



T.C.

BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**GELİŞİM ÇAĞINDAKİ ÇOCUKLARIN EL YAZISI GÖRÜNTÜLERİNDEN HARF
DÜZEYİNDE DİSLEKSİ BELİRTİLERİNİN TESPİTİ**

YÜKSEK LİSANS TEZİ

RUMEYSA AYDEMİR

TEZ DANIŞMANI
PROF. DR. AHMET AKBAŞ

BİLECİK, 2026

10792448

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĐİ TEZLİ YÜKSEK LİSANS PROGRAMI

**GELİŐİM ÇAĐINDAKİ ÇOCUKLARIN EL YAZISI GÖRÜNTÜLERİNDEN HARF
DÜZEYİNDE DİSLEKSİ BELİRTİLERİNİN TESPİTİ**

YÜKSEK LİSANS TEZİ

RUMEYSA AYDEMİR

TEZ DANIŐMANI
PROF. DR. AHMET AKBAŐ

BİLECİK, 2026

10792448

BEYAN

“Gelişim Çağındaki Çocukların El Yazısı Görüntülerinden Disleksi Belirtilerinin Tespiti” başlıklı yüksek lisans tezinin hazırlık ve yazım aşamasında bilimsel araştırma ve etik kurallarına uyduğumu, [Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Faaliyetlerinde Üretken Yapay Zekâ Kullanımına Dair Etik Rehberine](#) uygun olarak tez/dönem projemi hazırladığımı, başkalarının eserlerinden yararlandığım bölümlerde bilimsel etik kurallarına uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, çalışmamın herhangi bir kısmının başka bir tez/dönem projesi olarak sunulmadığını, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Rumeysa Aydemir

.././2026

İmza:

ÖN SÖZ

Bu tez çalışmasının her aşamasında bilgi, tecrübe, hoşgörü ve anlayışla desteğini esirgemeyen, yol gösterici, çalışmamı sahiplenerek takip eden ve sabırla katlanıp emeği geçen yüksek lisans tez danışmanım saygıdeğer Prof. Dr. Ahmet AKBAŞ'a katkı ve emekleri için teşekkür ve şükranlarımı sunarım.

Çalışma boyunca desteklerini hissettiren Bilecik Şeyh Edebali Üniversitesi ailesine, bilhassa Mühendislik Fakültesi'nde görev yapan değerli hocam Dr. Hakan ÜÇGÜN ve diğer öğretim üyelerine teşekkür ederim.

Tez savunma sürecinde yapıcı geri bildirimleri ve katkılarıyla çalışmanın geliştirilmesine önemli katkılarda bulunan kıymetli jüri üyelerine saygı ve teşekkürlerimi arz ederim.

Akademik gelişimime katkıda bulunan, bilgi ve deneyimleriyle bu süreci anlamlı kılan tüm hocalarıma, ayrıca desteğini her zaman yanımda hissettiğim aileme, maddi ve manevi desteğini esirgemeyen, beni her zaman cesaretlendiren sevgili hayat arkadaşım Erkan AYDEMİR'e teşekkür eder, bu çalışmanın biricik yavrum Osman Mahmud AYDEMİR'e eğitim hayatında ışık olmasını dilerim.

Veri temini ve teknik konularda katkı sağlayan tüm kurum ve kişilere teşekkür eder, bu çalışmanın disleksi teşhisi ile eğitim sürecini iyileştirmeyi amaçlayan araştırmacılar ve uygulayıcılar için yararlı bir kaynak olmasını temenni ederim.

Rumeysa AYDEMİR
2026

ÖZET

Bu çalışmada, el yazısı görüntülerinden harf düzeyinde disleksi belirtilerini tespit etmek için YOLOv8n derin öğrenme modeline dayalı bir sınıflandırma yaklaşımı önerilmiş ve 5-katlı eğitim ve çapraz doğrulama yöntemi ile test edilmiştir.

Bu amaçla kullanılan veri seti, YOLO biçiminde harf kutuları ve sınıf etiketlerini (Normal, Ters, Düzeltilmiş) içeren görüntülerden oluşmaktadır. Beş katlı çapraz doğrulama testlerinin her katı için hesaplanan karmaşıklık matrisleri ve sınıf başına kesinlik, hatırlama, mAP@50 ve mAP50–95 değerleri, önerilen modelin el yazısı görüntülerinde harf nesnelerinin sınırlarını ve disleksi paternlerini yüksek bir doğrulukla belirlediğini göstermektedir.

Bu yaklaşım, veri etiketleme düzeyi ile aynı düzlemde çalışan harf düzeyinde bir boru hattı kurarak, sonuçları sınıf ve kat bazında ayrıntılı raporlamakta ve konumlandırılmış çıktılarla disleksi tedavisi ile ilgili eğitim süreçlerine geri bildirim yapma imkânı sunmaktadır.

Anahtar Kelimeler: El yazısı görüntüsü, harf düzeyinde nesne algılama, nesne sınırlama, özellik çıkarma, disleksi belirtisi, harf sınıflandırma, YOLOv8n.

ABSTRACT

In this study, a classification approach based on the YOLOv8n deep learning model to detect dyslexia symptoms at the letter level in handwritten images is proposed and evaluated using a five-fold cross-validation method.

The dataset used for this purpose consists of images containing letter boxes and class labels (Normal, Inverse, Corrected) in the YOLO format. The correlation matrices calculated for each fold of the five-fold cross-validation tests, along with per-class precision, recall, mAP@50, and mAP50–95 values, demonstrate that the proposed model identifies and localizes letter-level dyslexic patterns in handwriting images with high accuracy.

This approach establishes a letter-level pipeline that operates in tandem with the data-labeling level, reporting detailed results at the class and fold level. Localized outputs facilitate feedback into the training processes necessary for dyslexia treatment.

Keywords: Handwriting image, letter-level object detection, object localization, feature extraction, dyslexia symptoms, letter classification, YOLOv8n.

İÇİNDEKİLER

Sayfa

ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vi
KISALTMALAR VE SİMGELER LİSTESİ	vii
1. ÖĞRENME GÜÇLÜĞÜ	1
1.1. Disgrafi ve Disleksi	1
1.2. Öğrenme Güçlüğü Tanısı.....	2
1.3. El Yazısı Görüntülerinde Disleksi Belirtilerinin Tespiti.....	4
2. LİTERATÜR ARAŞTIRMASI.....	6
2.1. El Yazısı Görüntülerinden Yapay Zekâ ile Disleksi Tanıma Yaklaşımları	6
2.1.1. Klasik Öznitelik Çıkarımı ile ML Esash Sınıflandırma	6
2.1.2. Sayfa ve Parça Bazında DL Esash Sınıflandırma	6
2.1.3. Kelime ve Harf Düzeyinde Nesne Çevrelemeli Sınıflandırma	7
2.2. Literatürdeki Yaklaşımların Sınırlılıkları ve Çalışmanın Konumlandırılması	8
3. MATERYAL VE YÖNTEM.....	9
3.1. Veri Seti	9
3.2. YOLOv8 Nesne Algılama ve Tanıma Modeli.....	11
4. 5-KATLI EĞİTİM VE DOĞRULAMA TESTLERİ.....	18
4.1. Eğitim ve Test Süreçleri	18
4.2. Test Sonuçları	21
5. TARTIŞMA VE SONUÇ	28
KAYNAKÇA	32

TABLÖLAR LİSTESİ

Tablo 3.1. YOLOv8'in farklı modelleri için performans metrikleri	12
Tablo 4.1. 5-katlı çapraz doğrulamada birinci katın test sonuçları.	22
Tablo 4.2. 5-katlı çapraz doğrulamada ikinci katın test sonuçları.....	23
Tablo 4.3. 5-katlı çapraz doğrulamada üçüncü katın test sonuçları.	24
Tablo 4.4. 5-katlı çapraz doğrulamada dördüncü katın test sonuçları.....	25
Tablo 4.5. 5-katlı çapraz doğrulamada beşinci katın test sonuçları.....	26
Tablo 4.6. 5-katlı çapraz doğrulama testlerinin toplu sonuçları.	27

ŞEKİLLER LİSTESİ

Şekil 3. 1. Aynı harfe ait üç farklı sınıftaki görüntü örnekleri (Patil vd., 2024).....	9
Şekil 3.2. Sentetik veri setinden eğitim ve doğrulama görüntüsü örnekleri (Zenodo, 2025) ..	10
Şekil 3.3. YOLOv8 Nesne Tanıma modeli (Yaseen, 2024).....	11
Şekil 3.4. YOLOv8 FPN mimarisinin farklı düzenlenme alternatifleri.	12
Şekil 3.5. YOLOv8 eğitim sürecinde karma hassasiyet kullanımı (İsa vd., 2023).....	13
Şekil 4.1. Eğitim ve doğrulama testleri için yapılan parametre ayarları.....	19
Şekil 4.2. 5-katlı testlerin birinci katında elde edilen performans eğrileri.....	19
Şekil 4.3. 5-katlı testlerin ikinci katında elde edilen performans eğrileri.	19
Şekil 4.4. 5-katlı testlerin üçüncü katında elde edilen performans eğrileri.....	20
Şekil 4.5. 5-katlı testlerin dördüncü katında elde edilen performans eğrileri.	20
Şekil 4.6. 5-katlı testlerin beşinci katında elde edilen performans eğrileri.....	21
Şekil 4.7. Karmaşıklık matrisi hesaplamaları için kullanılan fonksiyonlar.....	21
Şekil 4.8. 5-katlı doğrulama testlerinde birinci katın karmaşıklık matrisi.....	22
Şekil 4.9. 5-katlı doğrulama testlerinde ikinci katın karmaşıklık matrisi.	23
Şekil 4.10. 5- katlı doğrulama testlerinde üçüncü katın karmaşıklık matrisi.....	24
Şekil 4.11. 5-katlı doğrulama testlerinde dördüncü katın karmaşıklık matrisi.	25
Şekil 4.12. 5-katlı doğrulama testlerinde beşinci katın karmaşıklık matrisi.	26

KISALTMALAR VE SİMGELER LİSTESİ

ADASYN: Adaptive Synthetic (Uyarlanabilir Sentetik Örneklem)

BHK: Brave Handwriting Kinder (Cesur El Yazısı Testi (Çocuklar için))

CNN: Convolutional Neural Network (Evrışimsel Sinir Ağı)

CSPNet: Cross Stage Partial Network (Çapraz Aşamalı Kısmi Ağ)

CUDA: Compute Unified Device Architecture (Birleşik Hesaplama Cihazı Mimarisi)

CVAT: Computer Vision Annotation Tool (Bilgisayarlı Görü Açıklama Aracı)

DDBIC: Disgrafi ve Disleksi Davranışsal Gösterge Listesi

DL: Deep Learning (Derin Öğrenme)

EEG: Elektroensefalografi

EOG: Elektrokülografi

fMRI: Functional Magnetic Resonance Imaging (İşlevsel Manyetik Rezonans Görüntüleme)

FN: False Negative (Yanlış Negatif)

FP: False Positive (Yanlış Pozitif)

FPN: Feature Pyramid Network (Özellik Piramidi Ağı)

GPU: Graphics Processing Unit (Grafik İşlem Birimi)

IoU: Intersection over Union (Birleşim Üzerinden Kesişim)

LSTM: Long Short Term Memory (Uzun Kısa Süreli Bellek)

mAP: Mean Average Precision (Ortalama Kesinlik)

ML: Machine Learning (Makine Öğrenmesi)

NIRS: Near-infrared Spektroskopi (Yakın Kızılötesi Spektroskopi)

NIST: National Institute of Standards and Technology (Ulusal Standartlar ve Teknoloji Enstitüsü)

P: Precision (Kesinlik)

R: Recall (Hatırlama (Duyarlılık))

RF Algorithm: Random Forest (Rastgele Orman Algoritması)

SMOTE: Synthetic Minority Over-sampling Technique (Sentetik Azınlık Aşırı Örnekleme Tekniği)

SVM: Support Vector Machine (Destek Vektör Makinesi)

TN: True Negative (Doğru Negatif)

TP: True Positive (Doğru Pozitif)

VoTT: Visual Object Tagging Tool (Görsel Nesne Etiketleme Aracı)

YAML: Yet Another Markup Language (Bir Başka İşaretleme Dili)

YOLO Model: You Only Look Once

1. ÖĞRENME GÜÇLÜĞÜ

Öğrenme güçlüğü, konuşma veya yazı dilini anlama için gerekli psikolojik süreçleri etkileyen ve dinleme, konuşma, okuma, yazma veya matematiksel hesaplamaları tamamlamada zorluklara neden olabilen nörogelişimsel bir bozukluktur (IDEA,2004). Bu tür zorluklar, dünya çocuk nüfusunun yaklaşık %10'unu etkilemektedir (Kunhoth vd., 2024). Bu kapsamda zayıf motor beceriler ve motor koordinasyon sorunları nedeniyle ortaya çıkan yazma sorunları, öğrenmenin yanı sıra düşünceleri iletme ve duyguları ifade etme gibi temel ihtiyaçların karşılanmasına da engel olduğundan, bireylerin ilerleyen yaşlardaki sosyal başarı ve akademik performansının düşmesine neden olmaktadır (Graham vd., 2012). Literatürde öğrenme güçlüğü ile ilgili araştırmalar kısaca yazma engeli olarak da bilinen disgrafi ve okuma engeli olarak da bilinen disleksi kavramları ile kategorize edilmektedir.

1.1. Disgrafi ve Disleksi

Disgrafi, bireylerin yazma için kullanılan el hareketlerinde zorluk ve harf oluşumlarını saklama ve hatırlama becerisi nedeniyle okunaksız veya yetersiz el yazısına sahip olmasıyla karakterize olur (Cortiella vd., 2014). Disgrafik bireyler yazı yoluyla tutarlı bir şekilde iletişim kurmada zorluk veya yetersizlik yaşarlar (Chung vd., 2016). Yapılan bir araştırmada elde edilen ve ilk öğretim 3 ve 4. Sınıf öğrencilerinin yazma hızı ve okunaklılığı konusunda %10 oranında zorluk çektiği ve bunun da ödev tamamlama becerilerini etkilediğine ilişkin sonuç, bu yargıyı desteklemektedir (Phelps vd., 2015).

Disleksi ise, doğru ve akıcı kelime tanımada zorluk ve kelime yazım ve kod çözme (heceleme) becerilerinin zayıf olmasıyla karakterize olur. Bu gelişim bozukluğu okuma becerilerinin yanı sıra yazma becerilerini de etkiler. Burada kelime tanıma zorluğu genellikle dilin fonolojik bir bileşenin eksikliğinden kaynaklanmaktadır (Berninger, 2015). Dünyanın çeşitli bölgelerinde farklı tanı ve değerlendirme kriterlerine göre yapılan analizlerde nüfusun %5 ila %20'sinin disleksiden etkilendiği raporlanmıştır (Therapy, 2025). Çocukların okul öncesi döneminde bile gözlemlenebilen bu gelişim bozukluğu, akademik performansı daha üst düzeyde okuma parçaları ve kod çözme becerilerinin gerekli olduğu ileri sınıflara kadar etkileyebilir (Chung vd., 2020; Nelson, 2010).

Araştırmalar, dünyanın çeşitli bölgelerinde eğitimcilerin disleksi ve disgrafi konusunda yeterli düzeyde bir farkındalığa sahip olmadığını ve bu gelişim bozukluklarının düzeltilmesi ile ilgili yeterli bir mesleki eğitim de almadıklarını göstermektedir (Alahmadi and El Keshky, 2019; Bridges and Kelley, 2023; Walsh vd., 2006). Bu durum, özellikle çocuk eğitiminde, öğrenme güçlüğü tanıma ile ilgili yanlış veya eksik değerlendirmelere

yol açmakta, bu da geç ya da atlanmış tanı nedeniyle çocukların düşük akademik veya sosyal başarı riskiyle karşı karşıya kalmasına neden olmaktadır (Baggett vd., 2023).

Dolayısıyla, disgrafi ve disleksinin özellikle çocuk eğitimi süreçlerinde yapılması gereken taramalarla otomatik olarak tanınması, ileri yaşlarda ortaya çıkabilecek başarısızlık riskini ortadan kaldırmak açısından kritik bir öneme sahiptir. Bu durumda, öğrenme sorunu ile ilgili hızlı ve etkin tanı koymayı sağlayacak taramalarla beraber, bu sorunların giderilmesine yönelik eğitim ve tedavi araçlarının geliştirilmesi önemli bir ihtiyaç haline gelmektedir.

1.2. Öğrenme Güçlüğü Tanısı

Öğrenme güçlüğü, tanı ve tedavisi hem eğitim hem de sağlıkla ilgili uzmanlık alanlarını ilgilendiren bir sorundur. Bu sorun eğitim uzmanlığı açısından ele alındığında, tanı için kullanılacak temel materyallerden birisi bireylerin el yazısı örnekleri olmaktadır. Öyle ki, erken çocukluk, özel eğitim ve genel eğitim süreçlerinde çocukların öğrenme güçlüğüne olup olmadığı, varsa güçlüğü türü ile ilgili bir değerlendirme, eğitimciler tarafından yaptırılan gün boyu etkinlikler aracılığıyla elde edilen yazı örnekleri incelenmek suretiyle yapılmaktadır. Literatürde bu kapsamda el yazısı metinleri manuel olarak analiz ederek disgrafi ve disleksi tanısı koymayı amaçlayan çalışmalar yer almaktadır.

Bu çalışmalardan birinde, bir konuşma-dil patoloğu, bir ergoterapist, bir özel eğitmen ve bir de genel eğitimciden oluşan disiplinlerarası araştırma ekibi tarafından bir *disgrafi ve disleksi davranışsal göstergeler listesi* (DDBIC) geliştirilmiştir (Baggett, 2022). Bu liste, çocukların yazı örneklerindeki davranışsal göstergeleri belirlemede öğretmenin etkisini tespit etmek amacıyla bir pilot çalışmada uygulanmıştır. DDBIC, okuma ve yazmada öğrenme güçlüğüyle ilişkili olan ve bir yazı yazma sürecinde (çevrimiçi) ve yazma süreci tamamlandıktan sonra (çevrimdışı) elde edilen yazı örnekleri analiz edilerek belirlenen davranışsal göstergelerden oluşur. Uygulayıcılar, DDBIC'yi kullanarak yazma etkinliği esnasında dört farklı davranışsal göstergeyi ve yazma etkinliği tamamlandıktan sonra da on üç farklı davranışsal göstergeyi gözlemleyebilirler. Tüm bu göstergeler, tamamlanmış bir yazı örneği üzerinden ortaya çıkarılabilir. Burada disgrafi ve disleksi arasında ayırım yapmanın yazma etkinlikleri esnasında gözlemlenebilen birçok davranışın birbiriyle örtüşmesi nedeniyle zor olabileceğini unutmamak gerekir. Örneğin hem disgrafi hem de disleksi sorunu yaşayan çocukların yazılarında sıklıkla kötü dilbilgisi, harfleri ters yazma ve yavaş veya zorlayıcı yazma gibi hatalı durumlar görülebilir (Barton, 2017; Brooks vd., 2011; Collette, 1979; Kandel vd., 2017; Sumner vd., 2012).

Öğrenme güçlüğünün bir eğitim sorunu olarak ele alındığı diğer bir çalışmada, eğitimciler tarafından hazırlanan bir teste internet üzerinden yapılan çevrimiçi oturumlarda verilen cevaplara bağlı olarak disleksi tanısı konmaktadır (Shengchi Foundation, 2025). Başka bir çalışmada ise el yazısıyla yazılmış cümlelerin manuel olarak puanlanmasına dayanan *Brave Handwriting Kinder* (BHK) testinin sonuçlarına bağlı olarak disgrafi tanısı konmaktadır (Gemelli vd., 2023). Bu çalışmada ayrıca, akıllı kalemler vasıtasıyla yazılan çocuk el yazılarının *derin öğrenme* (deep learning, DL) esaslı bir yöntemle sınıflandırılmasında elde edilen başarının değerlendirilmesi için BHK testlerine göre yapılan sınıf atamaları referans alınmıştır. Literatürde bu kapsamda disleksi tarama ve erken müdahale çalışmasını bir sosyal sorumluluk projesi olarak ele alan başka denemeler de yer almaktadır (Schelbe vd., 2021).

Öğrenme güçlüğü bir sağlık sorunu olarak ele alındığında ise, bu nörogelişimsel bozukluğun tanı ve tedavisi için bireylerin yazma, okuma veya konuşma süreçlerinde elde edilen fMRI, EEG, ses ve EOG gibi görüntü ve biyolojik işaret kayıtları analiz edilerek bu rahatsızlıklarla ilgili fizyolojik arka plan hakkında değerlendirmeler yapılmaktadır. Bu işaretler üzerinde uzmanlar tarafından manuel olarak yapılan analizler son yıllarda yerini hızla gelişen yapay zekâ yöntemlerine bırakmaya başlamıştır. Bu kapsamda çeşitli biyolojik işaretlerin bilgisayarlı görme, makine öğrenmesi (ML) ve derin öğrenme (DL) yöntemleri kullanılarak analiz edildiği çok sayıda çalışma örneği literatürde yer almaktadır.

Bunlardan birinde normal ve disleksili deneklerin dinlenme ve görev yapma süreçlerinde beynin sol yarım küresindeki sinir ağlarında ne gibi değişiklikler olduğu fMRI verileri analiz edilerek belirlenmeye çalışılmıştır (Schurtz vd., 2015). Bir başka çalışmada 142'si disgrafi engelli olmak üzere, toplam 240 bireyden oluşan bir denek grubundan elde edilen öznitelik verilerinin en anlamlı olanları bir Elastic Net vasıtasıyla seçilerek farklı ML yöntemlerine göre sınıflandırmalar yapılmış ve en yüksek sınıflandırma performansının RF yöntemiyle elde edildiği gösterilmiştir (Dutt vd., 2021). Disleksi tespiti için göz takibine dayalı bir yöntemin önerildiği diğer bir çalışmada ise, 98 disleksili birey ve 88 disleksili olmayan/kontrol bireyinin göz takibi verilerinin giriş verisi olarak kullanıldığı gözetimsiz bir ML yöntemi ile sınıflandırmalar yapılmıştır (Algoasylum, 2021). Ana dili İspanyolca olan disleksili ve normal/kontrol sınıftan katılımcıların iştirakiyle oluşturulan bir veri seti üzerinde yapılan diğer bir çalışmada ise, veri seti Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) ve Uyarlanabilir Sentetik (ADASYN) gibi yöntemler kullanılarak yapılan ön işlemler sonucunda yeniden üretilmiş, böylece daha önce RF algoritması kullanılarak elde

edilen sınıflandırma performansı daha da iyileştirilmiştir (Kostadin, 2023).

Son yıllarda, öğrenme güçlüğüne bir sağlık sorunu olarak ele alarak, tanısı ve tedavisi için yakın infrared spektrum (NIRS) ölçümlerine dayalı yöntemleri kullanan diğer bir yaklaşım da beyin korteksinde öğrenme ile ilgili bölgelerin kan akış paternlerini izleyerek tanı ve tedaviye yönelik kararlar üretmektedir (Ali vd., 2023; Sela vd., 2012). Bu yaklaşım özellikle disleksi tanı ve tedavisi ile ilgili yeni araştırmaları gündeme taşımaktadır.

1.3. El Yazısı Görüntülerinde Disleksi Belirtilerinin Tespiti

Yukarıdaki kısa literatür taraması, öğrenme güçlüğüne tanısı için bir dizi okuma, yazma ve konuşma testine dayanan yöntemlerin hızlı sonuç alabilme ve yaygın uygulanabilirlik açısından çeşitli dezavantajlar taşıdığını göstermektedir. Bununla beraber, yazı örneklerini davranışsal göstergelere göre manuel yöntemlerle analiz ederek tanı koyan yaklaşım da anılan dezavantajların yanı sıra pahalı bir çözüm sunması itibarıyla yaygın kullanım açısından uygun değildir. Bu durum, öğrenme güçlüğüne tanısı için daha kolay, daha hızlı ve etkin sonuçların alınabileceği yeni arayışları gündeme taşımaktadır. Özellikle çocuk eğitimi süreçlerinde disleksi ve disgrafi tanısının hızlı, güvenilir ve etkin bir şekilde konmasına olan ihtiyaç bu arayışları daha hissedilir hale getirmiştir.

Bu ihtiyacın karşılanması için son yıllarda gelişen bir yaklaşıma göre, disleksi eğilimleri el yazısı örneklerindeki yazım hataları, harf şekli, aralık ve tutarlılık gibi değişken özellikler belirlenmek suretiyle tespit edilmektedir. Bu kapsamdaki çalışmalarda el yazısı metinler sayfa/parça veya harf bazında sınıflandırılmaktadır.

Bunlardan birinde disleksi kaynaklı yazma sorunu yaşayan çocukların yanlış yazılmış karakterleri tanınması ve düzeltilmesine imkân sağlayarak yazma pratiği yapmalarına yardımcı olmak üzere bir CNN sınıflandırma modeli geliştirilmiştir (Shrishti, 2023) Bu çalışmada, bireyler tarafından yazılan her karakter doğru veya yanlış yazılmış olarak kategorize edilmekte ve yanlış yazılmışsa, bireyin onun yerine yazılması gereken doğru karakteri belirleyerek düzeltme yapmasına imkan sağlayan eğitimlerle birlikte test süreçleri de tekrarlanmaktadır. Bu amaçla kullanılan veri seti, NIST veritabanından alınan büyük harfler (Grother, 2016), Kaggle veri setinden alınan küçük harfler (Patel, 2019), ayrıca Malezya-Penang'daki Seberang Jaya İlkokulu'ndaki disleksili çocukların el yazılarıyla oluşturulan küçük/büyük harf örnekleriyle oluşturulmuştur. Bu veri seti, Normal kategorisinden 78275, Ters kategorisinden 52196 ve Düzeltilmiş kategorisinden de 8029 harf olmak üzere toplam 138500 harf (karakter) görüntüsünü kapsamaktadır. Burada önerilen model, çok katlı çapraz doğrulama testlerine göre %90,4 oranında bir sınıflandırma doğruluğu sağlamıştır.

Harf düzeyindeki nesnelerin el yazısı görüntüleri içindeki konumları ve disleksiye niteleyen özelliklerini birlikte tespit eden son dönem çalışmalarında ise, harfleri çevreleyen kutular YOLO tabanlı tespit hatları ile tespit edilerek bunların sınıf atamaları yapılmaktadır (Ultralytics 1, 2023).

Anılan yaklaşım, bu çalışmada da el yazısı görüntülerinde disleksi belirtilerinin tespiti için veri etiketleme düzeyi ile aynı düzlemde çalışan harf düzeyinde bir boru hattı kurmak suretiyle kullanılmıştır. Böylece, el yazısının harf düzeyinde parçalanmasından kaynaklanan hata zincirleri en aza indirilmiştir. Performans değerlendirmesi için 5-katlı çapraz doğrulama yöntemi kullanılarak, bulguların bölünmeye duyarlılığı sınanmış ve böylece kullanılan YOLO esaslı sınıflandırma modelinin genelleştirilebilirliği daha sağlam biçimde ortaya konmuştur. Buna göre, bu çalışmanın literatüre katkıları aşağıdaki gibi sunulabilir:

- El yazısı görüntülerinden harf düzeyinde disleksi belirtilerinin tespiti için %99,65 üzerinde doğruluk sağlayan YOLOv8n esaslı bir sınıflandırma modeli,
- Disleksi ile ilişkili paternlerin YOLO tabanlı sistemlerle tespitindeki kararlılığın 5-katlı testlerle doğrulanması,
- Evrensel disleksi taraması için daha az işlem gücüne ihtiyaç duyan bir mimari önerisi,
- Harf-düzeyindeki sınıflandırma yönteminin veri, eğitim ve değerlendirme eşleştirmesi ile görev uyumu sağlama; sonuçları sınıf ve kat bazında ayrıntılı raporlama,
- Yerelleştirilmiş çıktılarla öğretmenlere geri bildirim kolaylaştırılması.

II. Bölümde, konu ile ilgili çalışmalar; III. Bölümde, kullanılan veri seti, YOLOv8n model mimarisi, eğitim ve test yöntemi ile performans değerlendirme ölçütleri tanıtılmıştır. IV. Bölümde test sonuçları sunulmuş; V. bölümde ise elde edilen bulgular değerlendirilmiş ve tartışılmıştır.

2. LİTERATÜR ARAŞTIRMASI

2.1. El Yazısı Görüntülerinden Yapay Zekâ ile Disleksi Tanıma Yaklaşımları

Görüntü işleme ve yapay zekâ alanındaki gelişmeler, nesne tanıma uygulamalarının doğruluğunu ve hızını önemli ölçüde artırmıştır. Bu uygulamaların ilk aşaması, bir görüntü veya video akışındaki nesnelerin konumunu ve sınıfını belirlemeyi amaçlayan nesne algılama görevidir. Bunun için, görüntüdeki nesneler bir dizi sınırlayıcı kutu ile çevrenir ve her kutu için sınıf etiketi ve bununla ilgili güven puanı belirlenir. El yazısı görüntülerinin tek bir nesne içermesi halinde de doğrudan o nesnenin sınıf etiketi ve bunun belirlenmesinde esas alınan güven puanı belirlenir. Buna göre, literatürde el yazısı görüntülerinin disleksi tespiti amacıyla sınıflandırılması için yapılan çalışmalar üç ana başlık altında toplanabilir:

- ML yöntemleriyle klasik öznitelik tabanlı sınıflandırma,
- DL yöntemleriyle sayfa/parça düzeyinde sınıflandırma,
- Hata tipini kelime veya harf düzeyinde yerleştirme ile sınıflandırma.

2.1.1. Klasik Öznitelik Çıkarımı ile ML Esaslı Sınıflandırma

Klasik öznitelik tabanlı sınıflandırma yaklaşımında, el yazısı görüntülerindeki kelime/harf nesnelerinin şekli, aralığı, hizalanması gibi manuel olarak çıkarılan özellik verileri kullanılır (Aldehim vd., 2024). Bu yaklaşım, düşük veri gereksinimi ve yorumlanabilirlik açısından avantaj sağlarken, yerleştirme ve ölçeklenebilirlik açısından sınırlamalar getirmektedir.

2.1.2. Sayfa ve Parça Bazında DL Esaslı Sınıflandırma

Sayfa/parça bazında sınıflandırma yaklaşımında ise CNN, CNN-LSTM gibi DL modelleri, sayfa veya parça görüntüsünü “disleksi var/yok” şeklinde etiketleyerek öğrenir (İsa vd., 2019; Alqahtani-1 vd., 2023, Alqahtani-2 vd., 2023). Literatürde bu kapsamda yer alan birçok çalışmada yukarıda anılan (Grother, 2016; Patel, 2017) kaynaklardan alınan harf bazındaki görüntüler kullanılarak üretilen veri setleri kullanılmıştır. Bunlardan erken durdurma yoluyla eğitilerek optimize edilen bir CNN modelinin kullanıldığı çalışmada %96,4 oranında sınıflandırma doğruluğu elde edilmiştir (İsa vd., 2019). Ön işleme, morfolojik dönüşüm, 32x32 piksele yeniden boyutlandırma ve veri artırma adımları tamamlanarak üretilen veri setinin kullanıldığı çalışmada, dört farklı CNN modeli ile yapılan sınıflandırmalar sonucunda eğitim veri seti üzerinde %98,5, doğrulama (validasyon) veri seti üzerinde de %86 başarı oranına ulaşılmıştır (Alqahtani-1 vd., 2023). Veri setinin gürültü enjeksiyonu ve döndürme gibi veri artırma süreçlerinden geçirilerek yeniden üretildiği

çalışmada, öznitelik verileri LeNet5 modeli ile çıkarılarak %95'lik bir doğruluk oranına ulaşılmıştır (Alqahtani-2 vd., 2023).

176.673 el yazısı harf görüntüsünden oluşan veri setinin kullanıldığı çalışmada ise; ön işleme, ön plan-arka plan değiştirme, kırpma ve 32x32 piksele yeniden boyutlandırma işlemlerinin ardından çekirdeğini dört evrişim katmanı, maksimum havuzlama, toplu normalleştirme ve bırakma özelliklerine sahip bir CNN modelinin oluşturduğu üç farklı model (CNN, CNN-RF, CNNSVM) ile sınıflandırmalar yapılmış ve bunlardan CNN-SVM ile %99,33'lük en yüksek doğruluk oranına ulaşılmıştır (Patil vd., 2024).

Sayfa/parça bazında sınıflandırma yaklaşımı ile disleksi tespitinde transfer öğrenme yöntemlerinin de etkin olarak kullanılabilceği, önceden eğitilmiş MobileNet V3 modelinin kullanıldığı bir çalışma ile gösterilmiştir (Koonce, 2021). Bu kapsamdaki diğer bir çalışmada transfer öğrenme modelinin ince ayarı yapılarak eğitim süresi azaltılmış; bununla beraber geleneksel CNN tabanlı yöntemlere göre daha az veri kullanılarak yapılan eğitimlerle sınıflandırma doğruluğu artırılmıştır (Zhang and Ogasawara, 2023). Bu çalışmada kullanılan transfer öğrenme yaklaşımında gelişmiş açıklanabilirlik için Grad-CAM entegre edilerek (Robaa vd., 2024), modelin karar alma sürecinin daha net bir şekilde açıklanması sağlanmıştır.

Buna göre, sayfa/parça bazında sınıflandırma yaklaşımları disleksi belirtisi ile ilgili global bir karar oluşturmasına rağmen, paternin el yazısı metninin hangi konumunda oluştuğunu açıkça göstermediğinden eğitim süreçleri için gerekli geri bildirim sağlamamaktadır.

2.1.3. Kelime ve Harf Düzeyinde Nesne Çevrelemeli Sınıflandırma

Bu eksiklik kelime veya harfleri, onları çevreleyen sınırları belirlemek suretiyle yerleştirerek sınıflandıran bir yaklaşımla giderilmiştir. Bu kapsamdaki çalışmalar son dönemde YOLO ailesi vasıtasıyla gerçekleştirilen kelime/harf kutuları üzerindeki hata tipini tespite yönelik çalışmalarla gündeme gelmiştir. Bunlardan birinde %99,9'un üzerindeki hassasiyet, hatırlama ve F1 skoru verileriyle mükemmel bir performans elde edilmiştir (Fink, 2025). Böylece, el yazısının daha gerçekçi temsilini sağlayan görüntüleri işleyen YOLO tabanlı modellerin disleksi tespitinde her harfi ayrı ayrı ele alarak sınıflandırma yapan CNN veya transfer öğrenme yöntemlerine göre daha hızlı ve daha yorumlanabilir çözümler sağlama potansiyeline sahip olduğu gösterilmiştir. Bu çalışmada sunulan YOLOv11 esaslı nesne tespit uygulaması, gerçek el yazısı desenlerine benzeyen sentetik görüntülerdeki karakterleri (harf) izole ederek (Normal, Ters, Düzeltilmiş) şeklinde etiketlemektedir. Bu

amaçla kullanılan sentetik el yazısı görüntüleri, 32x32 piksel boyutundaki harflerin tek tek işlenmesi ve ardından gerçekçi bir el yazısını simüle eden sentetik kelimeler halinde birleştirilmesi suretiyle oluşturulmuştur (Zenodo, 2025; Rosli vd., 2021; Seman vd., 2021; Isa, 2021; Isa vd., 2021). Sınıflandırma sürecinde el yazısı görüntülerinde yer alan her harf eşzamanlı olarak yerleştirilmekte ve disleksi özelliklerini yansıtan üç sınıftan birinin ismi ile etiketlenmektedir.

Bu yaklaşım, farklı dillerdeki el yazısı görüntülerini işleyerek yerel düzeyde disleksi tanısı için kullanılacak YOLO tabanlı sistemlerin geliştirilmesinde kullanılabilir. Bunun için öncelikle eğitimciler, klinisyenler ve aileler yerel (ana) dilde eğitim alan disleksili ve normal çocukların el yazısı örneklerini toplayarak eğitim ve testler için gerekli veri setlerini oluşturmalıdır. Bu çalışmanın ana motivasyonu da bu düşünceden kaynaklanmıştır.

2.2. Literatürdeki Yaklaşımların Sınırlılıkları ve Çalışmanın Konumlandırılması

Buna göre, bu çalışma esasen ana dili Türkçe olan çocukların el yazısı görüntülerini toplayarak bir veri setinin oluşturulması ve bu veri seti kullanılarak yapılacak çalışmalarla harf düzeyindeki disleksi ile ilişkili paternleri tespit eden bir sınıflandırıcı tasarımını amaçlamaktadır. Bununla beraber, böyle bir veri setinin hazırlanmasındaki zorluklar ve bunun için gerekli uzun sürenin getirdiği sınırlamalar nedeniyle bu aşamada yukarıda anılan sentetik veri seti kullanılarak bir sınıflandırıcı tasarımının gerçekleştirilmesi ve böylece ileride yapılacak çalışmalar için bir başlangıç yapılması amaçlanmıştır.

Bu kapsamda, eğitim ve test süreçleri 5-katlı çapraz doğrulama yaklaşımıyla gerçekleştirilerek, harf bazında disleksi belirtilerini tespit etmeyi amaçlayan YOLOv8n modeline dayalı bir nesne tanıma sistemi geliştirilmiştir. Böylece, YOLOv11 modeli ile geliştirilen sınıflandırma modelinin sağladığı mükemmel performansın daha az işlem gücü gerektiren YOLOv8 modeli ile de elde edilebileceği, ayrıca elde edilen performans verilerinin genelleştirilebilirliği ile ilgili daha kesin bir kanaat oluşturulabileceği görülmüştür.

3. MATERYAL VE YÖNTEM

Bu çalışmada, yukarıda anılan sentetik el yazısı görüntülerinden oluşan veri seti kullanılarak (Zenodo, 2025), bu görüntülerdeki harf nesnelerini algılama ve bunların disleksi özelliği taşıyıp taşımadığını belirlemeye yönelik YOLOv8 modeline dayalı bir sınıflandırma yaklaşımı geliştirilmiştir. Bu yaklaşımda, el yazısı harflerin karmaşıklığı Normal, Ters, Düzeltilmiş sınıflarına ayrılarak ortaya çıkarılmaktadır. Bu amaçla kullanılan gri tonlu görseller, el yazısı harflerdeki doğal çeşitliliği yansıtan yazı stili, boyutu ve yönelimini sergilemektedir. Bu çeşitlilik, normal ve disleksi kaynaklı el yazısı kalıpları arasında ayırım yapmak için çok önemlidir. Buna göre, aynı harfin üç farklı sınıftaki görsellerine ilişkin birer örnek Şekil 3.1’de verilmiştir.



Şekil 3. 1. Aynı harfe ait üç farklı sınıftaki görüntü örnekleri (Patil vd., 2024)

Normal

Ters (Reversed)

Düzeltilmiş (Corrected)

3.1. Veri Seti


Bu çalışmada kullanılan sentetik veri seti 640x640 piksel boyutunda 2739 el yazısı görüntüsünden oluşmaktadır. Orijinal veri setindeki 1873 görüntü eğitim, 866 görüntü de test (doğrulama ya da validasyon) verisi olarak bölümlendirilmiştir. Bu bölümler bu çalışmada bir araya toplanmış ve yapılan 5-katlı çapraz doğrulama testlerini gerçekleştirmek üzere 5 eşit parçaya bölünerek kullanılmıştır. Her bir görüntü yaklaşık 20 kelime ve 60 harf nesnesi içermektedir. Böylece, veri setinde sınıflandırma için kullanılan toplam nesne sayısı 165032, bunların Normal, Ters ve Düzeltilmiş sınıflarına dağılımı da sırasıyla 55647, 55336 ve 54049’dur.

Bu veri seti, orijinal büyük harf görüntülerinin çoğu NIST veritabanından (Grother, 2016), küçük harf görüntülerinin çoğu Kaggle veri setinden (Patel, 2017), küçük ve büyük harf görüntülerinin diğer bir kısmı da Seberang Jaya, Penang (Malezya) bölgesindeki disleksili ilkokul çocuklarından elde edilmek suretiyle oluşturulmuştur. Harf bazındaki bu görüntülerin ait olduğu sınıf tanımlamalarına göre;

- Normal sınıfı, disleksi ile ilgili varyasyonlardan etkilenmemiş, standart yönelimleriyle temsil edilen harfleri,
- Ters sınıfı, geleneksel yazım normlarına uymayan, ters çevrilmiş, yansıtılmış ve dönüştürülmüş olma gibi disleksi ile ilişkili görsel özellikler taşıyan harfleri,
- Düzeltilmiş sınıfı, yazım düzeltme eğitiminden geçtikten sonra düzeltmenin dinamik sürecini yakalayan, ters çevrilmiş olarak başlayan ancak daha sonra normatif yönelimlerine göre hizalanan ve genellikle orijinal yapılandırmaların incelikli ipuçlarını koruyan harfleri kapsamaktadır.

Sonuç olarak, disleksi ile ilişkili el yazısı kalıpları üzerine yapılan araştırmalarda nesne algılama modellerini eğitmek ve doğrulamak amacıyla kullanılacak olan bu veri seti, Normal sınıfından 78.275, Ters sınıfından 52.196, Düzeltilmiş sınıfından da 8.029 harf görüntüsü kullanılarak oluşturulmuştur. Burada görüntüler üretilirken harf düzeyinde kaynak veriler orijinal görüntü kümelerinden programatik olarak tek tek harfler halinde örneklenerek alınmıştır. Bu harfler, kelime ve satırlar halinde rastgele bir araya getirilerek çok çeşitli görsel düzenlemeler sağlanmıştır. Her harfe YOLO formatında (x, y, genişlik, yükseklik) değerlerine sahip bir sınırlayıcı kutu atanmıştır. Harflerin disleksi açısından taşıdığı temel özellikler (Normal, Ters, Düzeltilmiş) korunmuş, sınıf numaraları 0 = Normal, 1 = Ters ve 2 = Düzeltilmiş şeklinde atanmıştır.

Sentetik veri setindeki her görüntüde, siyah bir arka plan üzerinde Normal, Ters ve Düzeltilmiş sınıflarından harfler bir metin satırı şeklinde birleştirilmiş ve her harfi sınırlayan kutular YOLO uyumlu .txt ekleri ile birlikte tanımlanmıştır. Buna göre, orijinal veri setinin eğitim ve doğrulama bölümlerinde yer alan birer görüntü örneği Şekil 3.2’de sunulmuştur.

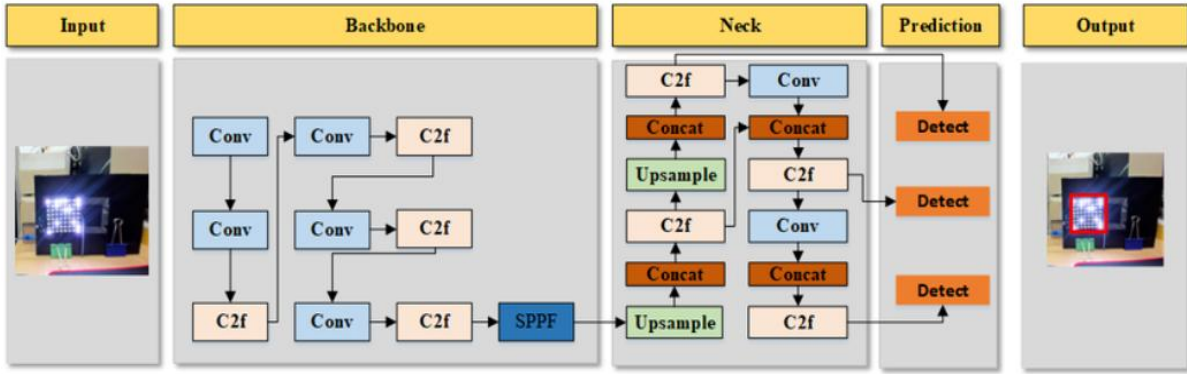


Şekil 3.2. Sentetik veri setinden eğitim ve doğrulama görüntüsü örnekleri (Zenodo, 2025)

3.2. YOLOv8 Nesne Algılama ve Tanıma Modeli

YOLOv8, gerçek zamanlı nesne tespitinde doğruluğu, verimliliği ve kullanılabilirliği önemli ölçüde artıran gelişmiş bir mimari ve metodolojik yenilikler sunmaktadır. Mimarisi bir özel sektör kuruluşu olan Ultralytics'in 2023 yılında geliştirdiği YOLOv5 mimarisi üzerine kurulmuştur (Ultralytics 2, 2023; Ultralytics 3, 2023).

YOLOv8, önceki sürümlere benzer şekilde, nesne yerelleştirme ve sınıflandırma görevlerini uçtan uca tek bir sinir ağında birleştirerek hız ve doğruluk arasındaki dengeyi korur. Bununla beraber, önceki sürümlerine göre daha optimize edilmiş katman yapısı, daha küçük model boyutları (nano, small, medium), genişletilmiş veri işleme desteği ve entegre eğitim/doğrulama araçları ile öne çıkmaktadır. Böylece, gerçek zamanlı görüntü işleme görevlerinde yüksek hız ve düşük gecikme sağlayarak görüntüdeki nesnelere bir geçişte tespit edebilmektedir (You Only Look Once). Buna göre, YOLOv8 mimarisi Şekil 3.3'te gösterilen üç temel modülden oluşur: Omurga (Backbone), Boyun (Neck) ve Baş (Prediction).



Şekil 3.3. YOLOv8 Nesne Tanıma modeli (Yaseen, 2024)

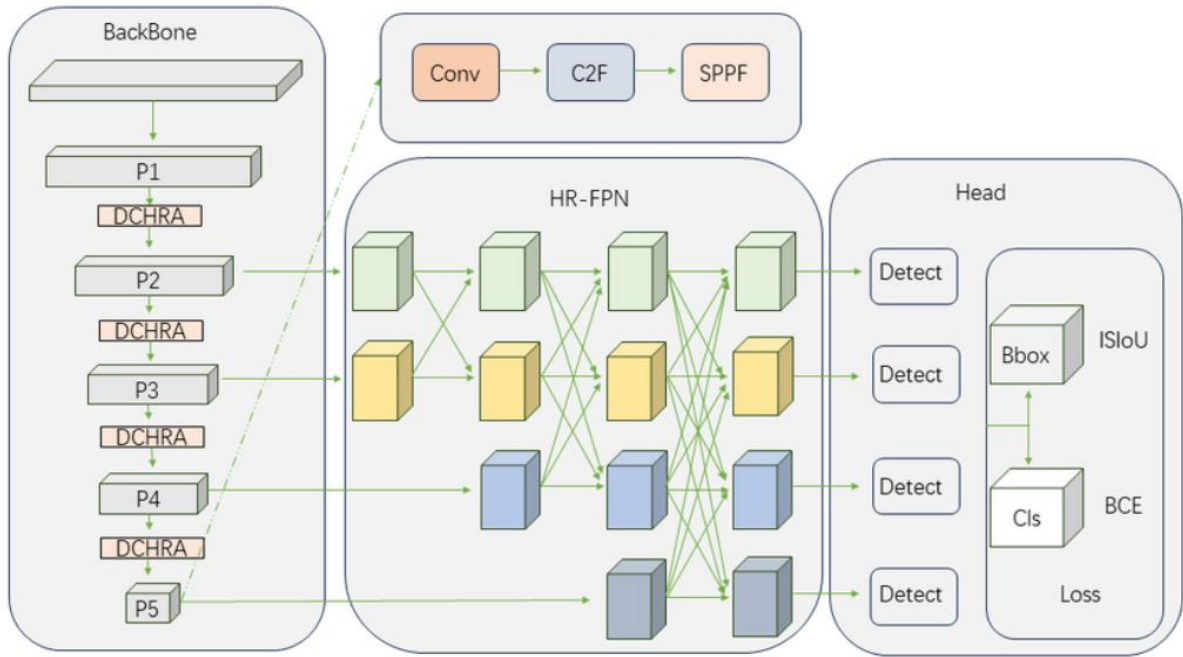
Omurga, giriş görüntülerinden çok ölçekli özellikler çıkaran gelişmiş bir evrişimli sinir ağıdır (CNN). Hem düşük seviyeli dokuları hem de doğru nesne tespiti için kritik öneme sahip yüksek seviyeli anlamsal bilgileri temsil eden hiyerarşik özellik haritalarını yakalar. Hesaplama yükünü en aza indirmek için derinlik bazında ayrılabilir evrişim katmanlarını birleştirerek hem hız hem de doğruluğu optimize eder.

Boyun, omurga tarafından çıkarılan çok ölçekli özellikleri iyileştirir ve birleştirir. Bunun için farklı özellik seviyelerindeki bilgi akışını iyileştiren Yol Toplama Ağı'nı (PANet) kullanır. Bu özelliğin entegrasyonu, farklı boyut ve ölçeklerdeki nesnelere algılanmasında kritik bir rol oynar.

Baş, nesne sınırlayıcı kutu koordinatları, nesne güven puanları ve sınıf etiketleri gibi nihai tahminleri belirler. Sınırlayıcı kutuyu tahmin ederken önceki YOLO sürümlerinde

kullanılan bağlantı tabanlı yöntemler yerine bağlantısız bir yaklaşım benimser. Bu yaklaşım, tahmin sürecini basitleştirir, hiperparametre sayısını azaltır ve modelin farklı en boy oranlarına ve ölçeklere sahip nesnelere uyarlanmasını sağlar.

YOLOv8'in CSPNet omurgası ve geliştirilmiş FPN+PANet boyun yapısı, özellik çıkarma ve çok ölçekli nesne algılamayı önemli ölçüde iyileştirerek gerçek zamanlı uygulamalar için güçlü bir model oluşturulmasına katkı sağlar (Şekil 3.4). Bu kapsamda geliştirilen farklı YOLOv8 modelleri ve bunların belirli metriklere (ölçüt) göre sağladıkları performans verileri Tablo 3.1'de gösterilmiştir.



Şekil 3.4. YOLOv8 FPN mimarisinin farklı düzenlenme alternatifleri.

Buna göre, en alt model olan YOLOv8n daha hızlı çıkarım süreleri ve daha düşük doğruluk sağlamaktadır.

Tablo 3.1. YOLOv8'in farklı modelleri için performans metrikleri

Model	Params (Million)	Accuracy (mAP@0.5)	CPU Time (ms)	GPU Time (ms)
YOLOv8n	2.0	47.2	42	5.8
YOLOv8s	9.0	58.5	90	6.0
YOLOv8m	25.0	66.3	210	7.8
YOLOv8l	55.0	69.8	400	9.8
YOLOv8x	90.0	71.5	720	11.5

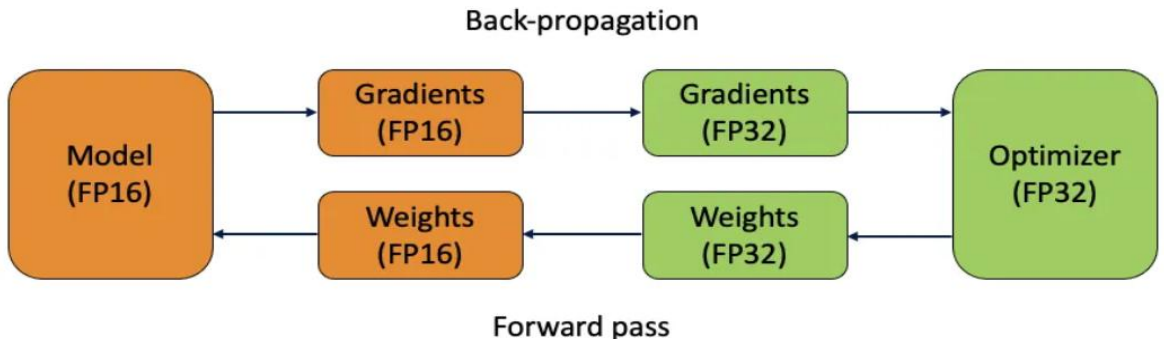
Bu durum, YOLOv8n'i özellikle hızın çok önemli olduğu, buna karşılık hesaplama gücünün sınırlı olduğu uç bilişim uygulamaları için uygun hale getirmektedir. En yüksek doğruluğu sunan YOLOv8x ise, tıbbi görüntüleme veya güvenlik uygulamaları gibi hassasiyetin kritik öneme sahip olduğu, ancak verimli bir şekilde çalışması için daha güçlü donanım gerektiren durumlarda kullanım için idealdir.

3.3. YOLOv8 Modelinin Eğitimi

YOLOv8'in nesne tespitinde sağladığı yüksek performans, yalnız mimari geliştirmelerle değil, aynı zamanda gelişmiş eğitim metodolojileriyle de ilgilidir. Bu kapsamda model genellemesini geliştiren mozaik artırma ve karıştırma gibi bir dizi yeni veri artırma stratejisi ile sınıflandırılması zor örneklerle daha fazla ağırlık veren bir odak kaybı fonksiyonu kullanır. Bu yaklaşım, nesne tespit veri kümelerinde sıklıkla görülen sınıf dengesizliği sorununu azaltır ve modelin yeterince temsil edilmeyen küçük veya örtülü nesnelere tespit etme yeteneğini artırır.

YOLOv8, devam eden PyTorch geçişinin bir parçası olarak modern GPU mimarilerinden etkili bir şekilde yararlanmak için hem mimarisini hem de eğitim süreçlerini optimize eder. Karma hassasiyetli eğitim ve diğer hesaplamalı optimizasyonları kullanarak, doğruluğu korurken (hatta artırırken) daha hızlı eğitim ve çıkarım süreleri elde eder. Bu optimizasyon, modelin kaynak kısıtlı ortamlarda kullanıma uygun olmasını sağlar.

YOLOv8, modelin eğitim ve çıkarımı esnasında 16-bit kayan nokta hassasiyetinden yararlanmasını sağlayan bir teknik olan karma hassasiyet eğitimi kullanır. Bu yaklaşım, NVIDIA'nın A100 ve T4 modelleri gibi uyumlu GPU'larda eğitim sürecini önemli ölçüde hızlandırırken, modelin doğruluğunu da korur. Karma hassasiyet eğitimi ayrıca bellek tüketimini azaltarak daha büyük toplu iş boyutlarına ve daha verimli GPU kullanımına imkân sağlar (Şekil 3.5).



Şekil 3.5. YOLOv8 eğitim sürecinde karma hassasiyet kullanımı (İsa vd., 2023)

Bu çalışmada YOLOv8 modelinin eğitim süreci GPU (CUDA) destekli olarak

gerçekleştirilmiş ve yüksek işlem hacmi sayesinde kısa sürede tamamlanabilmiştir. Model konfigürasyonları insan tarafından kolay okunabilir bir veri yapılandırma biçimi (Markup Language) olan YAML formatı üzerinden sağlanmış, böylece sade ve okunabilir bir veri organizasyonu gerçekleştirilmiştir. Buna göre, YAML dosyası aşağıdaki bilgileri içermektedir:

- Eğitim ve test görüntü dosyalarının yolları,
- Sınıf sayısı (nc),
- Sınıf isimleri (names).

Eğitilmiş bir modelin performansı, `model.val()` fonksiyonu çağrılarak hesaplanır. Bu fonksiyon test veri kümesini işleyerek çeşitli performans metriklerini döndürür (Ultralytics 3, 2023). Bu durumda `model.val()` fonksiyonunun sağladığı çıktılara eşlik eden performans ölçütleri (metrikler) aşağıda tanımlanmıştır.

3.4. Performans Metrikleri

Performans metrikleri, nesne algılama modellerinin doğruluğunu ve verimliliğini değerlendirmek için kullanılan temel araçlardır. Bu metrikler, modelin görüntüdeki nesnelere ne kadar etkili bir şekilde tanımlayıp konumlandırabildiğine ilişkin fikir verir. Ayrıca, modelin yanlış pozitif (FP) ve yanlış negatif (FN) sonuçları nasıl ele aldığını anlamaya yardımcı olur. Buna göre, nesne algılama ve tanıma modellerinin performansını değerlendirmek için yaygın olarak kullanılan metrikler aşağıda tanımlanmıştır (Ultralytics 4, 2023):

- *IoU (Birleşim Üzerinden Kesişim)*: Tahmin edilen bir sınırlayıcı kutu ile gerçeği arasındaki örtüşmenin bir ölçüsüdür. IoU değerleri 0 ile 1 arasında değişir; daha yüksek değerler daha iyi örtüşme doğruluğunu gösterir. 1.0 IoU değeri, mükemmel örtüşme anlamına gelir.

- *AP (Ortalama Kesinlik, Average Precision)*: Kesinlik-hatırlama eğrisi altındaki alandır. Modelin kesinlik ve hatırlama performansını kapsayan tek bir değer sağlar.

- *mAP (Ortalama Kesinliklerin Ortalaması)*: Çok sınıflı nesne algılama senaryolarında modelin performansının kapsamlı bir değerlendirmesini sağlamak için farklı sınıflardaki ortalama AP değerlerinin ortalamasını belirleyerek modelin nesne algılama doğruluğunu ölçer. Daha yüksek değerler daha iyi performansı gösterir.

- *Hassasiyet (Precision) ve Hatırlama (Recall)*: Hassasiyet, tüm pozitif tahminler

arasındaki gerçek pozitiflerin (TP) oranını nicelleyerek modelin yanlış pozitiflerden (FP) kaçınma yeteneğini değerlendirir. Hatırlama, gerçek pozitiflerin (TP) tüm gerçek pozitiflere göre oranını hesaplayarak, modelin bir sınıfın tüm örneklerini tespit etme yeteneğini ölçer.

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

$$\text{Kesinlik (Recall)} = \text{TP} / (\text{TP} + \text{FN})$$

• *F1 skoru*: kesinlik ve hatırlama metriklerinin harmonik ortalamasıdır. Hem yanlış pozitifleri (FP) hem de yanlış negatifleri (FN) dikkate alarak bir modelin performansının dengeli bir değerlendirmesini sağlar.

$$\text{F1-score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

• *Model Boyutu*: Dağıtım için gereken hesaplama kaynaklarını gösterir. Daha küçük model boyutları, sınırlı bellek ve işlem gücüne sahip cihazlar için avantajlıdır.

Sınıf Bazında Metrikler

model.val() fonksiyonunun çıktısının bölümlerinden biri performans metriklerinin sınıf bazındaki dökümüdür. Bu ayrıntılı bilgi, özellikle çeşitli nesne sınıflarına sahip veri kümelerinde modelin her bir sınıf için ne kadar iyi performans gösterdiğini anlama açısından faydalıdır. Buna göre, veri kümesindeki her bir sınıf için aşağıdaki parametreler sağlanır:

- *Sınıf (class)*: Bir nesne sınıfının adını belirtir,
- *Görüntüler (images)*: Test veri setinde ilgili nesne sınıfını içeren görüntülerin sayısını gösterir.
- *Örnekler (instances)*: Bir sınıfın test veri setindeki tüm görüntülerde kaç kez görüldüğünün sayısını sağlar.
- *Kutu (P, R, mAP50, mAP50-95)*: Bu metrik, modelin nesnelere algılama performansına dair bilgiler sağlar. Bunlar:
 - *P (Kesinlik)*: Tespit edilen nesnelere doğruluğunu, yani kaç tespitin doğru olduğunu gösterir,
 - *R (Hatırlama)*: Modelin görüntülerdeki nesnelere tüm örneklerini tanımlama yeteneğini gösterir,
 - *mAP50*: Birleşim Üzerinden Kesişim (IoU) eşiği 0,50'de hesaplanan ortalama kesinlik. Modelin yalnızca kolay tespitler dikkate alındığındaki doğruluk ölçüsüdür,

- *mAP50-95*: 0,50 ile 0,95 arasında deęişen çeşitli IoU eşiklerinde hesaplanan ortalama kesinlięin ortalamasıdır. Modelin farklı zorluk düzeylerindeki algılama performansı hakkında bir fikir saęlar.

Görsel Çıktılar:

model.val() fonksiyonu, sayısal metrikler üretmenin yanı sıra, modelin performansı hakkında daha sezgisel bir anlayış saęlayabilen görsel çıktıları da üretir. Bunlar:

- *F1-skoru eğrisi (F1_curve.png)*: Modelin çeşitli eşiklerde saęladığı F1-skorunu gösterir. Modelin farklı eşiklerdeki FP ve FN deęerleri arasındaki dengeye dair bir fikir verebilir.

- *Kesinlik-Hatırlama eğrisi (PR_curve.png)*: Modelin farklı eşiklerdeki kesinlik ve hatırlama metrikleri arasındaki dengeyi gösterir. Özellikle dengesiz sınıflarla uğraşırken önemlidir.

- *Kesinlik eğrisi (P_curve.png)*: Farklı eşiklerdeki kesinlik deęerlerinin grafiksel bir gösterimidir. Bu eğri, eşik deęiştikçe kesinlięin nasıl deęiştikğini anlamaya yardımcı olur.

- *Hatırlama eğrisi (R_curve.png)*: Hatırlama deęerlerinin farklı eşiklerde nasıl deęiştikğini gösterir.

- *Karmaşıklık matrisi (confusion_matrix.png)*: Her sınıf için TP, TN, FP ve FN sayılarını göstererek sonuçların ayrıntılı bir görünümünü sunar.

- *Normalize Karmaşıklık matrisi*: Karmaşıklık matrisinin normalize edilmiş halidir. Verileri sayılar yerine oranlar halinde gösterir. Bu format, sınıflar arası performansı karşılaştırmayı kolaylaştırır.

- *Toplu Test Etiketleri (val_batchX_labels.jpg)*: Test veri kümesindeki farklı gruplar için temel gerçeklik etiketlerini gösterir. Nesnelerin ne olduęu ve veri kümesine göre ilgili konumları hakkında net bir fikir verir.

- *Toplu Test Tahminleri (val_batchX_pred.jpg)*: YOLO modellerinin test veri kümesindeki farklı gruplar için yaptıęı tahminleri gösterir. Bunlar etiket görüntüleriyle karşılaştırılarak, modelin nesnelere görsel olarak ne kadar iyi algılayıp sınıflandırdığı kolayca deęerlendirilebilir.

Yukarıda sıralanan ve model.val() fonksiyonu ile üretilen metrikler, gelecekte kullanılmak üzere genellikle runs/detect/val adlı bir dizine kaydedilir.

3.5. YOLOv8 Açıklama Biçimi

YOLOv8 modeli açıklamalar için YOLOv5 PyTorch TXT biçimini esas alır. Açıklamalar, görüntüdeki her nesne için karşılık gelen bir metin dosyasında saklanır. Her satır, sınıf etiketini ve ardından sınırlayıcı kutunun görüntü boyutlarına göre normleştirilmiş koordinatlarını (center_x, center_y, genişlik, yükseklik) içerir. Biçim aşağıdaki gibidir:

```
<class> <center_x> <center_y> <width> <height>
```

Örneğin, bir açıklama şu şekilde görünebilir:

```
0 0,492 0,403 0,212 0,315
```

Bu biçime, modelin mimarisini ve sınıf etiketlerini belirten bir YAML yapılandırma dosyası eşlik eder. Bu dosya, YOLOv8'in farklı veri kümelerine ve görevlere kolayca uyarlanabilmesini sağlar (Geburu vd., 2018, Mitchell vd., 2019). Uyumluluk için, Microsoft COCO, Roboflow, VOTT, LabelImg ve CVAT gibi araçlardan gelen açıklamaların YOLOv8 biçimine uyum için dönüştürülmesi gerekebilir. Bu araçlar genellikle bu süreci kolaylaştırmak için doğrudan dışa aktarma seçenekleri veya dönüştürme yardımcı programları sunar. Bu ilerlemeler, YOLOv8'in yeteneklerini daha da geliştirmekte ve bilgisayarlı görme alanındaki etkisini genişletmektedir.

4. 5-KATLI EĞİTİM VE DOĞRULAMA TESTLERİ

5-katlı eğitim ve çapraz doğrulama testleri Google Colab ortamında NVIDIA A100 (SXM4, 40 GB) GPU, yüksek bant genişlikli HBM2e bellek ve PCIe 4.0 altyapısı üzerinde yürütülmüştür. YOLOv8n modelinin eğitimi ve doğrulama testleri yapılırken yazılım aracı olarak Python 3.12, PyTorch 2.8 (CUDA 12.x) ve Ultralytics YOLOv8 8.3.226 kullanılmıştır. Ayrıca veri setinin 5-katlı eğitim ve test süreçleri için bölümlendirilmesi ve test sonuçlarının görselleştirilmesi için Scikit-learn kütüphane fonksiyonlarından (KFold, ConfusionMatrixDisplay) yararlanılmıştır (Python, 2005; PyTorch, 2005; NVIDIA Developer, 2005; scikit-learn, 2005).

4.1. Eğitim ve Test Süreçleri

Eğitim ve doğrulama testleri için kullanılan veri seti toplam 2739 görüntü ve 2739 etiket dosyasından oluşmaktadır. Orijinal olarak 1873 görüntünün eğitim, 866 görüntünün de doğrulama setlerine bölüdüğü bu veri seti, Zenodo üzerinde Synthetic Dyslexia Handwriting (YOLO-Format) başlığı altında erişime açıktır. Bu çalışmada 5-katlı doğrulama uygulanacağı için tüm görüntüler “images/all” ve tüm etiketler de “labels/all” altında tek bir birleşik klasörde toplanmıştır. StratifiedKFold fonksiyonu bu sayede testlerin her katı için homojen bir sınıf dağılımı üretebilmiştir. Eğitim ve test süreçlerinde tespit edilen ve kutularla çevrelenen nesnelere tekil harfleri içermektedir. Bu nesnelere üç sınıfa ayrılmıştır: Normal, Ters, Düzeltilmiş. Buna göre, veri setindeki toplam 165032 kutulanmış nesnenin bu sınıflara dağılımı aşağıdaki gibidir:

sınıf 0: 55647 sınıf 1: 55336 sınıf 2: 54049

5-katlı eğitim ve doğrulama testleri için yapılan parametre ayarları Şekil 4.1’de gösterilen Ultralytics şablonuna göre yapılmıştır (Ultralytics 4, 2023). YOLOv8n modeli (yolov8n.pt) için yapılan bu ayarlara göre görüntü boyutları 640x640 piksel, epoch = 50, patience = 10, batch = 16, workers = 0, cache = ram olarak seçilmiştir. Tüm deneylerde sabit tohum (seed = 0) ve deterministik kip (deterministic = True) kullanılmıştır.

Buna göre, 5-katlı eğitim ve çapraz doğrulama süreçlerinde her kat için çeşitli metriklerle gerçekleştirilen performans verilerinin 50 döngü (epoch) boyunca değişimi Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6’daki grafiklerle toplu olarak gösterilmiştir.

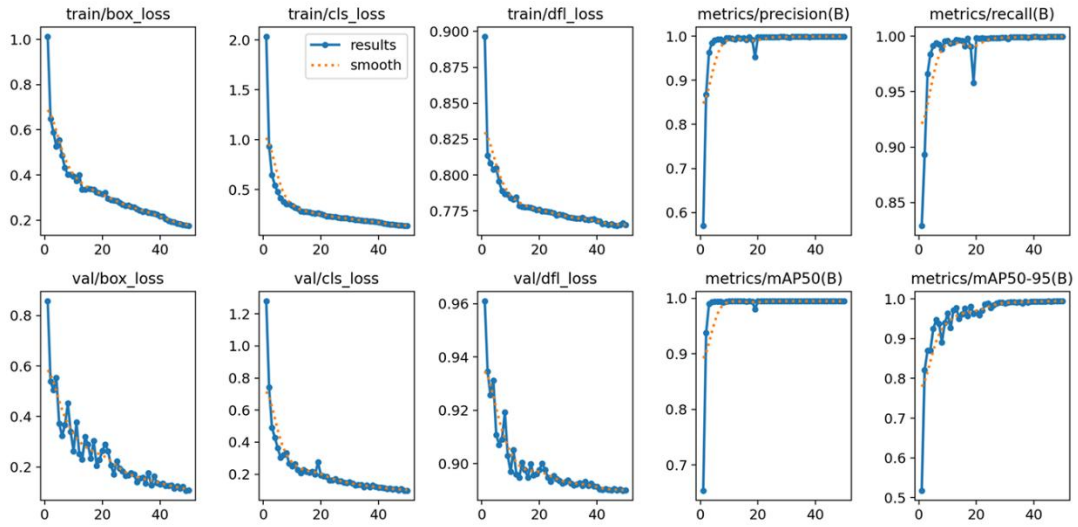
Eđitim (fold-k):

```
yolo detect train \  
  model=yolov8n.pt data=./data/data.yaml \  
  epochs=50 batch=16 imgsz=640 seed=0 deterministic=True \  
  optimizer=auto momentum=0.937 weight_decay=0.0005 \  
  box=7.5 cls=0.5 dfl=1.5 hsv_h=0.015 hsv_s=0.7 hsv_v=0.4 \  
  mosaic=1.0 close_mosaic=10 translate=0.1 erasing=0.4 fliplr=0.5 \  
  iou=0.7 max_det=300 amp=True \  
  project=./runs/yolo_kfold name=fold_k
```

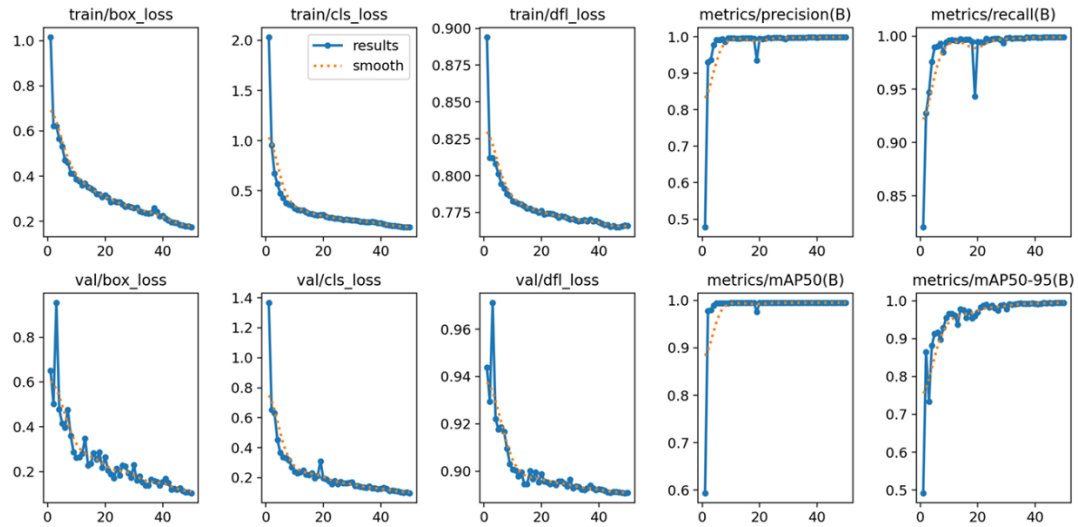
Dođrulama (fold-k):

```
yolo detect val \  
  model=./runs/yolo_kfold/fold_k/weights/best.pt \  
  data=./data/data.yaml imgsz=640 iou=0.7 \  
  save_txt=False save_json=False
```

Şekil 4.1. Eđitim ve dođrulama testleri iin yapılan parametre ayarları

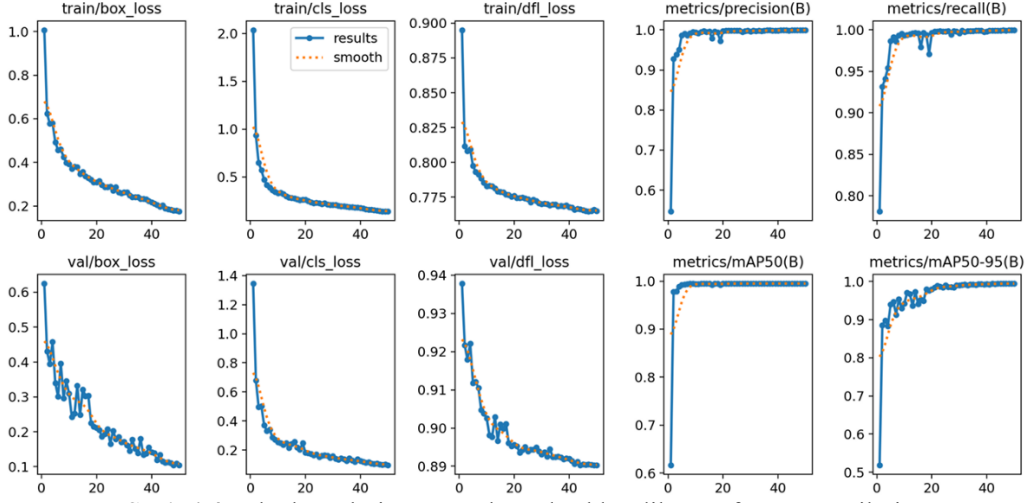


Şekil 4.2. 5-katlı testlerin birinci katında elde edilen performans eđrileri.



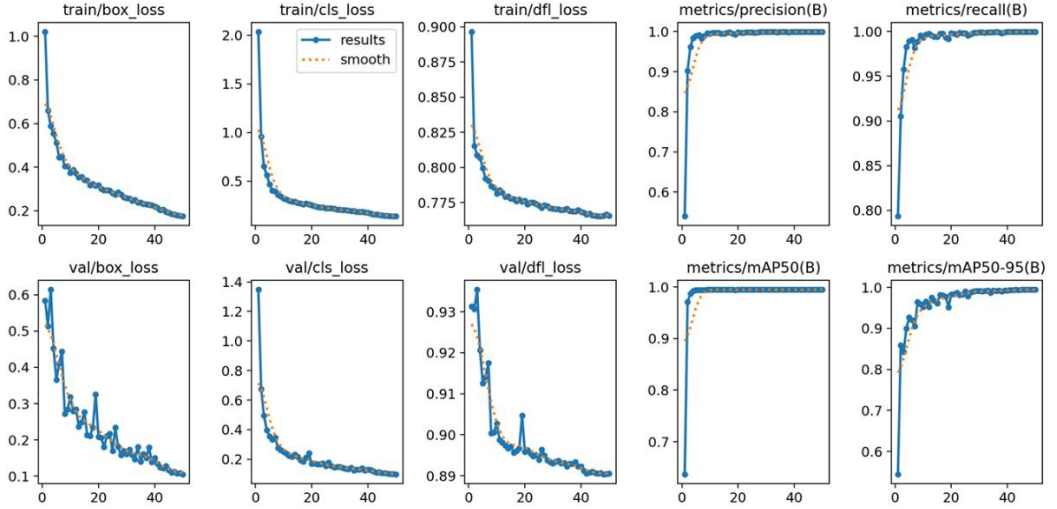
Şekil 4.3. 5-katlı testlerin ikinci katında elde edilen performans eđrileri.

Bu grafikler, eğitim ve test süreçlerinin herhangi bir aşırı öğrenme sorunu yaşanmadan başarıyla tamamlandığını göstermektedir.



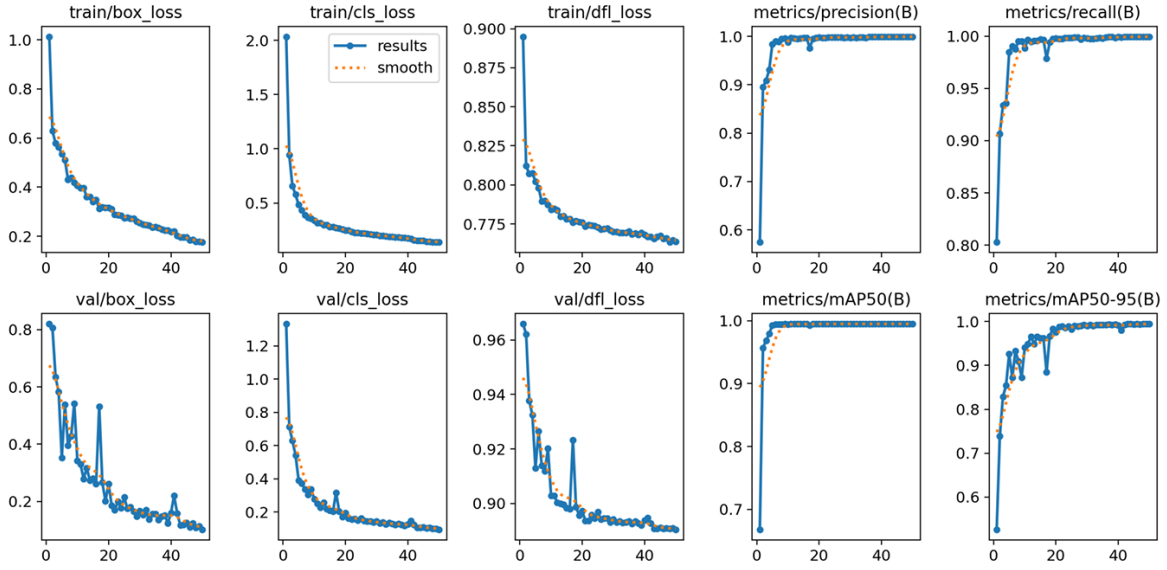
Şekil 4.4. 5-katlı testlerin üçüncü katında elde edilen performans eğrileri.

Buna göre, eğitilen YOLOv8 modelinin 5-katlı çapraz doğrulama testlerinin her katında doğrulama için veri setinden 550 civarında görüntü seçilmiştir.



Şekil 4.5. 5-katlı testlerin dördüncü katında elde edilen performans eğrileri.

Bu görüntülerde toplam olarak 33000 civarında harf nesnesi yer almaktadır. Bunların sınıflandırma başarısı Kesinlik (Precision), Hatırlama (Recall), mAP50 ve mAP50-95 metriklerine göre değerlendirilmiştir.



Şekil 4.6. 5-katlı testlerin beşinci katında elde edilen performans eğrileri.

4.2. Test Sonuçları

Test sonuçlarını gösteren çıktılar Ultralytics val kipi kullanılarak ALL ve sınıf başına Kesinlik (Precision), Hatırlama (Recall) ve $mAP@50/mAP50-95$ metriklerini gösterecek şekilde üretilmiştir (Ultralytics 4, 2023). Karmaşıklık matrisleri ise scikit-learn kütüphane fonksiyonları kullanılarak çizdirilmiştir:


```
runs/yolo_{fold}/fold_katında eğitim gnlkleri ve aβrılıklar
```

```
figures/confusion_foldk_normalized.png görselleri
```

Tablo metrikleri: Precision, Recall, $mAP@50$, $mAP50-95$

Şekil 4.7. Karmaşıklık matrisi hesaplamaları için kullanılan fonksiyonlar

Etiketleme harf kutuları bazında yapıldığından, test sonuçları harf düzeyinde tespit edilen sınıf atamalarına göre belirlenmiştir. Buna göre, 5-katlı çapraz doğrulama testlerinin birinci katında veri setinden eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 33179'dur. Bu kat için elde edilen karmaşıklık matrisi Şekil 4.8'de, sınıf bazındaki test sonuçları da Tablo 4.1'de verilmiştir.

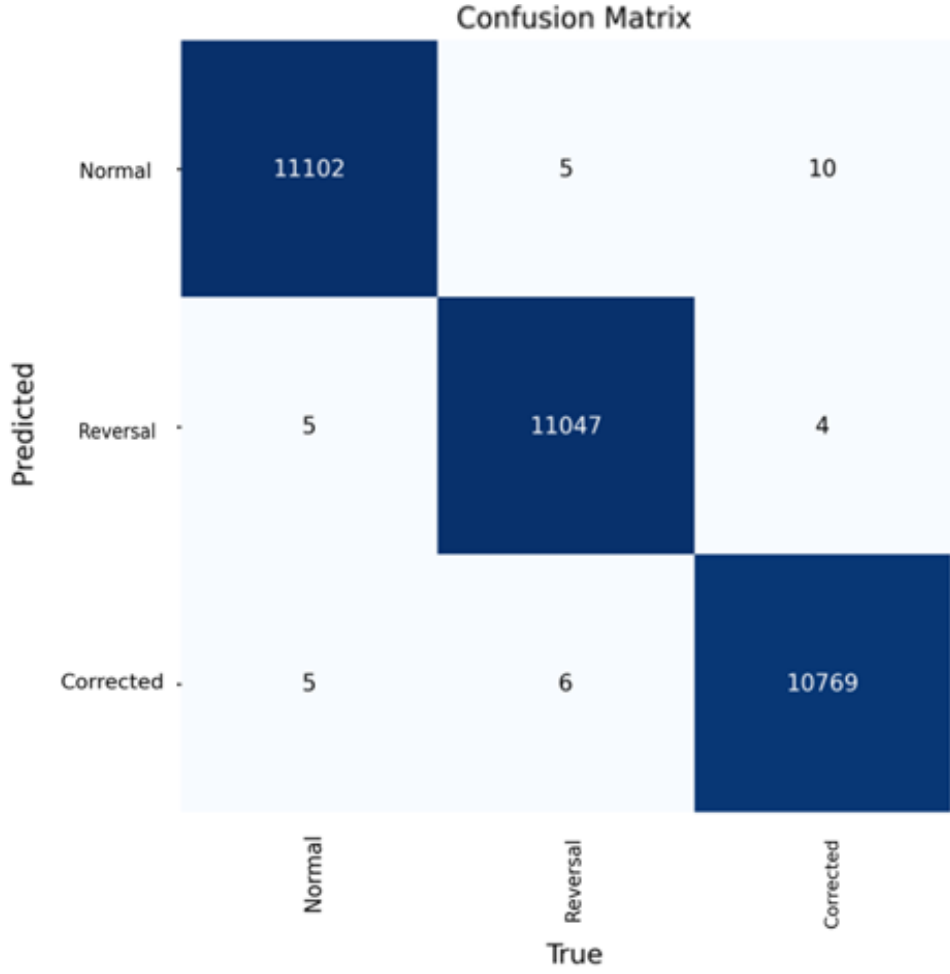


Şekil 4.8. 5-katlı doğrulama testlerinde birinci katın karmaşıklık matrisi.

Tablo 4.1. 5-katlı çapraz doğrulamada birinci katın test sonuçları.

Class	Images	Instances	P	R	mAP50	mAP50-95
All	548	33179	1.000	1.000	0.995	0.995
Normal	548	11196	1.000	1.000	0.995	0.995
Reversal	548	11125	1.000	1.000	0.995	0.995
Corrected	548	10858	1.000	1.000	0.995	0.995

Testlerin ikinci katında eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu sayısı 32953'tür. Bu kat için elde edilen karmaşıklık matrisi Şekil 4.9'da, sınıf bazlı test sonuçları da Tablo 4.2'de verilmiştir.




Şekil 4.9. 5-katlı doğrulama testlerinde ikinci katın karmaşıklık matrisi.

Tablo 4.2. 5-katlı çapraz doğrulamada ikinci katın test sonuçları

Class	Images	Instances	P	R	mAP50	mAP50-95
All	548	32953	0.999	0.999	0.995	0.995
Normal	548	11112	0.998	0.999	0.995	0.995
Reversal	548	11058	0.999	0.999	0.995	0.995
Corrected	548	10783	0.999	0.999	0.995	0.995

Benzer şekilde, testlerin üçüncü katında veri setinden eğitim için 2191, test için 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 32792'dir. Buna göre, bu kat için elde edilen karmaşıklık matrisi Şekil 4.10'da, sınıf bazındaki test sonuçları da Tablo 4.3'te verilmiştir.




Şekil 4.10. 5-katlı doğrulama testlerinde üçüncü katın karmaşıklık matrisi.

Tablo 4.3. 5-katlı çapraz doğrulamada üçüncü katın test sonuçları.

Class	Images	Instances	P	R	mAP50	mAP50-95
All	548	32792	1.000	1.000	0.995	0.995
Normal	548	11067	1.000	0.999	0.995	0.995
Reversal	548	10980	0.999	1.000	0.995	0.995
Corrected	548	10745	1.000	1.000	0.995	0.995

Testlerin dördüncü katında eğitim için 2191, test için 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu sayısı 33159'dur. Sonuçta bu kat için elde edilen karmaşıklık matrisi Şekil 4.11'de, sınıf bazındaki test sonuçları da Tablo 4.4'te verilmiştir.




Şekil 4.7. 5-katlı doğrulama testlerinde dördüncü katın karmaşıklık matrisi.

Son olarak, testlerin beşinci katında da veri setinden eğitim için 2192, test için 547 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 32949'dur.

Tablo 4.4. 5-katlı çapraz doğrulamada dördüncü katın test sonuçları.

Class	Images	Instances	P	R	mAP50	mAP50-95
All	548	33159	1.000	1.000	0.995	0.995
Normal	548	11160	1.000	1.000	0.995	0.995
Reversal	548	11123	1.000	1.000	0.995	0.995
Corrected	548	10876	1.000	1.000	0.995	0.995

Buna göre, bu kat için elde edilen karmaşıklık matrisi Şekil 4.12'de, sınıf bazındaki test sonuçları da Tablo 4.5'te verilmiştir.



Şekil 4.8. 5-katlı doğrulama testlerinde beşinci katın karmaşıklık matrisi.

Tablo 4.5. 5-katlı çapraz doğrulamada beşinci katın test sonuçları.

Class	Images	Instances	P	R	mAP50	mAP50-95
All	547	32949	1.000	1.000	0.995	0.995
Normal	547	11112	0.999	0.999	0.995	0.995
Reversal	547	11150	1.000	1.000	0.995	0.995
Corrected	547	10787	0.999	1.000	0.995	0.995

5-katlı çapraz doğrulama testlerinin yukarıda ayrıntılı olarak verilen sonuçları Tablo 4.6’da toplu olarak verilmiştir.

Tablo 4.6. 5-katlı çapraz doğrulama testlerinin toplu sonuçları.

Kat	Prec.	Rec.	mAP50	mAP50-95
Fold 1	0.9997	0.9996	0.9950	0.9947
Fold 2	0.9993	0.9990	0.9950	0.9947
Fold 3	0.9998	0.9995	0.9950	0.9948
Fold 4	0.9997	0.9998	0.9950	0.9947
Fold 5	0.9995	0.9996	0.9950	0.9947
Ort.	0.9996	0.9995	0.9950	0.9947

Bu sonuçlar incelendiğinde, model performansının tüm katlarda oldukça kararlı bir yapı sergilediği görülmektedir. Özellikle kesinlik (precision) ve hatırlama (recall) değerlerinin katlar arasında çok düşük varyasyon göstermesi, modelin veri bölünmelerine karşı yüksek derecede kararlı olduğunu ortaya koymaktadır. Bu durum, kullanılan çapraz doğrulama yaklaşımının model performansını daha güvenilir biçimde değerlendirmeye olanak sağladığını göstermektedir. Aynı zamanda mAP50 ve mAP50-95 metriklerinin tüm katlarda neredeyse sabit değerler üretmesi, modelin yalnızca nesne sınıflandırma başarısının değil, aynı zamanda nesne konumlandırma doğruluğunun da yüksek olduğunu göstermektedir.

Model performansının özellikle yüksek IoU eşiklerinde dahi korunabilmesi, harf nesnelerinin konumsal olarak doğru biçimde belirlenebildiğini ve sınıflandırma sürecinde hatalı eşleşmelerin sınırlı kaldığını göstermektedir. Bu durum, harf düzeyinde yapılan etiketlemenin model öğrenmesine önemli katkı sağladığını ve karakter temelli yaklaşımın disleksi belirtilerinin tespiti açısından uygun bir temsil düzeyi sunduğunu göstermektedir.

5. TARTIŞMA VE SONUÇ

Bu çalışma, el yazısı görüntülerinden disleksi ile ilişkili paternlerin harf düzeyinde nesne tespitiyle güvenilir biçimde belirlenebildiğini göstermiştir. Etiketleme, eğitim ve değerlendirme harf kutuları düzleminde eşleştirilmiştir. Bu sayede karakter parçalanmasından kaynaklanan hata zinciri en aza indirilmiştir.

5.1 Bulguların Değerlendirilmesi

5-katlı testler sonucunda sınıf bazında değerlendirme için oluşturulan tablolar ve karmaşıklık matrisleri, katlar arasında tutarlı bir performans profili oluşturduğunu göstermektedir. Özellikle bütün sınıflardaki yüksek kesinlik (precision) ve hatırlama (recall) değerleri, görsel ipuçlarının belirginliğine; mAP50 ve mAP50–95 değerleri ise, yüksek IoU eşiklerinde bile kutu hizalama duyarlılığının yüksekliğine işaret etmektedir. Böylece, bulguların bölünmeye duyarlılığı sınanmış ve genellenebilirlik daha sağlam biçimde tahmin edilmiştir. Bu bulgular, harf düzeyinde temsilin görev birimi ile doğal uyumunu doğrulamaktadır. Bu yolla:

- Öğretmen ve terapistlere, nerede sorusuna yanıt veren yerleştirilmiş geri bildirim sağlanır,
- Uygulama, kısa yazı örnekleriyle hızlı tarama senaryolarına doğrudan entegre edilebilir,
- Model çıktıları, hatanın türü ve konumu birlikte raporlanarak müdahale tasarımı kolaylaştırılır.

Böylece, harfleri ayrı ayrı ele alan daha basit veri hatları yerine harf görüntüleri işlenerek el yazısının daha gerçekçi bir temsili sağlanmıştır. Sentetik görüntüleri işleyerek ulaşılan bu sonuçlara güvenmekle, görüntüdeki boşluk alanlarının nasıl değerlendirildiğine ilişkin endişeler oluşabilir. Ancak yapılan denemeler daha hızlı ve daha yorumlanabilir disleksi taramasında YOLO tabanlı tespitin önemli bir potansiyele sahip olduğunu göstermektedir. Bu kapsamda gelecekte eğitimciler, klinisyenler ve aileler arasında güven oluşturmak için gerçek dünya el yazısına dayalı denemeler yapılabilir; bu çalışmalarda daha derin açıklanabilir yöntemler kullanılabilir.

Literatürde el yazısı üzerinden disleksi tespiti çalışmalarının önemli bir bölümü sayfa düzeyinde veya kelime düzeyinde sınıflandırma yaklaşımlarına dayanmaktadır. Bu tür yaklaşımlar genel yazı düzeni, karakter yoğunluğu veya kelime yapısı gibi makro özellikleri

analiz etmektedir. Ancak disleksi ile ilişkili bazı karakteristik hatalar, özellikle harf yönelimleri ve karakter dönüşleri gibi mikro düzeydeki görsel paternlerde ortaya çıkmaktadır. Bu nedenle harf düzeyinde nesne tespiti yaklaşımı, disleksi belirtilerinin daha ayrıntılı ve doğrudan analiz edilebilmesine olanak sağlamaktadır.

Bu çalışmada kullanılan YOLOv8 tabanlı nesne algılama yaklaşımı, her bir harf nesnesinin konumunu ve sınıfını aynı anda belirleyebilen bir mimariye sahiptir. Bu özellik sayesinde hem karakter türünün hem de karakterin yazı içindeki konumsal bilgisinin birlikte değerlendirilebilmesi mümkün olmaktadır. Böylece model yalnızca yazının genel özelliklerine değil, aynı zamanda harflerin yönelim, dönüş veya düzeltilme gibi disleksi ile ilişkilendirilebilen görsel özelliklerine de duyarlı hale gelmektedir.

Bu yaklaşım, özellikle ters yazılan veya düzeltilmiş karakterlerin tespit edilmesinde önemli bir avantaj sağlamaktadır. Sayfa düzeyinde yapılan sınıflandırma yöntemleri çoğu zaman bu tür yerel hataları doğrudan temsil edememektedir. Buna karşılık, nesne algılama tabanlı yöntemler, yazı içerisindeki problemlili karakterlerin tam konumlarını belirleyebildikleri için hem analiz sürecinin yorumlanabilirliğini artırmakta hem de eğitim ve klinik değerlendirme süreçlerinde kullanılabilir olacak daha açıklayıcı çıktılar üretmektedir.

5.2 Çalışmanın Sınırlılıkları

Bu çalışmada elde edilen sonuçlar oldukça yüksek performans değerleri göstermelerine rağmen, bazı sınırlılıkların dikkate alınması gerekmektedir. Öncelikle çalışmada kullanılan veri seti sentetik olarak üretilmiş el yazısı görüntülerinden oluşmaktadır. Sentetik veri üretimi, kontrollü veri çeşitliliği sağlama ve model geliştirme süreçlerini hızlandırma açısından önemli avantajlar sunmaktadır. Ancak gerçek dünyadaki el yazısı örnekleri; yazı stili, kalem basıncı, satır hizası, karakter aralıkları ve bireysel yazım alışkanlıkları açısından daha yüksek çeşitlilik göstermektedir. Bu nedenle model performansının gerçek dünya veri setleri üzerinde de değerlendirilmesi önem taşımaktadır.

Bir diğer sınırlılık, veri setinin belirli bir karakter kümesi ve sınıf yapısı üzerinden oluşturulmuş olmasıdır. Bu çalışmada harf nesneleri “normal”, “ters” ve “düzeltilmiş” olmak üzere üç sınıf altında değerlendirilmiştir. Ancak disleksi ile ilişkili yazım hataları yalnızca bu türlerle sınırlı olmayıp, karakter atlama, harf ekleme, harf sıralama hataları veya satır hizası bozulmaları gibi farklı biçimlerde de ortaya çıkabilmektedir. Bu nedenle gelecekte daha geniş bir hata tipolojisini kapsayan veri setlerinin oluşturulması modelin kapsamını genişletebilir.

Ayrıca çalışmada kullanılan model mimarisi YOLOv8n olarak seçilmiştir. Bu model, düşük hesaplama maliyeti ve hızlı çıkarım süresi avantajı sunmaktadır. Bununla birlikte, daha büyük model mimarilerinin veya farklı derin öğrenme yaklaşımlarının kullanılması durumunda performansın farklı veri koşullarında nasıl değişeceğinin incelenmesi de yararlı olabilir.

Son olarak, çalışmada kullanılan veri seti belirli bir dil yapısı ve karakter biçimine dayanmaktadır. Farklı alfabeler veya farklı yazım sistemleri kullanılan dillerde disleksi belirtileri farklı biçimlerde ortaya çıkabilmektedir. Bu nedenle yöntemin farklı dil ve yazı sistemlerine uyarlanabilirliğinin araştırılması önemli bir araştırma alanı olacaktır.

5.3 Gelecek Çalışmalar

Bu çalışmada elde edilen bulgular, el yazısı görüntülerinden disleksi belirtilerinin harf düzeyinde nesne algılama yaklaşımlarıyla başarılı biçimde tespit edilebileceğini göstermektedir. Bununla birlikte, gelecekte gerçekleştirilebilecek çalışmalar, yöntemin hem bilimsel hem de uygulamaya yönelik katkılarını daha da artırabilir.

Öncelikle, gerçek el yazısı örneklerinden oluşan daha geniş ve çeşitli veri setlerinin oluşturulması önemli bir araştırma yönü olarak görülmektedir. Özellikle farklı yaş gruplarındaki öğrencilerden elde edilen el yazısı örnekleri, modelin gerçek eğitim ortamlarında kullanılabilirliğini değerlendirmek açısından değerli olacaktır. Bu tür veri setleri, farklı yazı stilleri ve bireysel farklılıkların modele nasıl yansıdığını inceleme imkânı sağlayacaktır.

Bir diğer önemli araştırma yönü, model çıktılarının açıklanabilir yapay zekâ yöntemleri ile desteklenmesidir. Özellikle öğretmenler ve klinisyenler için geliştirilecek uygulamalarda modelin hangi görsel ipuçlarına dayanarak karar verdiğinin anlaşılabilir olması önem taşımaktadır. Bu nedenle Grad-CAM benzeri görselleştirme teknikleri veya dikkat haritaları kullanılarak model karar süreçlerinin daha şeffaf hale getirilmesi mümkündür.

Ayrıca, harf düzeyinde tespit edilen disleksi belirtilerinin zaman içinde değişimini inceleyen boylamsal çalışmalar da önemli katkılar sağlayabilir. Öğrencilerin belirli aralıklarla alınan yazı örneklerinin analiz edilmesi, öğrenme sürecindeki gelişimin veya müdahale programlarının etkisinin değerlendirilmesine yardımcı olabilir.

Son olarak, geliştirilen yaklaşımın eğitim teknolojileri ile entegre edilmesi de önemli

bir uygulama alanı sunmaktadır. Tablet tabanlı yazma uygulamaları veya dijital öğrenme platformları ile bütünleştirilecek otomatik analiz sistemleri, öğretmenlere hızlı geri bildirim sağlayarak erken disleksi taraması yapılmasına katkı sağlayabilir. Bu tür uygulamalar, öğrenme güçlüğü yaşayan çocukların erken dönemde desteklenmesine yardımcı olabilecek önemli araçlar sunabilir.

5.4. Genel Sonuç

Bu çalışmanın temel bilimsel katkısı, el yazısı görüntülerinden disleksi ile ilişkili görsel patenlerin harf düzeyinde nesne algılama yaklaşımı ile analiz edilebileceğini göstermesidir. Literatürdeki birçok çalışma el yazısı örneklerini sayfa veya kelime düzeyinde sınıflandırmaya odaklanırken, bu çalışmada her bir harf nesnesi ayrı bir analiz birimi olarak ele alınmıştır. Böylece disleksi ile ilişkilendirilebilen ters yazım ve düzeltilmiş karakter gibi hataların konumsal olarak belirlenebilmesi mümkün hale gelmiştir. YOLOv8n tabanlı nesne algılama yaklaşımının kullanılması sayesinde hem sınıflandırma hem de yerleştirme işlemleri tek bir model içinde gerçekleştirilmiş ve yüksek doğruluk oranları elde edilmiştir.

Ayrıca model performansının 5-katlı çapraz doğrulama yöntemi ile test edilmesi, elde edilen sonuçların veri bölünmelerine karşı kararlı olduğunu ve yöntemin genellenebilirliğinin yüksek olduğunu göstermektedir. Elde edilen bulgular, harf düzeyinde temsilin disleksi belirtilerinin otomatik tespiti açısından uygun bir analiz birimi olduğunu ortaya koymaktadır. Bu yönüyle çalışma, derin öğrenme tabanlı nesne algılama yaklaşımlarının eğitim teknolojileri ve öğrenme güçlüğü araştırmalarında kullanılabileceğine dair yeni bir yöntemsel çerçeve sunmaktadır.

Sonuçta bu çalışma, ana dili Türkçe olan disleksili çocukların el yazısı görüntüleri vasıtasıyla belirlenmesi için gerçek bir veri setinin oluşturulması suretiyle başlatılması planlanan çalışmalar için de bir motivasyon sağlamıştır.

KAYNAKÇA

- Alahmadi, N. A., & El Keshky, M. E. (2019). Assessing primary school teachers' knowledge of specific learning disabilities in the Kingdom of Saudi Arabia. *Journal of Educational and Developmental Psychology*, 9(1), 9–22.
- Aldehim G., Rashid M., Alluhaidan A. S., Sakri S. B., and Basheer S., (2024). Deep learning for dyslexia detection: A comprehensive CNN approach with handwriting analysis and benchmark comparisons. *Journal of Disability Research*, 3(2), 1-8.
- Alqahtani N.D., Alzahrani B., and Ramzan M.S. (2023). Deep learning applications for dyslexia prediction, *Applied Sciences*, 13(5), p. 2804.
- Alqahtani N.D., Alzahrani B., and Ramzan M.S. (2023). Detection of dyslexia through images of handwriting using a hybrid AI approach, *International Journal of Advanced Computer Science and Applications*, 14(10), 942-951.
- Ali, H., Muthudoss, P, Chauhan, C., Kaliappan, I., Kumar, D., Paudel, A., Ramasamy, G. (2023). Machine learning-enabled NIR spectroscopy. Part 3: Hyperparameter by design (HyD) based ANN-MLP optimization, model generalizability, and model transferability. *AAPS PharmSciTech*, 24(254).
- Algoasylum (2021). *Dyslexia detection*. [Erişim: 10.12.2025, https://github.com/algoasylum/Dyslexia_detection]
- Baggett, M. D. (2022). *Training future educators and speech language pathologists to identify indicators of specific learning disabilities in reading (dyslexia) and writing (dysgraphia) within handwriting samples*. University Of Nevada, The Graduate School, Reno.
- Baggett, M., Diamond, L. L., & Olszewski, A. (2023). Dysgraphia and Dyslexia Indicators: Analyzing Children's Writing. *Intervention in School and Clinic*, 59(5), 319-330.
- Barton, S. (2017, 13 Şubat). *How to spot dyslexia in a writing sample (Webinar)*. Bright Solutions for Dyslexia. Vimeo. [Erişim: 10.12.2025, <https://vimeo.com/203740803>]
- Berninger, V. W., Richards, T. L., & Abbott, R. D. (2015). Differential Diagnosis of Dysgraphia, Dyslexia, and OWL LD: Behavioral and Neuroimaging Evidence. *Reading and writing*, 28(8), 1119-1153.
- Bridges, M. S., & Kelley, E. (2023). Experiences and perceptions of school-based speech-language pathologists related to literacy: Results from a national survey. *Language, Speech, and Hearing Services in Schools*, 54(1), 189-197.
- Brooks, A. D., Berninger, V. W., & Abbott, R. D. (2011). Letter naming and letter writing reversals in children with dyslexia: Momentary inefficiency in the phonological and orthographic loops of working memory. *Developmental Neuropsychology*, 36(7), 847-868.
- Chung, P. J., Patel, D. R., & Nizami, I. (2020). Disorder of written expression and dysgraphia: Definition, diagnosis, and management. *Translational Pediatrics*, 9(1), 46-54.
- Collette, M. A. (1979). Dyslexia and classic pathognomic signs. *Perceptual and Motor Skills*, 48(3 suppl), 1055-1062.
- Fink, N. (2025). *Explainable YOLO-Based Dyslexia Detection in Synthetic Handwriting Data*, Cornell University, Computer Vision and Pattern Recognition. [Erişim: 10.12.2025, <https://arxiv.org/abs/2501.15263>]
- Geburu, T., Morgenstern, J., Vecchione, B., Vaughan, J.W., Wallach, H., Daumé, H., Crawford, K., (2018), *Datasheets for Datasets*. Communications of the ACM, 64(12), 86-92.
- Grother, P.J., Hanaoka K. K. (2016), *NIST Special Database 19: Handprinted Forms and Characters Database*, N.I. of Standards and Technology, U.S. Department of Commerce, United States.
- IDA (International Dyslexia Association) (2025), *Understanding Dysgraphia*. [Erişim: 10.12.2025, <https://dyslexiaida.org/understanding-dysgraphia-2/>]

- Isa, I. S., Zahir M. Ramlan A., S. A., Wang L.-C., and Sulaiman S. N. (2021). CNN comparisons models on dyslexia handwriting classification, *ESTEEM Academic Journal*, 17, 12-25.
- Isa, I. S., Rahimi, W. N. S., Ramlan, S. A., Sulaiman, S. N. (2019). Automated detection of dyslexia symptoms based on handwriting image for primary school children. *Procedia Computer Science*, 163, 440-449.
- Kandel, S., Lassus-Sangosse, D., Grosjacques, G., & Perret, C. (2017). The impact of developmental dyslexia and dysgraphia on movement production during word writing. *Cognitive Neuropsychology*, 34(3-4), 219-251.
- Koonce B. (2021). *MobileNetV3. Chapter 11: MobileNetV3, Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization*, Apress, Berkeley, CA, s. 125-144.
- Kostadin G. (2023), *Dyslexia*. [Erişim: 10.12.2025, https://github.com/kostadin-georgiev97/ct5129_dyslexia]
- Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., Spitzer, E., Raji, I.D., Gebru, T., (2019), *Model Cards for Model Reporting*. Model Cards for Model Reporting. In FAT* '19: Conference on Fairness, Accountability, and Transparency, Atlanta, GA, USA.
- Nelson, N. W. (2010). *Language and literacy disorders: Infancy through adolescence* (1st ed.), Allyn & Bacon, Boston, USA.
- NVIDIA (2025), *NVIDIA A100 Tensor Core GPU*, Data Center. [Erişim: 10.12.2025, <https://www.nvidia.com/en-us/data-center/a100>]
- NVIDIA Developer (2005), *CUDA Toolkit*. [Erişim: 10.12.2025, <https://www.developer.nvidia.com/cuda-toolkit>]
- Patel, S. (2017), *A-Z Handwritten Alphabets in .csv format*, Kaggle. [Erişim: 10.12.2025, <https://www.kaggle.com/sachinpatel21/az-handwritten-alphabets-in-csv-format>]
- Patil S.P., Apare R.S., Borhade R.H., Mahalle P.N. (2024). Automated Dyslexia Screening Using Children's Handwriting in English Language with Convolutional Neural Network and Bidirectional Long Short-Term Memory Model, *Engineered Science Journal*. 32, 1345.
- Python (2005), *Python Web Sitesi*. [Erişim: 10.12.2025, <https://www.python.org>]
- PyTorch (2005), *PyTorch Web Sitesi*. [Erişim: 10.12.2025, <https://www.pytorch.org>]
- Robaa M., Balat M., Awaad R., Omar E., Aly S.A. (2024). *Explainable AI in Handwriting Detection for Dyslexia Using Transfer Learning*, JAC-ECC Computer Vision and Pattern Recognition Conference. [Erişim: 10.12.2025, <https://doi.org/10.48550/arXiv.2410.19821>]
- Rosli, A. B., Isa, I. S., Ramlan, S. A., Sulaiman, S. N., Maruzuki, M. I. F. (2021). *Development of CNN Transfer Learning for Dyslexia Handwriting Recognition*, 11th IEEE International Conference on Control System, Computing and Engineering (ICCSCE), 194-199.
- Schurtz, M., Wimmer, H., Richlan, F., Ludersdorfer, P., Klackl, J., Kronbichler, M. (2015). Resting-state and task-based functional brain connectivity in developmental dyslexia. *Cerebral Cortex*, 25, 3502-3514.
- scikit-learn (2005), *scikit-learn, Machine Learning in Python*, [Erişim: 10.12.2025, <https://scikit-learn.org/stable/>].
- Sela, I., Izzetoglu, M., Izzetoglu, K., & Onaral, B. (2012). *A Functional Near-Infrared Spectroscopy Study of Lexical Decision Task Supports the Dual Route Model and the Phonological Deficit Theory of Dyslexia*. *Journal of Learning Disabilities*, 47(3), 279-288.
- Seman, N. S. L., Isa, I. S., Ramlan, S. A., Li-Chih, W., Maruzuki, M. I. F. (2021). *Notice of Removal: Classification of Handwriting Impairment Using CNN for Potential Dyslexia*

- Symptom*, 11th IEEE International Conference on Control System, Computing and Engineering (ICCSCE), 188-193.
- Shengchi Foundation (2025), *Can Identifying One Missing Micro-Skill Help You Overcome Dyslexia?* [Erişim: 10.12.2025, <https://shengchifoundation.org/analysis-dyslexia-test/>]
- Shrishtinagam (2022), *Dyslexic Character Recognition*. [Erişim: 10.12.2025, <https://github.com/shrishtinagam/dyslexic-character-recognition>]
- Sumner, E., Connelly, V., & Barnett, A. L. (2012). Children with dyslexia are slow writers because they pause more often and not because they are slow at handwriting execution. *Reading and Writing*, 26(6), 991-1008.
- Therapy, C. R., (2025), *33 Dyslexia Statistics & Facts: How Many People Have Dyslexia?* [Erişim: 10.12.2025, <https://www.crossrivertherapy.com/research/dyslexia-statistics>]
- Ultralytics 1 (2023), *Nesne Algulama*. [Erişim: 10.12.2025, <https://docs.ultralytics.com/tasks/detect/>]
- Ultralytics 2 (2023), *YOLO Performance Metrics*. [Erişim: 10.12.2025, <https://docs.ultralytics.com/guides/yolo-performance-metrics/>]
- Ultralytics 3 (2023), *YOLO ile Model Doğrulama*. [Erişim: 10.12.2025, <https://docs.ultralytics.com/tr/modes/val/>]
- Ultralytics 4 (2023), *Komut Satırı Arayüzü*. [Erişim: 10.12.2025, <https://docs.ultralytics.com/tr/usage/cli/>]
- Walsh, K., Glaser, D., and Wilcox, D. (2006). *What Education Schools Aren't Teaching About Reading and What Elementary Teachers Aren't Learning*. National Council on Teacher Quality, Washington, DC.
- Yaseen, M. (2024). *What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector*. [Erişim: 10.12.2025, <https://arxiv.org/html/2408.15857>]
- Zenodo (2025), *Synthetic Dyslexia Handwriting Dataset (YOLO-Format) v1*. [Erişim: 10.12.2025, <https://zenodo.org/records/14852659>]
- Zhang H. and Ogasawara K. (2023). Grad-cam-based explainable artificial intelligence related to medical text processing. *Bioengineering*, 10(9), 1070.