



Evriřimli Sinir Ağları kullanılarak Türk İřaret Dili Alfabesinin Tespit Edilmesi

Elif TAŐDEMİR^{1, a}, ✉ elifftasdemirr@gmail.com, Uğur TALAŐ^{2, b}, Burakhan ÇUBUKÇU^{1, c},

¹Bilecik Őeyh Edebalı Üniversitesi, Mühendislik Fakóltesi, Bilgisayar Mühendisliđi, Bilecik, Türkiye

²Bilecik Őeyh Edebalı Üniversitesi, Bilgi İřlem Daire Bařkanlıđı, Bilecik, Türkiye

^aORCID: 0009-0003-5938-992X; ^bORCID: 0000-0002-9287-413X; ^cORCID: 0000-0003-0480-1254;

✉ Sorumlu Yazar: ugur.talas@bilecik.edu.tr

Geliř tarihi: 26/09/2024

Kabul tarihi: 10/11/2024

Özet: Bu çalışmada engelli bireylerin iřaret dili bilmeyen insanlarla iletiřim kurabilmelerini destekleyici yapay zeka destekli bir uygulama geliřtirilmiřtir. Günümüzde engellilerin toplumsal yařamdaki birçok olaktan daha fazla yararlanabilme ya da indirimli yararlanabilme gibi engelli bireyleri toplumla kaynařtırmayı arttıran birçok giriřim bulunmaktadır. Engellilerin sadece sosyal olanak ya da maddi imkanlardan faydalanması deđil toplumda engelli bireyler ile engelsiz bireylerin aralarındaki iletiřimin kuvvetlenerek kendilerini toplumun bir parçası olarak hissetmeleri oldukça önemlidir. Toplum içinde iřitme engelliler iletiřim konusunda iřaret dili bilmeyen insanlar ile iletiřime geçmekte zorlanmaktadır. Bu yařanan iletiřim probleminin önüne geçmek için yapay zeka destekli bir uygulama geliřtirilmiřtir. Uygulamada derin öğrenme yöntemlerinin görüntü iřleme alanında en yaygın kullanılan Evriřimli Sinir Ağları (CNN) kullanılmıřtır. Kullanılan CNN modelinde başarıyı arttırmak için Adadelta, Stochastic Gradient Descent (SDG) ve Adagrad olmak üzere üç farklı optimizasyon algoritması ile eğitim ve testler yapılarak modelin başarılarını karşılařtırılmıřtır. Test sonuçlarında Adagrad algoritması %97,01, SGD algoritması %96,71, Adadelta algoritması ise %70,91 başarı oranı elde etmiřtir. En iyi sonucu veren Adagrad optimizasyon algoritması ile geliřtirilen model canlı kamera görüntüsünden alınan görüntüler üzerinde uygulanma geliřtirilmiřtir. Geliřtirilen uygulamada kameradan alınan görüntüdeki iřaret dili harfini anlık olarak ekrana yazdırılarak iřaret dili ile anlatılmak istenen harfler takip edilebilmektedir.

Anahtar Sözcükler: Türk iřaret dili, Derin Öğrenme, Evriřimli Sinir Ađı, Adagrad, SDG, Adadelta

Detection of the Turkish Sign Language Alphabet Using Convolutional Neural Networks

Abstract: In this study, an artificial intelligence-supported application has been developed to assist disabled individuals in communicating with people who do not know sign language. Nowadays, there are many initiatives aimed at increasing the integration of disabled individuals into society, such as enabling them to benefit more from social opportunities or providing discounts. It is crucial that disabled individuals not only benefit from social or financial opportunities but also feel like a part of society by strengthening the communication between them and non-disabled individuals. In society, hearing-impaired individuals often face challenges when trying to communicate with people who do not know sign language. To address this communication problem, an artificial intelligence-supported application has been developed. In this application, the most commonly used method in the field of image processing, the Convolutional Neural Network (CNN), has been utilized. To improve the performance of the CNN model used, the model's performance was compared by training and testing with three different optimization algorithms: Adadelta, SGD, and Adagrad. The test results showed that the Adagrad algorithm achieved a success rate of 97.01%, the SGD algorithm 96.71%, and the Adadelta algorithm 70.91%. The model developed with the Adagrad optimization algorithm, which provided the best results, was implemented on live camera footage. In the developed application, the letters conveyed through sign language can be tracked in real-time by displaying the sign language letters on the screen as they are captured by the camera.

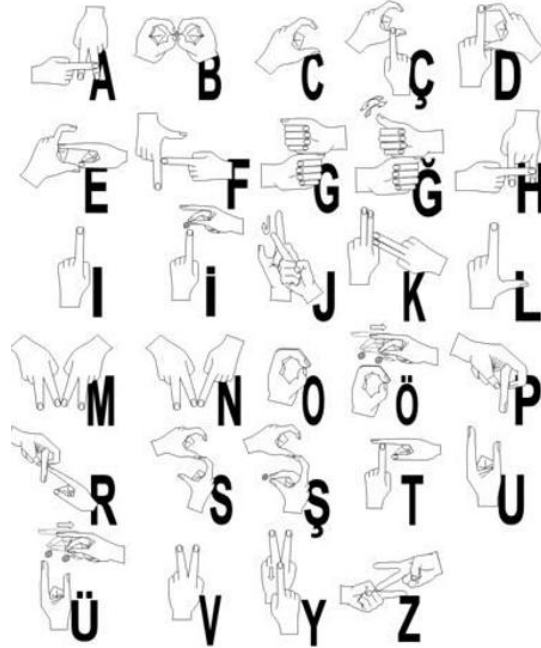
Keywords: Turkish sign language, Deep learning, Convolutional neural network, Adagrad, SGD, Adadelta

1. Giriş

Son yıllarda dünyada yürütülmeye başlanan engelsiz toplum politikasıyla engellilerin, toplumsal yaşama daha çok dahil edilmesi gerektiği farkındalığı giderek artmaktadır. Engelsiz toplum anlayışı, sadece fiziki koşulların iyileştirilerek engellilerin sosyal olanaklardan faydalanması değil, toplumla iletişim kurularak toplumla kaynaştırılması olarak algılanmalıdır(Hästbacka vd., 2016). Engelsiz bir toplum için iletişimde de engellerin mümkün olduğunca kalkması olarak düşünülmelidir. Engelli topluluğu içinde kendilerini görünmez engelli olarak tanımlayan işitme engelliler, işaret dilleri aracılığıyla iletişim kurmaktadır(Arslan, 2021a).

İşaret dilleri işitme engellilerin kendi aralarında ve duyan konuşan insanlarla iletişim kurmak amacıyla kullandıkları kendine özgü dil bilgisi, fonetiği, sözdizimi olan dillerdir. Ayrıca ifade biçimleriyle o dili kullanan “Sağır” toplumun kültürünü yansıtan, yaşayan ve dinamik dillerdir (Zeynep Oral vd., 2023). El işaretleri, elin konumu, parmak abecesi, dil bilgisel yüz mimikleri, kaşların kalkması, gözlerin açılması dudakların hareketi, vücudun konumu gibi el dışındaki işaretler de işaret dillerinin ortak paydasını oluşturmaktadır. Bu özellikleriyle işaret dilleri görsel uzamsal olarak nitelendirilmektedir. Bazı işaret dillerinde tek elin, bazılarında çift elin kullanıldığı parmak abecesi işaret dilindeki kavramların sözlü yazılı dillerde karşılığını vermek üzere geliştirilmiştir. Konuşma dilleri gibi milletten millete farklılık gösteren ve doğal diller olan işaret dilleri, görsel uzamsal diller olarak nitelendirilmektedir(Dikyuva vd., 2020).

Türkiye’de işitme engelliler, iletişimlerinde Türk İşaret Dili’ni (TİD) kullanmaktadırlar(Arslan, 2021b). Türk işaret dilinde harflerin çoğunluğu statik görüntülerden oluşurken bazı harfler ise dinamik görüntülerden meydana gelmektedir. Alfabedeki A,B,C,D,E,F,G,H,I,K,L,M,N,O,P,R,S,T,V,Y,Z harfleri statik görüntülerden oluşurken, Ç,Ğ,İ,J,Ö,Ş,Ü harfleri ise dinamik görüntülerden oluşmaktadır. TİD işaret dili alfabesi Şekil 1’de sunulmuştur.



Şekil 1. Türk işaret dili alfabesi

İşaret dili alfabeleri kullanılan ana dile özgü değişiklik gösterebilen bu alfabeler için literatürde derin öğrenme yöntemleriyle yapılan çalışmalar ve Leap Motion, Kinect ve elektronik eldivenler gibi donanımlarla birlikte yapılan çalışmalar bulunmaktadır(Agarwal & Thakur, 2013; Kaya vd., 2018; Potter vd., 2013).

Kemaloğlu ve Sevli’nin yaptıkları bir çalışmada işaret dilindeki rakamların tespitini gerçekleştirmişlerdir. İşaret dilinde 0-9 aralığındaki rakamların tamamı tek el ile ifade edilmektedir.

Kullandıkları veri seti 2602 adet veri içermektedir. CNN modeli ile yaptıkları eğitim ve test işlemleri sonucunda %97,8 oranında doğruluk elde etmişlerdir(Sevli & Kemalöglü, 2019).

Özer çelik ve arkadaşlarının Sign2Text isimli çalışmalarında hem statik hem de dinamik harfler için yapay zeka modeli geliştirmişlerdir. Özellikle dinamik harflerde sadece CNN kullanarak yaptıkları eğitimin test sonuçlarında %53,8'lik doğruluk oranı elde etmişlerdir. Elde edilen bu düşük orandaki başarıyı iyileştirmek için CNN ve Long Short Term Memory (LSTM)'in birlikte kullanıldığı hibrit bir yapı oluşturmuşlardır. Oluşturdukları yeni hibrit modelin test sonuçlarında %97'lik bir başarımlar elde etmişlerdir(Çelik & Odabaş, 2020).

Yapılan bir çalışmada Türk işaret dili alfabesi için canlı görüntüler üzerinde tahmin yapılmıştır. Çalışmada Faster-R-CNN modeli kullanılmıştır. Çalışmada Türk işaret diline ek olarak Q, W, X harflerini de kullanmışlardır. Çalışmada %88'lik bir başarımlar elde etmişlerdir. Ayrıca test aşamasında her bir harf için ayrı ayrı ölçümler yapmışlardır. Yapılan harf bazlı ölçümlerde %98'lik doğruluk oranı ile en iyi sonuç "A" harfi için alırken, en kötü sonuç %74'lük başarımlar ile "Q" ve "G" harfleri olmuştur.

M. Çiftçi ve arkadaşları çalışmalarında transfer öğrenme yöntemleri kullanarak TİD harf tahmini yapmışlardır. Transfer öğrenme yöntemlerinden Xception, NASNet, MobileNet, DenseNet169, VGG16, MobileNet, ResNet50V2 olmak üzere toplam yedi farklı önceden eğitilmiş ağ ile Türk İşaret Dili için eğitim gerçekleştirmişlerdir. Yaptıkları test işlemleri sonucunda %96'lık başarımlar ile en iyi sonucu ResNet50V2 ve MobileNet ile elde etmişlerdir(CİFTÇİ & TEKİN, t.y.).

Literatürdeki görüntü işleme temelli çalışmaların yanında donanım destekli çalışmalarda yapılmıştır. Bu alanda en yaygın kullanılan donanımların başında Leap Motion gelmektedir. A. KARACI ve arkadaşları yaptıkları bir çalışmada Leap Motion kullanarak Türk işaret dili tahmini yapmışlardır. Leap motion ile elde ettikleri anlık verileri Deep Neural Networks (DNN), Artificial Neural Networks (ANN) ve Decision Tree yöntemleriyle sınıflandırma yapmışlardır. Yapılan çalışma sonucunda 390 özellik kullanarak test sonucunda DNN %100, ANN %99 ve Decision Tree ise %98'lik bir başarımlar elde etmiştir(Karacı vd., 2018).

Z. Katılmış ve C. Karakuzu "ELM tabanlı iki elle dinamik Türk İşaret Dili (TİD) kelime tanıma" isimli çalışmalarında Leap Motion Controller cihazı kullanarak TİD dinamik kelime tanıma yapmışlardır. Kendi oluşturdukları veri setinde PCA, LDA ve PCA+LDA yöntemleri kullanarak boyut indirgeme işlemleri yapmışlardır. 5 farklı ELM ağı ile testler gerçekleştirip ML-KELM'in yüksek performans verdiğini gözlemlemişlerdir(Katılmış & Karakuzu, 2021).

Donanım destekli çalışmalar genellikle derin öğrenme tabanlı çalışmalara göre daha yüksek başarımlar elde etmektedir ancak bu donanımların elde edim maliyetleri ve her iletişim kurulması istendiği yere taşınması gerekliliği kullanışlılığını düşürmektedir. Bu anlamda kamera görüntüsü ile yapılan çalışmaların web cam kullanıldığında maliyetinin düşük olması veya telefon kamerası kullanıldığında hemen hemen herkeste bulunan bir donanım olması sebebiyle kamera üzerinde yapılan çalışmalar, donanım destekli çalışmalara göre kullanım alanının daha geniş olduğunu göstermektedir.

Bu çalışmada derin öğrenme temelli Türk işaret dili tahmini yapan bir uygulama geliştirilmiştir. Yapılan uygulama anlık kamera görüntüsünden alınan görüntüdeki yapılan Türk işaret dili harflerini tanıyıp ekrana yazdırmaktadır. Çalışma kapsamında derin öğrenme yöntemlerinden CNN modeli kullanılmıştır. Kullanılan modelin başarımlarını arttırmak için Adagrad, SDG, Adadelat optimizasyon algoritmaları ile üç farklı eğitim gerçekleştirilmiştir. Yapılan eğitimler uygulama ve sonuç bölümlerinde karşılaştırılarak en iyi sonucu veren Adagrad algoritması ile uygulama gerçekleştirilmiştir. Uygulama kamera haricinde herhangi bir ek donanıma ihtiyaç duymadan sonuç elde edebilmektedir.

Çalışmanın ikinci bölümünde kullanılan materyal ve metotlar sunulmuştur. CNN yönteminin çalışma alt yapısı incelenmiştir.

2. Materyal ve Metot

Bu çalışmada el işaretlerinin tespit edilip sınıflandırılması için derin öğrenme yöntemlerinden faydalanılmıştır. Bu bölümde kullanılan derin öğrenme modelinin çalışma prensibi ve alt yapısıyla ilgili bilgiler verilmiştir.


2.1 Derin Öğrenme

Yapay zekanın bir alt dalı olarak kabul edilen derin öğrenme IvanFellow'un Derin Öğrenme kitabında "Bilgisayarların problemi çözmek için gereksinim duyduğu kuralları insan eliyle girmek yerine hiyerarşik bir şekilde karmaşık kavramlardan basit kavramlara dönüştürülerek inşa edilen bir yapı oluşturursak çok katmanlı ya da diğer bir deyişle derin bir anlamsal bütün oluştururuz. Bu sebeple bu yaklaşıma derin öğrenme denilmektedir." şeklinde tanımlanmıştır(Lecun vd., 2015). Derin öğrenme yöntemleri görüntü analizi, ses analizi robotik otonom araçlar, gen analizleri ve sağlık alanındaki karar destek sistemleri gibi birçok alanda kullanılmaktadır.

Makine öğrenmesi yöntemlerinde genellikle istatistik temellere dayanan Lineer Regresyon, Logistic Regresyon, Karar Ağaçları ve En Yakın Komşu gibi algoritmalar kullanılırken derin öğrenme de daha çok eldeki mevcut verilerden hareketle bir sonuç alınması temeline dayanan Evrişimli Sinir Ağları CNN, Uzun Kısa Süreli Bellek LSTM ve Aşırı Öğrenme Makineleri ELM gibi yöntemler kullanılmaktadır. Uygulanacak alana ve veri tiplerine göre birbirinden farklı birçok yaklaşım ortaya atılmıştır. Zaman serisi verileriyle çalışmak için LSTM yöntemi kullanılırken metinler üzerinde çalışılacağı zaman NLP yöntemleri kullanılmaktadır. Görüntü işleme alanında ise en popüler yaklaşım CNN ve CNN'den türetilen yaklaşımlardır(El Naqa & Murphy, 2015).

2.2 Evrişimli Sinir Ağları - Convolutional Neural Network CNN


CNN görüntü işleme çalışmalarında yaygın şekilde kullanılan bir derin öğrenme modelidir. CNN temel olarak verinin karmaşık özelliklerini otomatik olarak çıkarabilme problemini çözen bir yaklaşımdır. CNN, özellik çıkarımının yapıldığı konvolüsyon katmanı ile sınıflandırma işlemlerinin yapıldığı tam bağlı katman olmak üzere iki ana katmandan oluşmaktadır. Birinci katmanda konvolüsyon, pooling, padding teknikleri uygulanarak öznelik çıkarma işlemi yapılır. Birinci katmanda elde edilen veriler ikinci katman içerisindeki Multilayer Perceptron (MLP)'a verilir ve MLP ile sınıflandırma işlemi yapılmaktadır(Al Batatineh vd., 2022). CNN mimarisi aşağıdaki Şekil 2'de verilmiştir.



Şekil 2. CNN mimarisi(Example of a network with many convolutional layers., t.y.)

CNN mimarisinin son bölümünü oluşturan MLP sınıflama işleminin yapıldığı katmandır. Konvolüsyon katmalarındaki işlemler sonrasında oluşan flatten vektörü tam bağlı katman içerisinde bulunan MLP ağına girdi olarak verilir ve sınıflama işlemi yapılır. MLP içerisinde nöronların bağlantı

ağırlıkları, bias ve nöronların arkasında aktivasyon fonksiyonları içerir. Genel yapısı Şekil 3'te verilmiştir.



Şekil 3. Multilayer perceptron yapısı(Arvind Sreenivas vd., 2020)

Nöronlara gelen girdiler geldikleri bağlantının ağırlığıyla çarpılır ve bias değerleri de kendi bağlantı ağırlığı ile çarpılarak toplama işlemi yapılır. Elde edilen sonuçlar ise bir aktivasyon fonksiyonundan geçirilerek sonuç elde edilir. Aktivasyon fonksiyonlarının temel amacı ağırlık ve bias değerlerini ayarlamaktır. Relu, sigmoid, softmax gibi farklı fonksiyonlar bulunmaktadır ancak literatürde en sık kullanılanı relu veya leakly relu olarak görülmektedir.

Derin öğrenme uygulamalarında bu bölümde belirtilen birçok parametreye bağlı çalışmaktadır. Doğrusal olmayan bu parametrelerin optimum değeri belirlemek için optimizasyon algoritmaları geliştirilmiştir. Bu çalışma kapsamında literatürde sıklıkla kullanılan Adagrad, SGD ve Adadelta algoritmaları çalışılmıştır.


Uyarlanabilir Gradyan Algoritması (Adagrad) modele uygulanırken global minimuma giderken adım boyutu oldukça önemlidir. Adgrad adım boyutunu dinamik olarak hesaplar. Geriye yayılım hesaplamasındaki güncelleme sıklığı arttıkça, adım boyutunu kısaltır. Böylelikle minimuma yaklaştıkça daha emin adımlarla model eğitimi devam ettirilmiş olur(Irfan vd., 2022).

Stokastik Gradyan Azalma algoritması (SGD), rastgele seçilen parametreler ile global minimuma gitmeyi hedeflemektedir. Gradyan azalmaya benzer ancak gradyanda bütün veri seti kullanılırken, stokastik gradyan yönteminde tek bir örneklem kullanılarak hesaplama işlemleri gerçekleştirilir. Tek bir örneklem üzerinden ilerlediği için global minimuma gidiş hızı düşüktür, hızlı ilerlemez ancak local minimuma takılma ihtimali düşüktür. Hızı düşük olsa da local minimuma takılmadığı için avantajlıdır. Minimuma giderken gürültülü bir grafik çizer ve hedefe ulaşmak için iterasyon sayısı yüksektir(Abdullah ATCILI, 2020).

Adadelta algoritması, Uyarlanabilir Gradyan Algoritması (Adagrad)'tan türetilmiş bir algoritmadır. Adagrad'taki öğrenme oranı agresifliğini daha yumuşatmaya çalışır. Sabit bir w değeriyle sınırlayarak çalışır. T zamanında önceki ortalama ve eğime bakarak hesaplama yapar. Öğrenme oranı dinamik olarak hesapladığından sabit bir değer atanmasına gerek yoktur.

2.3 Veri Seti

Çalışmada Türk işaret dilin için Berkay Kocaoğlu'nun Kaggle üzerinden paylaştığı Tr Sign Language Data Set isimli veri seti kullanılmıştır(*Tr Sign Language Dataset*, t.y.). Veri seti toplamda 44.000 veri içermektedir. Veri seti statik harflerden oluşan toplam 23 sınıf bulunmaktadır. Kullanılan veri seti örnek verileri aşağıdaki şekil 4'te sunulmuştur.



Şekil 4. Tr Sing Language veri seti (Tr Sign Language Dataset, t.y.)

Kullanılan 44000 adet görüntü %80 eğitim, %20 test verisi olarak ayrılmıştır. Eğitim setinde 35200, test setinde ise 8800 adet görüntü yer almaktadır.

3. Evrişimli Sinir Ağları kullanılarak Türk İşaret Dili Alfabesinin Tespit Edilmesi

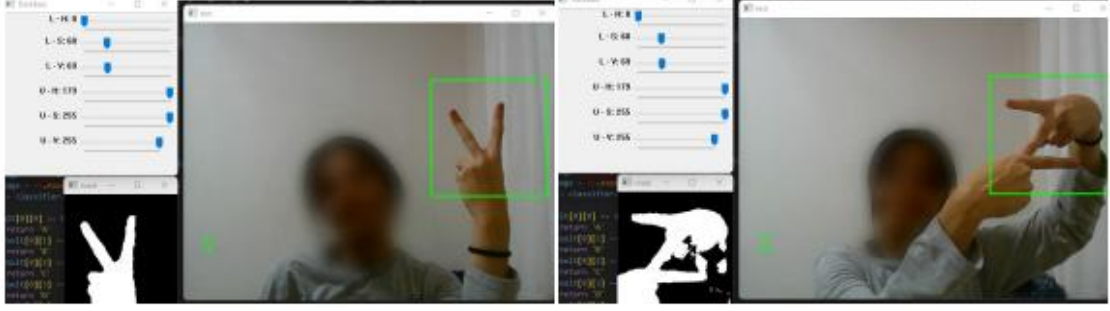
Bu çalışmada CNN mimarisi kullanılarak kameradan anlık elde edilen video üzerinde görüntü işleme yapılarak TİD'e ait statik harflerin tespit edilmesi ve bu harflerin ekrana yazdırılarak karşı taraf ile iletişimin kolaylaştırılması amacıyla bir yazılım geliştirilmiştir.

Geliştirilen yazılım alt yapısında kullanılan ve bir yapay zeka modeli olan CNN, 10 katman olarak oluşturulmuştur. Model konvolüsyon için 7 katman, FCN için ise 3 katman olarak tasarlanmıştır. Oluşturulan modelin bilgileri aşağıdaki Tablo 1'de verilmiştir.

Tablo 1. Eğitimde kullanılan mimari ve parametreleri

Katman Tipi	Çıkış Boyutları	Parametreler
Conv2D	32, 32, 32	896
Conv2D	32, 32, 64	18496
Max Pooling 2D	16, 16, 64	0
Conv2D	16, 16, 64	36928
Max Pooling 2D	8, 8, 64	0
Conv2D	8, 8, 128	73856
Max Pooling 2D	4, 4, 128	0
Flatten	2048	0
Dense	256	524544
Dropout	256	0
Dense	22	5654

Tablo 1'de görüldüğü üzere ilk konvolüsyon katman katmanıdır. Bu katmanda 32x32x3 bir input görüntüsü kullanılmıştır. Bu katmanda ve diğer konvolüsyon katmanlarında 3x3 boyutunda 32 filtre seçilmiştir. İkinci katman konvolüsyon katmanı olup 3x3 boyutunda 64 adet filtreden oluşmaktadır. Üçüncü katman 2x2 pencere boyutlu, stride değeri 2 olan havuzlama katmanıdır. Dördüncü katman konvolüsyon katmanı olup 3x3 boyutunda 64 adet filtreden oluşmaktadır. Beşinci katman 2x2 pencere boyutlu, stride 2 olan havuzlama katmanıdır. Altıncı katman 128 nörona sahip 3x3 filtre uygulanarak oluşturulmuştur. Yedinci katman 2x2 pencere boyutlu, stride 2 olan havuzlama katmanıdır. Sekizinci katman Tam Bağlantılı katmandır. Bu katman için modele gizli bir katman eklenir, bu katman her olası



Şekil 6. Canlı uygulama ekran görüntüleri- 2

4. Tartışma ve Sonuç

Bu çalışmada işitme engelli bireylerin günlük hayatta işaret dili bilmeyen insanlar ile iletişime geçmelerini kolaylaştıracak, derin öğrenme destekli bir uygulama geliştirilmiştir.

İşaret dilleri aynı günlük hayatta konuşulan diller gibi birbirine göre farklılık göstermektedir ve alfabeleri birbirinden farklıdır. Alfabelerdeki harflerin yapısına göre bazı harfler tek elle bazı harfler ise çift elle gösterilebilmektedir. Türk işaret dilinde alfabenin 22 harfi statik görüntüden oluşurken 7 tane harf ise dinamik görüntülerden meydana gelmektedir. Bu alfabe görüntülerini içeren Tr Sign Language Data Set isimli veri seti ile çalışılmıştır. Veri setinde toplam 44.000 adet veri bulunmaktadır bu veriler %80'si eğitim, %20'si test için ayrılarak yapay zeka eğitimi gerçekleştirilmiştir.

Yapay zeka eğitimi yapılırken Derin öğrenme yöntemlerinden görüntü işleme alanında en yaygın kullanılanlardan biri olan CNN yöntemi kullanılmıştır. Çalışmada CNN'nin çalışma prensipleri incelenerek model başarımını artırmak için CNN ile birlikte kullanılan üç farklı optimizasyon algoritması kullanılmıştır. Kullanılan algoritmaların farklı tekrar sayılarındaki eğitimlerinin test sonuçları için karşılaştırma yapılmıştır. Adagrad optimizasyon algoritması 60 epoch için %97,01'lik bir doğruluk elde ederek en iyi sonucu veren algoritma olmuştur. SGD optimizasyon algoritması ise Adagrad'tan sonra en iyi sonucu veren ikinci optimizasyon algoritması olmuştur ve 60 epoch'ta %96,71'lik bir doğruluk elde etmiştir. Adagrad ve SGD optimizasyon algoritması birbirine yakın sonuçlar veririrken 60 epoch için Adadelta algoritması %70,91'lik bir başarımla diğer algoritmaların gerisinde kalmıştır.

Yapılan çalışma test ortamında masaüstü uygulaması olarak tasarlanmıştır. Çalışmanın günlük hayatta kullanılması bu anlamda zorluklar oluşturmaktadır. Çalışmada eğitilen yapay zeka modeli gelecekteki, çalışmalarda bir mobil uygulamanın altyapısında çalıştırılıp günlük hayata faydası artırılabilir.

Çıkar Çatışması

Yazarlar çıkar çatışması olmadığını beyan etmişlerdir.

Etik Beyan

Bu çalışmada sunulan veri, bilgi ve belgeler akademik ve etik kurallar çerçevesinde elde edilmiştir.

Finansal Destek

Bu araştırma herhangi bir fon sağlayan kurumdan / sektörden hibe almamıştır.

Kaynakça

- Abdullah ATCILI. (2020). *Yapay Sinir Aglarında Kullanılan Optimizasyon Algoritmaları* / by ABDULLAH ATCILI / Machine Learning Türkiye / Medium. <https://medium.com/machine-learning-t%C3%BCrkiye/yapay-sinir-a%C4%9Flar%C4%B1nda-kullan%C4%B1lan-optimizasyon-algoritmalar%C4%B1-3e87cd738cb5>
- Agarwal, A., & Thakur, M. K. (2013). Sign language recognition using Microsoft Kinect. *2013 6th International Conference on Contemporary Computing, IC3 2013*, 181-185. <https://doi.org/10.1109/IC3.2013.6612186>
- Al Bataineh, A., Kaur, D., & Jalali, S. M. J. (2022). Multi-Layer Perceptron Training Optimization Using Nature Inspired Computing. *IEEE Access*, 10, 36963-36977. <https://doi.org/10.1109/ACCESS.2022.3164669>
- Arslan, Y. (2021a). Geçmişten günümüze işitme engellilerin eğitimi ve Türk işaret dilinin rolü. *Academic Journal of History and Idea*, 8(1), 163-178. <https://doi.org/10.46868/atdd.99>
- Arslan, Y. (2021b). Geçmişten günümüze işitme engellilerin eğitimi ve Türk işaret dilinin rolü. *Akademik Tarih ve Düşünce Dergisi*, 8(1), 163-178. <https://doi.org/10.46868/atdd.99>
- Arvind Sreenivas, Mudit Maheshwari, Saiyam Jain, Shalini Choudhary, & Dr.G.Vadivu. (2020). Indian sign language communicator using convolutional neural network. *International Journal of Advanced Science and Technology*, 29(3).
- CIFTCI, M. E., & TEKIN, R. (t.y.). *TÜRK İŞARET DİLİNİN TRANSFER ÖĞRENME YÖNTEMLERİYLE SINIFLANDIRILMASI*. Geliş tarihi 23 Eylül 2024, gönderen https://scholar.google.com/citations?view_op=view_citation&hl=en&user=6lNkO5UAAAJ&ccstart=20&pagesize=80&citation_for_view=6lNkO5UAAAJ:MDX3w3dAD3Y C
- Dikyuva, H., Makaroğlu, B., Arık, E., Türk, ", Dili, İ., Kitabı, D., Aile, ", Topraksoy, A., Üniversitesi, İ., Fakültesi, E., & Bölümü, D. (2020). Türk İşaret Dili Dilbilgisi Kitabı. *Journal of Linguistics*, 34(34), 73-75. <https://doi.org/10.26650/jol.2020.005>
- El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? *Machine Learning in Radiation Oncology*, 3-11. https://doi.org/10.1007/978-3-319-18305-3_1
- Example of a network with many convolutional layers.* (t.y.). <https://www.mathworks.com/discovery/convolutional-neural-network.html>
- Hästbacka, E., Nygård, M., & Nyqvist, F. (2016). Barriers and facilitators to societal participation of people with disabilities: A scoping review of studies concerning European countries. *Alter*, 10(3), 201-220. <https://doi.org/10.1016/J.ALTER.2016.02.002>
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangga, A. (2022). PERBANDINGAN OPTIMASI SGD, ADADELTA, DAN ADAM DALAM KLASIFIKASI HYDRANGEA MENGGUNAKAN CNN. *JOURNAL OF SCIENCE AND SOCIAL RESEARCH*, 5(2), 244-253. <https://doi.org/10.54314/JSSR.V5I2.789>
- Karacı, A., K. AKYOL, & Y. GÜLTEPE. (2018). *Turkish Sign Language Alphabet Recognition with Leap Motion*. <https://www.researchgate.net/publication/326837399>
- Katılmış, Z., & Karakuzu, C. (2021). ELM based two-handed dynamic Turkish Sign Language (TSL) word recognition. *Expert Systems with Applications*, 182, 115213. <https://doi.org/10.1016/J.ESWA.2021.115213>
- Kaya, F., Tuncer, A. F., & Yildiz, Ş. K. (2018). Detection of the turkish sign language alphabet with strain sensor based data glove. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, 1-4. <https://doi.org/10.1109/SIU.2018.8404459>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature* 2015 521:7553, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

- A., Çelik, Ö., & Odabaş, A. (2020). Sign2Text: Konvolüsyonel Sinir Ağları Kullanarak Türk İşaret Dili Tanıma. *Avrupa Bilim ve Teknoloji Dergisi*, 19, 923-934. <https://doi.org/10.31590/EJOSAT.747231>
- Potter, L. E., Araullo, J., & Carter, L. (2013). The leap motion controller: A view on sign language. *Proceedings of the 25th Australian Computer-Human Interaction Conference: Augmentation, Application, Innovation, Collaboration, OzCHI 2013*, 175-178. <https://doi.org/10.1145/2541016.2541072>
- Sevli, O., & Kemaloğlu, N. (2019). Evrişimsel Sinir Ağları ile İşaret Dili Tanıma. *Proceedings on 2nd International Conference on Technology and Science*, 14-16. <https://www.researchgate.net/publication/349057657>
- Tr Sign Language Dataset*. (t.y.). Geliş tarihi 23 Eylül 2024, gönderen <https://www.kaggle.com/datasets/berkaykocaoglu/tr-sign-language>
- Zeynep Oral, A., Ören, T., Üniversitesi, H., Fakültesi, E., Mütercim Tercümanlık, F., öğrencisi, D., Üniversitesi, İ., & Mütercim Tercümanlık, A. (2023). S/sağır ve İşitme Engelli Çocukların Erişimi Bağlamında Fablların Türk İşaret Diline Çevirileri Üzerine Bir İnceleme. *Çeviribilim ve Uygulamaları Dergisi*, 35(35), 128-141. <https://doi.org/10.37599/CEVIRI.1376300>