

El Yazısı Karakterlerin Tanınmasında Derin Sinir Ağlarının Etkinliği Kısıtlı ve Geniş Sınıf Yapılarının Performans Analizi

Erdin FİDAN ^{1*}, Mahir KAYA ²

^{1,2} Bilgisayar Mühendisliği, Tokat Gaziosmanpaşa Üniversitesi, Türkiye (erdin.fidan6425@gop.edu.tr, mahir.kaya@gop.edu.tr)

Özet – Bu çalışmada, el yazısı karakterlerin tanınmasına yönelik derin öğrenme tabanlı bir model geliştirilmiştir. Model, farklı sayıda çıkış sınıfı (karakter) için test edilmiş; yalnızca 10 karakterin sınıflandırıldığı senaryoda %96 doğruluk oranı elde edilirken, sınıf sayısı 62'ye çıkarıldığında %86 doğruluk oranı yakalanmıştır. Elde edilen sonuçlar, sınıf sayısının artmasının model performansı üzerindeki etkisini açıkça göstermekte ve karakter çeşitliliği arttıkça sınıflandırma probleminin daha karmaşık hâle geldiğini ortaya koymaktadır. Bu bağlamda, önerilen modelin çok sınıflı karakter tanıma görevlerinde yüksek doğrulukla çalışabildiği görülmüş ve modelin performansı sınıf sayısına bağlı olarak detaylı şekilde analiz edilmiştir. Ayrıca, modelin eğitimi iki aşamalı olarak planlanmış olup, ilk olarak SGD optimizasyon algoritması ile temel öğrenme sağlanmış, ardından Adam algoritması ile model ince ayar (fine-tuning) sürecine tabi tutulmuştur.

Anahtar Kelimeler – El Yazısı Tanıma, Derin Öğrenme, Konvolüsyonel Sinir Ağı, Batch Normalization, Dropout, Sınıflandırma, Karakter Tanıma

Effectiveness of Deep Neural Networks in Handwritten Character Recognition Performance Analysis of Limited and Extensive Class Structures

Abstract – In this study, a deep learning-based model was developed for handwritten character recognition. The model was tested with varying numbers of output classes (characters); while an accuracy rate of 96% was achieved in the scenario with only 10 character classes, an accuracy of 86% was obtained when the number of classes was increased to 62. The results clearly demonstrate the impact of the number of classes on model performance, revealing that the classification task becomes more complex as character variety increases. In this context, the proposed model was shown to perform with high accuracy in multi-class character recognition tasks, and its performance was analyzed in detail based on the number of classes. Additionally, the model training was planned in two stages: initial learning was conducted using the SGD optimization algorithm, followed by a fine-tuning process with the Adam algorithm.

Keywords – Handwriting Recognition, Deep Learning, Convolutional Neural Network, Batch Normalization, Dropout, Classification, Character Recognition

I. GİRİŞ

Görüntü sınıflandırma, bilgisayarla görme ve makine öğrenimi alanlarının en temel ve yaygın uygulamalarından biridir. El yazısı karakter tanıma, otonom araçlar, tıbbi görüntü analizi ve güvenlik sistemleri gibi birçok alanda, görüntülerin doğru sınıflara atanması kritik öneme sahiptir. Özellikle çok sınıflı (multi-class) sınıflandırma problemleri, sınıf sayısının artmasıyla birlikte daha karmaşık hale gelmekte ve geleneksel makine öğrenimi yöntemleri bu tür problemler karşısında yetersiz kalabilmektedir [1],[2].

Bu bağlamda, derin öğrenme mimarilerinin ortaya çıkışı, görüntü sınıflandırma alanında devrim yaratmıştır. Özellikle Evrişimli Sinir Ağları (ESA) yapıları, görüntülerdeki uzamsal ilişkileri başarıyla öğrenebilmesi sayesinde yüksek doğruluk oranlarına ulaşmayı mümkün kılmıştır [3]. Ancak, klasik ESA modelleri sınırlı sayıda katmana sahip olup, büyük ve karmaşık veri setlerinde yeterli genelleme yeteneği

gösteremeyebilirler. Bu nedenle son yıllarda daha derin, daha modüler ve parametre açısından optimize edilmiş CNN mimarileri üzerine çalışmalar yoğunlaşmıştır [4].

Bu çalışmada, 62 farklı sınıftan oluşan bir görüntü veri kümesi üzerinde yüksek başarı elde edebilmek amacıyla, gelişmiş bir CNN mimarisi tasarlanmıştır. Model, klasik konvolüsyon katmanlarının yanı sıra SeparableConv2D, BatchNormalization ve Dropout gibi bileşenleri içermektedir. Önerilen model karakter sınıflandırması işlemini başarılı bir şekilde gerçekleştirmektedir.

II. İLGİLİ ÇALIŞMALAR

Görüntü işleme, dijital görsellerin sayısal olarak analiz edilip işlenmesini sağlayan bir alandır. Bu alanda geleneksel yöntemler genellikle kenar tespiti (edge detection), histogram eşitleme ve filtreleme gibi tekniklerle sınırlı kalmaktaydı. Ancak son yıllarda derin öğrenme (Deep Learning)

tekniklerinin gelişmesiyle birlikte görüntü işleme görevlerinde büyük ilerlemeler sağlanmıştır [5].

Konvolüsyonel Sinir Ağları (CNN), görüntü tanıma ve sınıflandırma gibi görevlerde yaygın olarak kullanılan bir derin öğrenme mimarisidir. CNN'ler, görüntülerdeki uzamsal ilişkileri yakalayabilen konvolüsyon filtreleri sayesinde geleneksel yöntemlere göre çok daha yüksek başarı oranları sunmaktadır [6].

A. Derin Öğrenme ve CNN'lerin Yükselişi

2012 yılında Krizhevsky, Sutskever ve Hinton tarafından geliştirilen AlexNet modeli, ImageNet yarışmasında birinci gelerek derin öğrenmenin gücünü tüm dünyaya göstermiştir. Bu model, ilk defa çok katmanlı bir CNN mimarisinin büyük bir görüntü veri kümesinde klasik yöntemlerden çok daha üstün performans gösterdiğini kanıtlamıştır. Ardından gelen VGGNet, GoogLeNet (Inception), ResNet, ve DenseNet gibi derin mimariler, katman sayısını artırarak veya farklı yapılar deneyerek performansı daha da ileri taşımıştır. [7]

Derin Konvolüsyonel Sinir Ağları (CNN'ler), görüntü sınıflandırma ve nesne tanıma gibi bilgisayarla görme görevlerinde yüksek başarı göstermiştir. CNN'ler, görüntü verisinden otomatik olarak anlamlı öznitelikler çıkarabilmekte ve bu sayede klasik yöntemlere göre daha üstün performans sağlamaktadır. Çok katmanlı yapıları sayesinde hem düşük seviyeli hem de yüksek seviyeli özellikleri hiyerarşik olarak öğrenebilme yeteneğine sahiptirler [8].

Özellikle ResNet mimarisi, "residual connection" yaklaşımı sayesinde çok derin ağların eğitiminde yaşanan gradyan sönümlenmesi (vanishing gradient) problemini aşarak, 100'den fazla katmana sahip ağların başarılı şekilde eğitilmesine olanak tanımıştır.

B. Aktivasyon Fonksiyonları ve Normalizasyon Yöntemleri

CNN performansını etkileyen önemli unsurlardan biri de aktivasyon fonksiyonlarıdır. Uzun süre ReLU (Rectified Linear Unit) fonksiyonu standart olarak kullanılmıştır. Aynı şekilde, BatchNormalization ve LayerNormalization gibi normalizasyon teknikleri, eğitim sürecini istikrarlı hale getirerek daha hızlı ve başarılı öğrenmeyi mümkün kılmıştır.

C. Optimizasyon Teknikleri

Derin öğrenme modellerinin eğitimi sırasında kullanılan optimizasyon algoritmaları da modelin başarısı açısından belirleyici rol oynamaktadır. Klasik Stochastic Gradient Descent (SGD) algoritması, momentum ve learning rate ayarlamaları ile birlikte iyi sonuçlar verebilse de, günümüzde Adam, RMSprop, Nadam gibi daha gelişmiş optimizasyon yöntemleri tercih edilmektedir. Bu algoritmalar adaptif öğrenme oranları sayesinde daha hızlı yakınsama sağlayabilmektedir.

El yazısı karakter tanıma, karakterlerin dijital ortamda yorumlanmasını sağlayan klasik bir bilgisayarla görme problemidir. Bu alanda en yaygın kullanılan veri setlerinden biri MNIST olup, 0-9 arası rakamları içerir [1]. Ancak, daha geniş karakter kümeleri için farklı veri setleri geliştirilmiştir.

- EMNIST: MNIST'in genişletilmiş versiyonu olan EMNIST, hem harf hem rakamları içerir ve 62 sınıfa kadar tanım yapmayı mümkün kılar [9].
- Chars74K: İngilizce büyük/küçük harfler ile bazı semboller içeren 74.000'den fazla görüntüden oluşur [10].
- Kuzushiji-MNIST: Japonca eski yazı karakterlerinin tanınması amacıyla geliştirilmiştir [11].

- Arabic Handwritten Characters Dataset (AHCD): Arap alfabesinin el yazısı ile yazılmış karakterlerini barındırır [12].

Bu veri setleri, çok sınıflı sınıflandırma problemleriyle başa çıkabilen modellerin geliştirilmesini teşvik etmiştir.

D. Çok Sınıflı Sınıflandırma Problemleri

Çok sayıda sınıfa sahip görüntü sınıflandırma problemleri, iki temel zorluğu beraberinde getirir: sınıflar arası ayrımın zorlaşması ve veri setindeki sınıf dengesizlikleri. Literatürde bu problemleri çözmek amacıyla veri artırma (data augmentation), sınıf ağırlıklı kayıplar (class-weighted loss functions) ve focal loss gibi çeşitli yaklaşımlar önerilmiştir [13, 14].

EMNIST Dataset Üzerine Yapılan Çalışmalar:

Cohen ve arkadaşları EMNIST veri kümesini tanıtarak temel bir CNN modeliyle Balanced subset üzerinde %87,9 doğruluk raporlamıştır [9]. Afzal ve arkadaşları, CNN ile LSTM katmanlarını birleştirdikleri modelde EMNIST Letters alt kümesi üzerinde %89,3 doğruluk ve %87,1 F1-score elde etmiştir [15].

Chars74K Dataset Üzerine:

Klasik öznitelik çıkarım yöntemleriyle yapılan ilk çalışmalar yalnızca %62 doğruluk elde etmiştir. Ancak derin öğrenme yöntemlerinin yükselmesiyle, Jaderberg ve arkadaşları CNN tabanlı modellerle %85,5 doğruluk ve %84,7 F1-score seviyelerine ulaşmıştır [16].

Kuzushiji-MNIST Dataset:

Clanuwat ve arkadaşları, temel CNN mimarisiyle %96,4 doğruluk ve %96,1 F1-score elde etmiştir [11]. Miyazaki & Kitamoto daha derin bir ResNet mimarisi ile bu başarıyı %98,2 doğruluk ve %97,9 F1-score'a çıkarmıştır [17].

Arabic Handwritten Characters Dataset (AHCD):

Jindal ve arkadaşları önerdikleri CNN mimarisiyle %94,2 doğruluk ve %93,7 F1-score elde etmiştir [12]. Alginahi ve ekibi, CNN ve RNN modellerini birleştirerek %96,8 doğruluk, %95,4 F1-score'a ulaşmıştır [18].

E. Bu Çalışmanın Katkısı

Literatürdeki bu gelişmeler doğrultusunda, bu çalışmada önerilen CNN modeli hem derinlik hem de mimari tasarımı açısından güncel tekniklerden faydalanmakta; SeparableConv2D katmanları ve BatchNormalization bileşenleriyle optimize edilmiştir. Ayrıca iki aşamalı optimizasyon yaklaşımı (SGD + Adam), modelin genel başarımını artırmada etkili olmuştur. Mevcut literatürde bu mimari kombinasyonu ve eğitim stratejisini barındıran az sayıda çalışma bulunmakta olup, bu bağlamda çalışma, yeni bir bakış açısı sunmayı hedeflemektedir.

III. MATERYAL VE METOT

Bu çalışmada, el yazısı karakterlerin sınıflandırılması amacıyla Evrişimli Sinir Ağı (ESA) tabanlı bir model tasarlanmış ve farklı sınıf sayılarıyla test edilmiştir. Aşağıda kullanılan veri seti, ön işleme süreci, model mimarisi ve eğitim parametreleri detaylı olarak sunulmuştur.

A. Kullanılan Veri Seti


Çalışmada Extended MNIST (EMNIST) veri seti kullanılmıştır. EMNIST, hem rakamları (0-9) hem de büyük ve küçük harfleri (A-Z, a-z) içeren genişletilmiş bir veri setidir. Veri seti farklı alt kategoriler içermektedir. Bu çalışmada iki farklı senaryo ele alınmıştır:

- 10 sınıflı senaryo: Yalnızca rakamlar (0-9)
- 62 sınıflı senaryo: Rakamlar ve tüm harfler (0-9,A-Z, a-z)

EMNIST veri seti, 28x28 piksel boyutunda gri tonlamalı (grayscale) el yazısı karakterlerden oluşmaktadır.

Veri Setlerinin İçeriği


- 10 Sınıflı Veri Seti: Bu set yalnızca 0-9 arasındaki rakamlardan oluşmaktadır. Eğitim için 3.688 örnek, doğrulama için 650 ve test için 120 örnek kullanılmıştır..



Şekil 1. Örnek el yazısı rakamları

Şekil 1'de örnek el yazısı rakamlar gösterilmiştir [19]

- 62 Sınıflı Veri Seti: Bu set, küçük ve büyük harfler ile rakamları içeren toplam 62 sınıftan oluşmaktadır. Eğitim için 16.368 örnek, doğrulama için 3.100 ve test için 682 örnek kullanılmıştır. Yukarıdaki tablo, her iki veri setinin büyüklüğünü ve sınıf çeşitliliğini açıkça göstermektedir. Görüldüğü üzere, sınıf sayısındaki artış, hem modelin öğrenmesi gereken ayırım sayısını artırmakta hem de verilerin dengeli dağılması açısından daha karmaşık bir problem sunmaktadır.



Şekil 2

Şekil 2'de ise örnek el yazısı harfler gösterilmiştir [19]

B. Veri Ön İşleme

Veri seti üzerinde aşağıdaki ön işleme adımları uygulanmıştır:

- Görüntüler normalize edilerek [0, 1] aralığına çekilmiştir.
- Görseller 28x28 boyutunda tutulmuştur.
- Label'lar one-hot encoding yöntemiyle dönüştürülmüştür.
- Eğitim ve test için veri seti 80/20 oranında ayrılmıştır.

C. Model Mimarisi

Model, klasik bir Evrişimli Sinir Ağı (ESA) yapısı kullanılarak geliştirilmiştir

Model aşağıdaki katmanlardan oluşmaktadır:

16 adet evrişimsel katman kullanılmıştır. ilk olarak SGD optimizasyon algoritması ile temel öğrenme sağlanmış, ardından Adam algoritması ile model ince ayar (fine-tuning) sürecine tabi tutulmuştur. Her evrişimsel katmandan sonra batch normalization kullanılmıştır ve 6 adet de max pooling katmanı kullanılmıştır. Evrişim katmanlarının arasına 6 adet max pooling katmanı eklenmiştir.

D. Eğitim Parametreleri

Tablo 1. Eğitim parametreleri

Parametre	Değer
Epoch	10 (SGD) + 40 (ADAM)
Batch Size	128
Optimizer	SGD + Adam
Loss Function	Categorical Crossentropy
Performans Metrikleri	Accuracy

Tablo-1'de Her iki sınıf içinde sabit tutulan eğitim parametreleri verilmiştir.

IV. DENEYSEL SONUÇLAR

Tablo 2. Deneysel sonuçlar

Sınıf Sayısı	Doğruluk Oranı (%)	Kayıp (Loss)
10 sınıf	98.2	0.057
62 sınıf	86.5	0.431

Tablo 2 'de, modelin 10 sınıf ve 62 sınıf üzerindeki başarı oranı karşılaştırılmıştır:


Bu tablo, modelin daha fazla sınıf içeren veri setlerinde doğruluk oranının düştüğünü, ancak hâlâ başarılı sonuçlar verdiğini göstermektedir.

A. Eğitim Sonuçlarının Karşılaştırılması


Bu çalışmada aynı model mimarisi kullanılarak iki farklı sınıflandırma problemi çözülmüştür:

- 10 sınıflı model: EMNIST veri setinin sadece rakamları içeren alt kümesiyle eğitildi (0-9).
- 62 sınıflı model: EMNIST veri setindeki tüm karakterler (rakamlar, büyük ve küçük harfler) kullanıldı.

Aşağıdaki tablo, her iki modelin eğitim sürecinde gösterdiği performansı özetlemektedir:



Şekil-3. İlk sınıf için doğruluk ve kayıp grafiği



Şekil-4 İkinci sınıf için doğruluk ve kayıp grafiği

Şekil 3 ve Şekil 4'de, modelin iki ayrı sınıf için eğitim süreci boyunca elde edilen doğruluk (accuracy) ve kayıp (loss) değerlerinin değişimini gösteren grafiklere yer verilmiştir. Bu grafikler, modelin öğrenme performansını ve optimizasyon sürecini görsel olarak değerlendirmeye olanak sağlamaktadır. Şekil 3 eğitim ve doğrulama doğruluk grafiği belli bir turdan (epoch) sonra birbirine yaklaşmaktadır. Bu da önerilen modelin aşırı öğrenme durumuna düşmediğini göstermektedir. Şekil 4'te ise eğitim ve doğrulama doğruluk çizgileri daha erken turlarda yakınsamakta ve çakışık bir şekilde devam etmektedir. Aşırı öğrenme durumu iki grafikte de en azından belirtilen tur sayılarında görülmemektedir. Şekil 1'de tur sayısına göre model eğitim grafiklerine bakıldığında yakınsama tamamlanmış ve paralel bir şekilde devam ettiği

görülmektedir. Oysa ki Şekil 2'de tur sayısı artırıldığı takdirde model daha da iyileşebilir.

B. Karşılaştırma Tablosu

Tablo 3. Sonuçların karşılaştırılması

Özellik	10 Sınıf (Rakamsal)	62 Sınıf (Alfasayısal)
Eğitim Verisi Sayısı	3688	16368
Test Verisi Sayısı	770	3782
Çıkış Katmanı Boyutu	10	62
Aktivasyon Fonksiyonu	Softmax	Softmax
Son Eğitim Başarımı	%98.35	%86.87
Test Başarımı	%98.2	%86.5
Epoch Sayısı	20	20
En İyi Model Boyutu	2.4 MB	4.7 MB

Tablo 3 'te, modelin 10 sınıf ve 62 sınıf üzerindeki başarı oranı ve Eğitim verileri karşılaştırılmıştır:

C. Değerlendirme

- 10 sınıflı model, basit bir sınıflandırma problemidir. Karakter çeşitliliği az olduğu için modelin öğrenmesi daha kolay olmuş, yüksek başarımlar elde edilmiştir.
- 62 sınıflı model, karakter çeşitliliğinin artması nedeniyle daha karmaşık bir problem sunar. Bu karmaşıklık hem eğitim süresini uzatmış hem de başarı oranını nispeten düşürmüştür.
- Her iki modelde de GlobalAveragePooling2D katmanı ile boyut azaltımı sağlanmış, çıkış katmanında Dense (softmax) ile sınıf tahmini yapılmıştır.

D. Analiz

Model mimarisi her iki senaryoda da aynıdır. Farklılık yalnızca veri setinin kapsamı ve çıkış katmanı boyutundadır. Bu da gösteriyor ki, doğru yapılandırılmış bir model küçük ya da büyük ölçekteki sınıflandırma problemlerine uyarlanabilir. Ancak sınıf sayısı arttıkça:

- Hata yapma ihtimali artar,
- Eğitilmesi daha uzun zaman alır,
- Genel doğrulukta düşüş yaşanabilir.

Modellerden ilki yalnızca rakamlardan oluşan 10 sınıflı bir veri setiyle, diğeri ise hem harf hem rakam içeren 62 sınıflı bir veri setiyle eğitilmiştir.

E. Model Eğitimi ve Zorluklar

10 sınıflı model, sınırlı veriyle bile oldukça başarılı sonuçlar verirken; 62 sınıflı modelin, daha fazla örneğe ve daha derin bir öğrenme sürecine ihtiyaç duyduğu gözlemlenmiştir. Ayrıca, sınıflar arasındaki benzerlik (örneğin 'O' ve '0' gibi) 62 sınıflı modelin hata yapma ihtimalini artırmaktadır.

V. SONUÇ

Bu çalışmada, el yazısı karakterlerin sınıflandırılmasına yönelik derin öğrenme tabanlı bir CNN modeli geliştirilmiş ve modelin farklı sınıf sayıları altındaki performansı detaylı olarak analiz edilmiştir. 10 sınıflı senaryoda %96 gibi yüksek

bir doğruluk oranı elde edilirken, 62 sınıflı çoklu sınıflandırma senaryosunda doğruluk oranı %86'ya gerilemiştir. Bu sonuçlar, sınıf sayısının artmasının modelin sınıflandırma başarısı üzerinde doğrudan etkili olduğunu ve daha fazla karakter içeren veri kümeleriyle başa çıkabilmek için mimari optimizasyonun kritik öneme sahip olduğunu göstermektedir. Model mimarisinde kullanılan SeparableConv2D, BatchNormalization ve Dropout gibi bileşenlerin, öğrenme sürecine olumlu katkılar sağladığı gözlemlenmiştir. Ayrıca, iki aşamalı eğitim stratejisi ile elde edilen başarı, optimizasyon algoritmalarının sıralı kullanımının model performansına etkisini ortaya koymuştur. Gelecekte yapılacak çalışmalarda, veri artırma tekniklerinin daha yaygın kullanımı, farklı normalizasyon ve dikkat (attention) mekanizmalarının entegrasyonu ile model başarımının daha da artırılması hedeflenebilir.

KAYNAKÇA

- [1] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, Nov. 1998.
- [2] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in Neural Information Processing Systems*, vol. 25, 2012, pp. 1097–1105.
- [3] M. Kaya, "Feature fusion-based ensemble CNN learning optimization for automated detection of pediatric pneumonia," *Biomed. Signal Process. Control*, vol. 87, p. 105472, 2024.
- [4] M. Kaya and Y. Çetin-Kaya, "A novel deep learning architecture optimization for multiclass classification of Alzheimer's disease level," *IEEE Access*, vol. 12, pp. 46562–46581, 2024.
- [5] Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing*. Pearson.
- [6] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*.
- [7] Barbedo, J. G. A. (2013). *Digital image processing techniques for detecting, quantifying and classifying plant diseases*. SpringerPlus.
- [8] M. Kaya, S. Ulutürk, Y. Çetin Kaya, O. Altıntaş ve B. Turan "Optimization of Several Deep CNN Models for Waste Classification," *Sakarya Üniversitesi Bilgisayar Bilimleri ve Mühendisliği Dergisi*, <http://saucis.sakarya.edu.tr/en/pub/issue/79575/1257100>
- [9] Cohen, G., Afshar, S., Tapson, J., & van Schaik, A. (2017). EMNIST: Extending MNIST to handwritten letters.
- [10] de Campos, T. E., Babu, B. R., & Varma, M. (2009). Character recognition in natural images.
- [11] Clanuwat, T., Bober-Irizar, M., Kitamoto, A., Lamb, A., Yamamoto, K., & Ha, D. (2018). Deep Learning for Classical Japanese Literature.
- [12] Jindal, A., Dua, M., & Kumar, M. (2018). Handwritten Arabic character recognition using convolutional neural network.
- [13] Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal Loss for Dense Object Detection. *ICCV*.
- [14] Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*.
- [15] Afzal, M. Z., Kölsch, A., Ahmed, S., & Liwicki, M. (2019). Deep learning based baseline detection in historical documents.
- [16] Jaderberg, M., Simonyan, K., Vedaldi, A., & Zisserman, A. (2014). Synthetic data and artificial neural networks for natural scene text recognition.
- [17] Miyazaki, K., & Kitamoto, A. (2019). Improving character recognition in Kuzushiji using ResNets.
- [18] Alginahi, Y. M., Alabrah, A., & Alotaibi, M. (2020). Arabic handwritten character recognition using hybrid deep neural networks
- [19] S. Mann, "Handwritten English Characters and Digits," Kaggle, 2023. [Online]. Available: <https://www.kaggle.com/datasets/sujaymann/handwritten-english-characters-and-digits>