

YOLOv8n MODELİ İLE EL YAZISI GÖRÜNTÜLERİNDEN HARF DÜZEYİNDE DİSLEKSİ BELİRTİLERİNİN TESPİTİ

Lisansüstü Öğrencisi Rumeysa GEÇGÜN¹, Prof. Dr. Ahmet AKBAŞ², Dr. Öğr. Üyesi Hakan ÜÇGÜN³

¹Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı
Tezli Yüksek Lisans Öğrencisi, Bilecik, Türkiye rumeysagecgun@gmail.com, 0009-0007-4228-1583

²Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Bilecik, Türkiye
ahmet.akbas@bilecik.edu.tr, ORCID ID: 0000-0002-9448-0679

³Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Bilecik, Türkiye
hakan.ucgun@bilecik.edu.tr, ORCID ID: 0000-0002-9448-0679

Özet

Bu çalışmada, el yazısı görüntülerinden harf düzeyinde disleksi belirtilerini tespit etmek için YOLOv8n derin öğrenme modeline dayalı bir sınıflandırma yöntemi önerilmiş ve 5-katlı eğitim ve çapraz doğrulama yaklaşımı ile test edilmiştir. Bu amaçla kullanılan veri seti, YOLO biçiminde harf kutuları ve sınıf etiketlerini (Normal, Ters ve 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 harf düzeyindeki disleksi paternlerini yüksek bir doğrulukla belirlediğini ve yerleştirdiğini göstermektedir. Bu yaklaşım, veri etiketleme düzeyi ile aynı düzlemde çalışan harf düzeyinde bir boru hattı kurarak, sonuçları sınıf ve kat bazında ayrıntılı raporlamakta ve yerleştirilmiş çıktılarla disleksi tedavisi ile ilgili eğitim süreçlerine geri bildirim yapma imkânı sunmaktadır.

Anahtar Kelimeler: Disleksi belirtisi tespiti, El yazısı analizi, Harf Düzeyinde Özellik Çıkarma, YOLOv8n.

DETECTING LETTER-LEVEL DYSLEXIA SYMPTOMS FROM HANDWRITING IMAGES WITH YOLOv8n MODEL

Abstract

In this study, a classification method based on the YOLOv8n deep learning model detecting dyslexia symptoms at the letter level in handwritten images is proposed and tested using a 5-fold training and cross-validation approach. The dataset used for this purpose consists of images containing letter boxes and class labels (Normal, Inverse, and 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 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: Dyslexia symptom detection, Handwriting analysis, Letter-Level Feature Extraction, YOLOv8n.

1. GİRİŞ

Disleksi, doğru ve/veya akıcı kelime tanımada zorluk ve kelime yazım ve kod çözme (heceleme) becerilerinin zayıf olmasıyla karakterize olan ve okuma becerilerinin yanı sıra yazma becerilerini de etkileyen nörogelişimsel bir bozukluktur. Burada kelime tanıma zorluğu genellikle dilin fonolojik bir bileşenin eksikliğinden kaynaklanmaktadır (IDA, 2025).

Disleksi, sosyal başarı ve akademik performansı yazmanın yanı sıra okuma ve heceleme bozuklukları nedeniyle de olumsuz yönde etkileyebilir. 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 bozukluk (Berninger vd., 2015), akademik performansı daha üst düzey okuma parçaları ve kod çözme becerilerinin gerekli olduğu ileri sınıflara kadar etkileyebilir (Chung vd., 2020; Nelson 2010).

Araştırmalar, dünyanın çeşitli bölgelerinde eğitimcilerin disleksi 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, disleksi 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, disleksinin özellikle çocuk eğitimi süreçlerinde yapılması gereken taramalarla otomatik olarak tanınması, ileri yaşlarda ortaya çıkabilecek başarısızlık riskini ortadan kaldırmak açısından kritik bir öneme sahiptir.

1.1. Bir Eğitim ve Sağlık Sorunu Olarak Disleksi

Disleksi, tanı ve tedavisi hem eğitim ve 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 disleksi özüllü olup olmadığı 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 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 gösterge 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 (çevrim-içi) ve yazma süreci tamamlandıktan sonra (çevrim-dışı) 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. Disleksi sorunu yaşayan çocukların yazılarında sıklıkla kötü dil bilgisi, harfleri ters yazma ve yavaş veya zorlayıcı yazma gibi hatalı durumlar görülür (Barton, 2017; Brooks vd., 2011; Collette, 1979; Kandel vd., 2017; Sumner vd., 2012). Bu kapsamda yapılan bir başka çalışmada, eğitimciler tarafından hazırlanan bir teste internet üzerinden yapılan çevrim-içi oturumlarda verilen cevaplara bağlı olarak disleksi tanısı konmaktadır (Shengchi Foundation, 2025).

Disleksi 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/veya 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). 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 iştiraki ile 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, disleksiye 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 disleksi tanı ve tedavisi ile ilgili yeni araştırmaları gündeme taşımaktadır.

1.2. El Yazısı Görüntülerinde Disleksi Belirtilerinin Tespiti

Yukarıdaki kısa literatür taraması, disleksi 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 itibariyle yaygın kullanım açısından uygun değildir. Bu durum, disleksi tanısı için daha kolay, daha hızlı ve etkin sonuçların alınabileceği yeni arayışları gündeme taşımaktadır. Özellikle çocuk eğitimi süreçlerinde disleksi 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 (Shrishtinagam, 2022). 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 imkân sağlayan eğitimlerle birlikte test süreçleri de tekrarlanmaktadır. Bu amaçla kullanılan veri seti, NIST veri tabanından alınan büyük harfler (Grother, 2016), Kaggle veri setinden alınan küçük harfler (Patel, 2017), 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 konumu 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 literature 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 YOLOv11 modeline göre 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 eğitmenlere geri bildirimini 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

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 çevrelenir 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 bazında sınıflandırma,
- Hata tipini kelime veya harf düzeyinde yerleştirme ile 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.

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, öznelik 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 kullanılabileceği, 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 metnin hangi konumunda oluştuğunu açıkça göstermediğinden eğitim süreçleri için gerekli geri bildirim sağlamamaktadır.

Bu eksiklik kelime/harf düzeyinde yerleştirerek sınıflandırma yaklaşımıyla giderilmiştir. Bu kapsamdaki çalışmalar son dönemde YOLO ailesi vasıtasıyla gerçekleştirilen kelime/harf kutuları üzerindeki hata tipini tespiti 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 eş zamanlı 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 kullanılabilecek 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. 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, bu aşamada yukarıda anılan sentetik veri seti kullanılarak bir sınıflandırıcı tasarımının gerçekleştirilmesi ve böylece ilerdeki 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 1’de gösterilmiştir.



Şekil 1. Aynı harfin üç farklı sınıftaki görüntü örnekleri (Patil vd., 2024)

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 veri tabanından (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 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.

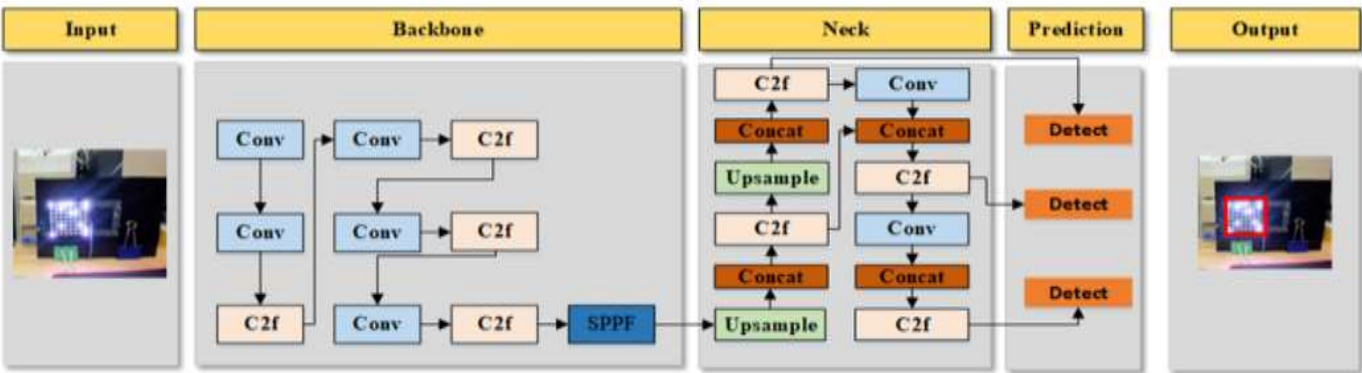
Sentetik veri setindeki her görüntüde, siyah bir arka plan üzerinde Normal, Ters ve Düzeltilmiş sınıflarından harfler bir metin satırı şeklinde birleştirilmiş ve her harfi sınırlayan kutular YOLO uyumlu .txt ekleri ile birlikte tanımlanmıştır. Buna göre, orijinal veri setinin eğitim ve doğrulama bölümlerinde yer alan birer görüntü örneği Şekil 2’de sunulmuştur.



Şekil 2. Sentetik veri setinden birer eğitim ve doğrulama görüntüsü (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 yerleştirme ve sınıflandırma görevlerini uçtan uca tek bir sinir ağına 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’te gösterilen üç temel modülden oluşur: Omurga (Backbone), Boyun (Neck) ve Baş (Prediction).



Şekil 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 yaklaşımı 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 4. Buna göre, en alt model olan YOLOv8n, daha hızlı çıkarım süreleri ve daha düşük doğruluk sağlamaktadır.



Şekil 4. YOLOv8 FPN mimarisinin farklı düzenlenme alternatifleri (Yaseen, 2024)

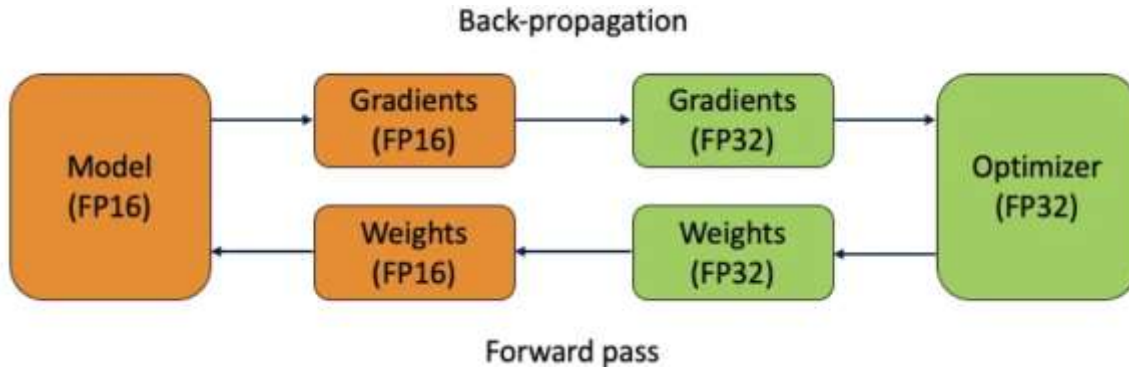
3.3. YOLOv8 Modelinin Eğitimi

YOLOv8'in nesne tespitinde sağladığı yüksek performans, yalnız mimari geliştirmelerle değil aynı zamanda gelişmiş eğitim metodolojileri ile de ilgilidir. Bu kapsamda model genellemesini geliştiren mozaik artırma ve karıştırma gibi bir dizi yeni veri artırma stratejisi ile, sınıflandırılması zor örnekler için 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

hesaplama 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 imkan sağlar, Şekil 5.

Bu çalışmada YOLOv8 modelinin eğitim süreci GPU (CUDA) destekli olarak gerçekleştirilmiş, yüksek işlem hacmi bu sayede 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:



Şekil 5. YOLOv8 eğitim sürecinde karma hassasiyet kullanımı (İsa vd., 2023)

Bu çalışmada YOLOv8 modelinin eğitim süreci GPU (CUDA) destekli olarak gerçekleştirilmiş, yüksek işlem hacmi bu sayede 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. 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 ölçütlerinden (metrikler) bu çalışmada kullanılanlar 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.

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

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 normalleştirilmiş koordinatlarını (class, center_x, center_y, genişlik, yükseklik) içerir. 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 (Gebru 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 dış 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 (NVIDIA, 2025). 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. Veri setinin 5-katlı eğitim ve test süreçleri için bölümlendirilmesi ve test sonuçlarının görselleştirilmesinde Scikit-learn kütüphane fonksiyonlarından (KFold, Confusion Matrix Display) 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 bölümlendirildiği bu veri seti, Zenodo üzerinde Synthetic Dyslexia Handwriting (YOLO-Format) başlığı altında erişime açıktır (Zenodo, 2025). 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.

Veri setinde toplam 165032 kutulanmış nesnenin sınıflara dağılımı şu şekildedir: sınıf 0: 55647, sınıf 1: 55336, sınıf 2: 54049.

5-katlı eğitim ve doğrulama testleri için yapılan parametre ayarları 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, eğitilen YOLOv8 modelinin 5-katlı çapraz doğrulama testlerinin her katında doğrulama için veri setinden 550 civarında görüntü seçilmiştir. Bu görüntülerde toplam olarak 33000 civarında harf nesnesi yer almaktadır. Bunların sınıflandırma başarısı Kesinlik (Precision), Hatırlama (Recall), mAP50 ve mAP50-95 metriklerine göre değerlendirilmiştir.

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. Etiketleme harf kutuları bazında yapıldığından, test sonuçları harf düzeyinde tespit edilen sınıf atamalarına göre belirlenmiştir. Buna göre, 5-katlı çapraz doğrulama testlerinin;

- 1.katında veri setinden eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 33179'dur.
- 2.katında veri setinden eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu sayısı 32953'dür.
- 3.katında veri setinden eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 32792'dir.
- 4.katında veri setinden eğitim için 2191, test için de 548 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu sayısı 33159'dur.
- 5.katında veri setinden eğitim için 2192, test için de 547 görüntü seçilerek kullanılmıştır. Bu görüntülerdeki toplam kutu (harf nesnesi) sayısı 32949'dur.

5-katlı çapraz doğrulama testlerinin yukarıda ayrıntılı olarak verilen sonuçları Tablo 1'de toplu olarak verilmiştir.

Tablo 1. 5-katlı çapraz doğrulama testlerinin toplu sonuçları

Kat (Fold)	Precision	Recall	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
Ortalama	0.9996	0.9995	0.9950	0.9947

Bu sonuçlar, sınıflandırma başarısının ortalama %99.96 kesinlik ve %99,95 hatırlama oranlarıyla YOLOv11 modeli ile elde edilen mükemmel performansın daha az işlem gücü gerektiren YOLOv8n modeli ile de elde edilebileceğini göstermektedir. Üstelik sonuçların 5-katlı çapraz doğrulama yöntemi ile doğrulanmış olması, modelin gürbüzlüğünü göstermesi açısından anlamlıdır. Bu yaklaşım ayrıca, bu çalışmada kullanılanlardan daha az

sayıdaki görüntüden oluşan bir veri setinin bile harf düzeyindeki disleksi belirtilerini başarılı bir şekilde tespit edebilen YOLOv8n esaslı sınıflandırma modellerinin geliştirilmesi için yeterli olabileceği yönündeki beklentiyi güçlendirmiştir.

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 eşleştirilmiş; bu sayede karakter parçalanmasından kaynaklanan hata zinciri en aza indirilmiştir.

5-katlı testler sonucunda sınıf bazında değerlendirme için oluşturulan tablolar ve karmaşıklık matrisleri, katlar arasında tutarlı bir performans profili oluştuğunu göstermektedir. Özellikle bütün sınıflardaki yüksek kesinlik ve hatırlama 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. Bununla beraber, sentetik görüntüleri işleyerek ulaşılan bu sonuçlara güvenmekle, görüntüdeki boşluk alanlarının nasıl değerlendirildiğine ilişkin endişeler oluşabilir. Ancak, yapılan denemeler daha hızlı ve daha yorumlanabilir disleksi taraması için 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 çalışmaların yapılması beklenmektedir. Bu çalışmalar, diğer dilleri ve daha derin açıklanabilirlik yöntemlerini de kapsayacaktır.

Sonuç olarak, bu çalışmanın devamında 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 sağlanmıştır.

KAYNAKLAR

- 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, <https://doi.org/10.5539/jedp.v9n1p9>.
- 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*, vol. 3, no. 2, p. 20240010.
- Alqahtani N.D., Alzahrani B., and Ramzan M.S. (2023). “Deep learning applications for dyslexia prediction,” *Applied Sciences*, vol. 13, no. 5, p. 2804. (1)
- 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*, vol. 14, 01. (2)
- 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, <https://doi.org/10.1208/s12249-023-02697-3>.
- Algoasylum, (2021), Dyslexia detection, accessed 2025-12-10. Online Available: 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. Proquest Dissertations Publishing.
- 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, <https://doi.org/10.1177/10534512231189449>.
- Barton, S. (2017). How to spot dyslexia in a writing sample. Bright Solutions for Dyslexia; Vimeo. <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, 1119–1153, <https://doi.org/10.1007/s11145-015-9565-0>.
- 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. https://doi.org/10.1044/2022_LSHSS-22-00010.
- 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, <https://doi.org/10.1080/87565641.2011.606401>.
- Chung, P. J., Patel, D. R., & Nizami, I. (2020). Disorder of written expression and dysgraphia: Definition, diagnosis, and management. *Translational Pediatrics*, 9(S1), S46–S54, <https://doi.org/10.21037/tp.2019.11.01>.
- Collette, M. A. (1979). Dyslexia and classic pathognomic signs. *Perceptual and Motor Skills*, 48, 1055–1062, <https://doi.org/10.2466/pms.1979.48.3c.1055>.
- Fink, N. (2025). "Explainable YOLO-Based Dyslexia Detection in Synthetic Handwriting Data", *Computer Vision and Pattern Recognition*, Cornell University, arXiv:2501.15263, <https://arxiv.org/abs/2501.15263>.
- Gebru, T., Morgenstern, J., Vecchione, B., Vaughan, J.W., Wallach, H., Daumé, H., Crawford, K., (2018), Datasheets for Datasets, <https://doi.org/10.48550/arXiv.1803.09010>.
- Grother, P.J. (2016), "NIST Special Database 19: Handprinted Forms and Characters Database", N.I. of Standards and Technology, NIST Special, Available online: <https://www.nist.gov/srd/nist-special-database-19>.
- IDA (International Dyslexia Association) (2025), Understanding dysgraphia, Erişim Tarihi:(2025-12-10) Online Available: <https://dyslexiaida.org/understanding-dysgraphia-/2>.
- Isa, I. S. (2021). CNN Comparisons Models On Dyslexia Handwriting Classification, *ESTEEM Academic Journal*, Vol. 17, March 2021, 12-25.
- 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*, vol. 17, p. 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, <https://doi.org/10.1080/02643294.2017.1389706>.
- Koonce B. (2021). “Mobilenetv3,” Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization, p. 125–144.
- Kostadin G. (2023), Dyslexia, accessed 2025-12-10. Online Available: 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, <https://doi.org/10.48550/arXiv.1810.03993>.
- Nelson, N. W. (2010). *Language and literacy disorders: Infancy through adolescence* (1st ed.), Allyn & Bacon.
- NVIDIA (2025), NVIDIA A100 Tensor Core GPU, accessed 2025-12-10. Online Available: <https://www.nvidia.com/en-us/data-center/a100/>.
- NVIDIA Developer (2005), CUDA Toolkit, accessed 2025-12-10. Online Available: <https://www.developer.nvidia.com/cuda-toolkit>.
- Patel, S. (2017), “A-Z Handwritten Alphabets in .csv format,” Kaggle. accessed 2025-12-10. Online Available <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”, 2024: *Engineered Science Journal*, vol. 32, 1345.
- Python (2005), Python Web Sitesi, accessed 2025-12-10. Online Available: <https://www.python.org/>.
- PyTorch (2005), PyTorch Web Sitesi, accessed 2025-12-10. Online Available: <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*, Available online: <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), p. 194–199, <https://doi.org/10.1109/ICCSCE52189.2021.9530971>.
- 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, <https://doi.org/10.1093/cercor/bhu184>.
- scikit-learn (2005), scikit-learn Machine Learning in Python, <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, <https://doi.org/10.1177/0022219412451998>.



- 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), p. 188–193, <https://doi.org/10.1109/ICCSCE52189.2021.9530989>
- Shengchi Foundation (2025), Can identifying one missing micro-skill help you overcome dyslexia? accessed 2025-12-10. Online Available: <https://shengchifoundation.org/analysis-dyslexia-test/>.
- Shrishtinagam (2022), Dyslexic Character Recognition, accessed 2025-12-10. Online Available: <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, <https://doi.org/10.1007/s11145-012-9403-6>.
- Therapy, C. R., (2025), "33 dyslexia statistics & facts: How many people have dyslexia?", accessed 2025-12-10. Online Available: <https://www.crossrivertherapy.com/research/dyslexia-statistics>.
- Ultralytics 1 (2023), Nesne Algılama, accessed 2025-12-10. Online Available: <https://docs.ultralytics.com/tasks/detect/>.
- Ultralytics 2 (2023), YOLO Performance Metrics, <https://docs.ultralytics.com/guides/yolo-performance-metrics/>
- Ultralytics 3 (2023), YOLO ile Model Doğrulama, accessed 2025-12-10. Online Available: <https://docs.ultralytics.com/tr/modes/val/>.
- Ultralytics 4 (2023), Komut Satırı Arayüzü, accessed 2025-12-10. Online Available: <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.
- Yaseen, M. (2024). "What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector", arXiv:2408.15857v1, <https://arxiv.org/html/2408.15857>.
- Zenodo (2025), Synthetic Dyslexia Handwriting Dataset (YOLO-Format) v1, accessed 2025-12-10. Online Available: <https://zenodo.org/records/14852659>, DOI: 10.5281/zenodo.14852659.
- Zhang H. and Ogasawara K. (2023). "Grad-cam-based explainable artificial intelligence related to medical text processing," *Bioengineering*, vol. 10, no. 9, p. 1070.