-Based ADHD Detection for Children Having ASD Using Machine Learning Approaches. *IEEE Access*, 11, 84974–84984. <https://doi.org/10.1109/ACCESS.2023.3302903>
- Snowling, M. J., & Hulme, C. (2012). Interventions for children’s language and literacy difficulties. *International Journal of Language and Communication Disorders*, 47(1), 27–34. <https://doi.org/10.1111/J.1460-6984.2011.00081.X>

- Sonka. (2014). *Sonka, M., Hlavac, V. and Boyle, R. (2014) Image Processing, Analysis, and Machine Vision. Cengage Learning, 875. - References - Scientific Research Publishing.*
<https://www.scirp.org/reference/referencespapers?referenceid=2152181>
- Sözen, D. T., & Yücel, D. Ö. T. (2010). İntraoperatif Manyetik Rezonans Görüntüleme. *Türkiye Klinikleri Kulak Burun Boğaz - Özel Konular*, 3(4), 6–9.
<https://www.turkiyeklinikleri.com/article/tr--ntraoperatif-manyetik-rezonans-goruntuleme-59572.html>
- Stein, M. A., Snyder, S. M., Rugino, T. A., & Hornig, M. (2016). Commentary: Objective aids for the assessment of ADHD - Further clarification of what FDA approval for marketing means and why NEBA might help clinicians. A response to Arns et al. (2016). *Journal of Child Psychology and Psychiatry and Allied Disciplines*, 57(6), 770–771. <https://doi.org/10.1111/JCPP.12534>,
- Szeliski. (2010). *Szeliski, R. (2010) Computer Vision Algorithms and Applications. Springer, London, UK. - References - Scientific Research Publishing.*
<https://www.scirp.org/reference/referencespapers?referenceid=2655269>
- Tan, M., Pang, R., & Le, Q. V. (2020). EfficientDet: Scalable and efficient object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 10778–10787.
- Theodoridis. (2008). *Theodoridis, S. and Koutroumbas, K. (2008) Pattern Recognition. 4th Edition, Academic Press, Cambridge. - References - Scientific Research Publishing.*
<https://www.scirp.org/reference/referencespapers?referenceid=3570363>
- Tian, Z., Shen, C., Chen, H., & He, T. (2019). FCOS: Fully Convolutional One-Stage Object Detection (pp. 9627–9636).
- Tucha, O., Mecklinger, L., Laufkötter, R., Klein, H. E., Walitza, S., & Lange, K. W. (2006). Methylphenidate-induced improvements of various measures of attention in adults with Attention Deficit Hyperactivity Disorder. *Journal of Neural Transmission*, 113(10), 1575–1592. <https://doi.org/10.1007/S00702-005-0437-7>,
- Ulu Ercan, E. (2018). Çocuk Ve Ergenlerde Dikk Eksikliği Hiperaktivite Bozukluğu Ve Saldırganlık. *Sinop Üniversitesi Sosyal Bilimler Dergisi*, 2(2), 149–164.
<https://doi.org/10.30561/sinopusd.451204>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2023-June, 7464–7475.
<https://doi.org/10.1109/CVPR52729.2023.00721>
- Wang, C. Y., Yeh, I. H., & Liao, H. Y. M. (2023). You Only Learn One Representation: Unified Network for Multiple Tasks. *Journal of Information Science and Engineering*, 39(3), 691–709.
[https://doi.org/10.6688/JISE.202305_39\(3\).0015](https://doi.org/10.6688/JISE.202305_39(3).0015)
- Yin, W., Li, L., & Wu, F. X. (2022). Deep learning for brain disorder diagnosis based on fMRI images. *Neurocomputing*, 469, 332–345.
<https://doi.org/10.1016/J.NEUCOM.2020.05.113>

- Yu, L., Zhou, F., & Wan, J. (2025). A dual path deep framework integrated with fuzzy random vector functional link for ADHD detection from fMRI data. *Signal, Image and Video Processing* 2025 19:10, 19(10), 1–14. <https://doi.org/10.1007/S11760-025-04383-2>
- Zhang, L., Wang, M., Liu, M., & Zhang, D. (2020). A Survey on Deep Learning for Neuroimaging-based Brain Disorder Analysis. *Machine Learning and Deep Learning in Neuroimaging Data Analysis*, 57–72. <https://doi.org/10.1201/9781003264767-4>
- Zhang, S., Chi, C., Yao, Y., Lei, Z., & Li, S. Z. (2020). Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 9756–9765.
- Zhang, Z., & Sabuncu, M. R. (2018). Generalized Cross Entropy Loss for Training Deep Neural Networks with Noisy Labels. *Advances in Neural Information Processing Systems*, 31.
- Zylowska, L., Ackerman, D. L., Yang, M. H., Futrell, J. L., Horton, N. L., Hale, T. S., Pataki, C., & Smalley, S. L. (2008). Mindfulness meditation training in adults and adolescents with ADHD: A feasibility study. *Journal of Attention Disorders*, 11(6), 737–746. <https://doi.org/10.1177/1087054707308502>,



ÖZGEÇMİŞ

Ad-Soyad : Özlem YILDIZ BUDAK

ÖĞRENİM DURUMU:

- **Lise** :2005, Bahçelievler Siyavuşpaşa Anadolu Meslek Lisesi, Bilgisayar
- **Önlisans** : 2007, İstanbul Ticaret Üniversitesi M.Y.O , Bilgisayar Teknolojisi ve Prog
- **Lisans** : 2011, Marmara Üniversitesi, Teknik Eğitim Fakültesi, Bilgisayar ve Kontrol Öğrt.
- **Yükseklisans** : 2025, Sakarya Üniversitesi, Fen Bilimleri Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- ICHORA 2025 7. International Congress on Human-Computer Interaction, Optimization and Robotic Applicatin, “A Novel Approach to ADHD Detection Using Handwriting and Image Processing” başlıklı bildirinin sözlü sunumu.
- 2025 yılında Tübitak Proje Yürütücüsü-Koordinatörü olarak çalıştı.
- 2025 yılında Tübitak Bilişim Söyleşilerinde Yürütücü olarak çalıştı.
- 2022 yılında Milli Eğitim Bakanlığı Tarafından Haziran ayında Başarı Belgesi alındı.
- 2022 yılında Milli Eğitim Bakanlığı tarafından Ocak ayında Başarı Belgesi alındı.
- 2014’den itibaren Milli Eğitim Bakanlığı’nda Bilişim Teknolojileri Öğretmeni olarak görev yapmaktadır.
- 2012-2014 yılları arasına Atm Dış Tic ve Paz.’ da Yazılım Uzmanı olarak çalıştı.
- 2011-2012 yılları arasında Zeynep Tekstil’de Bilgi İşlem Departmanında Yazılım Uzmanı olarak çalıştı.
- 2009-2009 yılları arasında Nar Yazılımda Stajyer olarak görev aldı.
- 2009-2009 yılları arasında Siyavuşpaşa Anadolu Meslek Lisesi’nde Bilgisayar Öğretmeni olarak görev aldı.
- 2008 yılında ÖSYM ‘nin DGS sınavında Türkiye 222. olarak başarı sıralamasına girildi.