



## İŞİTME ENGELLİ BİREYLERİN HAREKETLERİNİ SINIFLANDIRMAYA YÖNELİK YAPAY ZEKA MODELİNİN GELİŞTİRİLMESİ

Ahmed KASAPBAŞI<sup>1\*</sup>, Hüseyin CANBOLAT<sup>1</sup>

<sup>1</sup>Ankara Yıldırım Beyazıt University, Faculty of Engineering and Natural Sciences, Department of Electrical and Electronics Engineering, 06760, Ankara, Türkiye

**Özet:** İşaret Dili, işitme engelli bireyler için hayati bir iletişim aracıdır. Farklı ülkelerde kendi ihtiyaçlarına geliştirilmiş birçok işaret dili vardır. Bu çalışma, Türk İşaret Dili (TİD) jestlerini derin öğrenme teknikleriyle metne dönüştürmeyi amaçlamaktadır. Bu amaçla, arka planlar, aydınlatma koşulları ve işaret pozisyonları gibi çeşitli çevresel faktörler açısından çeşitlilik gösteren yeni bir veri kümesi oluşturulmuştur. Daha sonra, TİD alfabesini algılamak ve sınıflandırmak için Evrişimli Sinir Ağları (CNN'ler) kullanılmıştır. Ayrıca, geliştirilen modellerin performansını optimize etmek için çeşitli hiperparametreler araştırılmıştır. En iyi CNN mimarisi, beş evrişimli katmanı içerir ve Adam öğrenme hızı optimizasyon yöntemini kullanır; 80 epoch'tan sonra yaklaşık %98'lik bir doğruluk (başarı) elde edilmiştir. Sonuç olarak, zorlu bir veri kümesi üzerinde eğitilen önerilen modeller, işaret dili tanıma alanında önemli bir ilerleme temsil etmektedir.

**Anahtar kelimeler:** Yapay zeka, Jest, Tanımlama, İşitme engelli


### Development of an Artificial Intelligence Model for Classification of the Movements of Hearing Impaired Individuals

**Abstract:** Hearing impaired individuals utilize a crucial communication tool called sign language. There are numerous sign languages across different countries such as natural languages. This study proposes leveraging deep learning (DL) advancements to facilitate the conversion of sign language gestures into text. To this end, a novel dataset is curated under various environmental factors such as backgrounds, lighting conditions, and sign positions. Subsequently, Convolutional Neural Networks (CNNs) are employed to detect and classify twenty-three gestures of Turkish sign language alphabet. Furthermore, various hyperparameters are explored to optimize the performance of the developed models. The best model relies on a five-layer convolutional network coupled with the Adam optimization algorithm. This model approximately achieves a commendable accuracy of 98% after 80 epochs. As a result, the proposed models and dataset represent a significant advancement in the field of gestures recognition.

**Keywords:** Artificial intelligence, Gesture, Recognition, Hearing impaired

\*Sorumlu yazar (Corresponding author): Ankara Yıldırım Beyazıt University, Faculty of Engineering and Natural Sciences, Department of Electrical and Electronics Engineering, 06760, Ankara, Türkiye

E mail: 185105405@aybu.edu.tr (A. KASAPBAŞI)

Ahmed KASAPBAŞI  <https://orcid.org/0000-0003-2383-1774>

Hüseyin CANBOLAT  <https://orcid.org/0000-0002-2577-0517>

Gönderi: 03 Mayıs 2024

Kabul: 18 Temmuz 2024

Yayınlanma: 15 Eylül 2024

Received: May 03, 2024

Accepted: July 18, 2024

Published: September 15, 2024

**Cite as:** Kasapbaşı A, Canbolat H. 2024. Development of an artificial intelligence model for classification of the movements of hearing impaired individuals. 7(5): 826-835.

### 1. Giriş

İşitme engelli bireyler, işaret dili aracılığıyla sadece birbirleriyle değil, aynı zamanda bu engeli paylaşmayanlarla da iletişim kurabilirler. Her toplumun kendi belirgin ulusal işaret dili vardır ve ülkeden ülkeye farklılık gösterir (Karaca ve Bayır, 2018). İletişimin önemli bir yönü, bireylerin birbirleri arasındaki etkileşimi kolaylaştırmak için sıkça kullandığı dilde yatar (Thomas ve McDonagh, 2013). Her toplumun kendine özgü konuşulan dili vardır ve bireylerin kendilerini ifade etmeleri için doğrudan veya dolaylı bir araç olarak hizmet eder (Alshehri, 2023). Ancak, bazı bireyler çeşitli faktörlerden dolayı işitme kaybı yaşayabilir ve bu durum onları sosyal ortamlarda etkili bir şekilde iletişim kuramaz hale getirebilir. Sonuç olarak, işitme engelliler

için her toplumda işaret dili geliştirilmiştir ve işitsel ipuçlarından olmaksızın el, parmak ve kol hareketlerini kullanılır (Vijayalakshmi ve Aarthi, 2016). İşaret dili, işitme engelli bireylerin sayılarını, harflerin ve özel karakterlerin jestleriyle vasıtasıyla kendilerini ifade etmelerine ve başkalarıyla iletişim kurmalarına yardımcı olur (Oktekin, 2018).

2015 yılı istatistiklerine göre Türkiye'de yaklaşık 836 bin işitme engelli vatandaş bulunmaktadır (Yıldız ve ark., 2018). İşitme engelliler için kullanışlı olmasına rağmen, toplumun bazı kesimleri için işaret dili hala yabancıdır. Bu nedenle, gerektiğinde işaret dilinin kullanımını sağlayan akıllı araçların teknolojik araçlarla sunulması mümkün bir çözüm olarak görülmektedir (Jantunen ve ark., 2021). Yapay zeka, tanıma ve sınıflandırma alanında



önemli ilerlemeler kaydetmiştir (Anand ve ark., 2021; Machiraju ve ark., 2021; Singh ve ark., 2021). Bu nedenle, işaret dili tanıma sistemleri, işitme engelli bireylere yardımcı olmak için bu ilerlemeyi kullanır. İşaret dili tanıma için iki ana yöntem bulunmaktadır. İlk yöntem, veri eldivenleri (Lu ve ark., 2016) ve elektromiyografi (Qi ve ark., 2020) gibi giyilebilir cihazları içerir, ancak bu cihazlar genellikle kullanışsız ve maliyetlidir. İkinci yöntem ise, yalnızca el hareketi görüntülerini yakalamak için bir kamera gerektirdiğinden ek ekipman ihtiyacını ortadan kaldıran bilgisayarla görme tabanlı yöntemdir.

Araştırmamızın temel amacı, işitme engelli bireylerin hareketlerini algılayan ve bu hareketleri metne dönüştüren bir teknoloji geliştirmektir. Bu, işaret dilini bilmeyen kişilerin bu hareketleri anlamasına yardımcı olacaktır. Bu yaklaşım, işitme engelli bireyler ile toplum arasında kesintisiz iletişimi kolaylaştırmayı hedeflemektedir. Bu kapsamda, bu araştırma, Türk işaret dili karakterlerini sınıflandırmak için gelişmiş bir veri kümesi ve model önermektedir. Bu model, çeşitli işaretleri karşılık gelen Türkçe metne sınıflandırır. Bu sistem, işaretleri Türk alfabesine çevirerek işitme engelli bireylerin etkili bir şekilde iletişim kurmasını sağlar. Dahası, bu çalışmada önerilen modeller, geliştirilen veri kümesini yaklaşık %98'lik bir doğruluk oranıyla işleyebilmektedir.

Bu çalışmanın geri kalanı aşağıdaki gibi yapılandırılmıştır: İkinci bölümde konuyla ilgili bir literatür taraması sunulurken, üçüncü bölüm sistem mimarisi ve veri kümesini içeren metodolojiyi açıklar. Son olarak, dördüncü bölüm çalışmayı sonuçlandırır ve üçüncü bölümde sunulan sonuçların tartışmasını içerir.

### 1.1. İlgili Çalışmalar

Addepalli ve ark. (2023), Amerikan İşaret Dili (AİD) alfabelerini ve rakamlarını tanıyan ve bunları metne çeviren bir sistem önermişlerdir. Bir AİD veri seti oluşturmuşlar ve kapsamlı bir analizden sonra, özellik çıkarımı için AlexNet'i kullanan transfer öğrenimi ile AİD'yi metne dönüştürmenin optimal tekniğini belirlemişlerdir. AlexNet'i Naive Bayes, SVM ve KNN gibi sınıflandırma algoritmalarıyla birleştirmişler ve Naive Bayes %97.92'lik en yüksek doğruluğa ulaşırken, SVM ve KNN sırasıyla %96.98 ve %96.97 doğruluk oranlarına erişmişlerdir.

Shanmuga Priya ve ark. (2023), işaret dilini sese dönüştürmek için özel bir CNN algoritması önermektedir; bu algoritma, kullanıcıların işaret dilini "duymasını" sağlamaktadır. Bu amaçla on hareketten oluşan bir veri seti toplamışlar ve veri seti oluşturma, görüntü ön işleme ve etiketleme, veri artırma, sinir ağı eğitimi ve doğrulama verileri ile test etme gibi adımları takip etmişlerdir. Hareket tanıma sistemleri %90'ın üzerinde bir doğruluk oranına ulaşmıştır.

Shokoori ve ark. (2022), Pashto İşaret Dili'nin on alfabesi üzerine odaklanarak, engelli bireylerin toplumla iletişim kurmalarını sağlayan bir sistem önermişlerdir. Önerilen sistem, işaretleri ve hareketleri yakalar ve bunları Pashto alfabesine dönüştürür. El hareketlerini tanımak için bir

CNN modeli tasarlamışlar ve %98 doğruluğa erişmişlerdir.

Öztürk ve ark. (2021) çalışmalarında işaret dili parmak alfabesi hareketlerini tanımak için derin öğrenme ve görüntü işleme tekniklerini kullanmış, bunları metne dönüştürmüştür. Sistemi, el görüntülerini derin öğrenme yöntemleri kullanarak yorumlar, onları alfabedeki harflerle eşleştirir ve tahmin edilen harfi metin olarak görüntüler; böylece 1300 fotoğraftan oluşan bir veri kümesiyle %88 doğruluk oranı elde etmişlerdir. Toğaçar ve ark. (2021), Türk İşaret Dili (TİD) için rakam işaretlerini belirlemek için Siamese sinir ağı kullanarak, %98.16'lık eşleştirme başarısına'ya ulaşmıştır.

Katılmış ve Karakuzu (2020), Leap Motion ile çift eli kullanarak TİD alfabesini tanıyan bir sistem aracılığıyla tanıma performansını geleneksel sınıflandırıcılar ve özellik seçme algoritmalarını kullanarak analiz etmişlerdir. Bantupalli ve Xie, 2019, işaret dili işaretlerini metne çevirmek için görüntü tabanlı bir sistem önermişler, videolardan çıkarılan mekansal ve zamansal özellikleri ile Inception ve CNN yapılarını kullanarak AİD veri kümesiyle başarılı bir şekilde jest tanımlamışlardır.

Hurroo ve Walizad (2020), bir AİD alfabesi tanıma sistemi tasarlamıştır. Kendi AİD veri setlerini on statik alfabe işareti ile oluşturmuşlardır. Yaklaşımları, özellik çıkarımı (ikili pikseller) için görüntüleri 64 piksele normalleştirme ve yeniden ölçeklendirme, el hareketlerini algılamak için HSV renk algoritmasını kullanma ve siyah bir arka plan kullanma gibi adımları içermektedir. İlgili bölgesi olan el hareketi, çeşitli bilgisayar görme teknikleri (gri tonlama, genişletme ve maskeleyme) kullanılarak segmentlenir ve özellikler çıkarılır. Eğitim ve sınıflandırma için bir CNN kullanarak %90'ın üzerinde doğruluğa ulaşmışlardır.

Sabeenian ve ark. (2020), AİD alfabelerini metne çevirmek için özel bir CNN kullanarak bir sistem geliştirmişlerdir. MNIST AİD veri seti üzerinde eğitilen modelleri, %93'ün üzerinde doğruluğa ulaşmıştır.

Sevli ve Kemaloğlu (2020), Türk işaret dili rakamlarını sınıflandırmak için bir CNN modeli önermiş, Adam optimizatörü kullanarak eğitim için %98.42, test doğruluğu için %98.55 doğruluk oranı elde etmişlerdir. Yalçın ve ark., 2018, esnek sensörler ve bir jiroskop kullanarak Türk İşaret Dili (TİD) harflerini tespit edip çeviren bir veri eldiveni tasarlamışlar, 18 TİD alfabesi harfini tanımayı başarmışlardır.

Arora ve Roy (2018), Bhattacharyya Mesafe Metriği ve OpenCV kullanarak AİD jestlerini tanımayı ve metne çevirmeyi sağlayan bir teknik sunmuşlar. Bu teknik, jestlerin histogram benzerliklerine dayanmaktadır. Unutmaz ve ark. (2019), Kinect cihazından iskelet bilgilerini kullanarak Türk işaretlerini kelimelere dönüştürmek için CNN tabanlı bir sistem önerisiyle, veri kümesi ve CNN yapısına bağlı olarak %80 ila %93 arasında değişen doğruluk değerlerine erişmişlerdir.

Nguyen ve Do, 2019, yapay zeka kullanarak geliştirdikleri bir işaret dili parmak alfabesi tanıma sistemini kullanarak Çok Sınıflı Destek Vektör Makineleri (SVM'ler)


ve CNN yapıları ile tatmin edici sonuçlar elde etmişlerdir. Kaya ve ark., 2018, Türk İşaret Dili (TİD) kullanarak sayıları ve harfleri tespit etmeyi amaçlar, sensörlerle donatılmış bir veri eldiveni kullanarak başarılı bir şekilde 1 ile 5 arasındaki sayıları tespit etmişlerdir.

## 2. Materyal ve Yöntem

### 2.1. Veri Kümesi

Bu çalışma, Türk İşaret Dili (TİD) de dahil olmak üzere çeşitli işaret dilleri için kısıtlı sayıdaki veri setlerine ilaveten TİD alfabesinin yirmi üç harfine odaklanan yeni bir veri seti sunmaktadır. Bu araştırmanın temel amacı, TİD alfabesinin jestlerini metne dönüştürmektir. Bunun için TİD harflerinin görüntülerinden oluşan bir veri seti önerilmektedir. Şekil 1, TİD alfabesinin yirmi üç harfini göstermektedir.

Veri setini derlemek için, OpenCV kütüphanesini kullanarak eşik teknikleri kullanılmış ve görüntü boyutları 224x224 piksel olarak ayarlanmıştır. Ortaya çıkan veri seti, kamera mesafelerindeki değişimler, aydınlatma koşulları ve arka planlar gibi çeşitli faktörleri de içeren çeşitli koşullar altında yaklaşık 10,000 görüntü içeren zorlu bir veri setidir. Kullanıma hazır hale getirilmeden önce, görüntüler önerilen modele uygun şekilde 64x64 boyutuna yeniden boyutlandırılır. Daha sonra, veri seti eşit olarak bölünür ve %80'i eğitim için ayrılırken geri kalan %20'si doğrulama ve test amaçları için kullanılır. Dahası, veri artırma teknikleri, veri setinin çeşitliliğini artırmak ve model performansını iyileştirmek için uygulanır. Oluşturulan yeni veri seti, özellikle işaret dili tanıma araştırmaları alanında, yeni derin öğrenme uygulamalarına ilham verebilir.



Şekil 1. Yeni Veri Setinde TİD Alfabesinin Jestleri.

### 2.2. Model Yapısı

Yapay zeka ile donatılmış akıllı bilgisayarlar, doğal dil işleme, karar verme ve konuşma tanıma gibi tipik olarak insan zekası gerektiren görevleri yerine getirmek üzere geliştirilmektedir (Shanmuga Priya ve ark., 2023). Gelişmiş bir sinir ağı mimarisi olan Konvolüsyonel Sinir Ağları (CNN'ler), canlı organizmalarda gözlemlenen karmaşık görsel algı sürecinden esinlenmiştir. Dolayısıyla, günümüz araştırmalarının çoğu, tanıma sistemlerinde CNN tabanlı model yapıları kullanmaktadır (Sadeddine ve ark., 2021; Tan ve ark., 2021). Konvolüsyonel Sinir Ağları (CNN'ler), canlı organizmalarda gözlemlenen karmaşık görsel algı süreçlerinden ilham alan gelişmiş bir sinir ağı mimarisini temsil eder. Canlıların görsel bilgiyi nasıl tanıdığı ve yorumladığını taklit etmek üzere tasarlanan CNN'ler, verileri çok katmanlı olarak işleyerek ve modelleyerek görüntülerdeki karmaşık desenleri ve özellikleri tanıyabilir ve öğrenebilir. Bu nedenle, bu yapılar, nesne tespiti ve görüntü sınıflandırma gibi bilgisayarla görme görevleri için oldukça uygundur.

Son yıllarda, CNN'ler, el yazısı rakamları sınıflandırmak için kullanılan ilk yaygın olarak tanınan derin öğrenme mimarisi olan LeNet'in icadıyla başlayan çeşitli hesaplama zorluklarını çözmeye son derece etkili olduklarını kanıtlamıştır. Bu zorluklar, nesne yeniden tanımlama (Khan ve ark., 2022) ve güç tahmini (Khan ve ark., 2023) gibi çeşitli bilgisayarla görme görevlerini içerir. CNN'ler, büyük ölçekli veri kümeleriyle çalışırken, geleneksel özellik tabanlı yaklaşımlara göre üstün performansları sayesinde görüntü sınıflandırmada önemli bir ivme kazanmıştır. Başarıları, ham verilerden doğrudan karmaşık ve çok ölçekli özellikler öğrenme yeteneklerine de bağlanabilir. Dolayısıyla, CNN'ler, görüntülerdeki karmaşık desenleri ve özellikleri tanımlamalarını sağlayan yerleşik yeteneklere sahip olup, bilgisayarla görme ve diğer alanlarda kullanılmaktadır. CNN'ler, bir görüntüde çeşitli işlemler gerçekleştiren ve ağa giriş sağlayan birden çok katmandan oluşur. Bu katmanlar arasında, evrişimli katmanlar, küçük filtreler kullanarak giriş görüntüsünden özellikler çıkaran ve görüntü içinde farklı desenleri vurgulayan özellik

haritaları oluşturarak önemli bir rol oynar. Ayrıca, CNN'deki iki önemli katman arasında, özellik haritası boyutunu belirlenen bir alandaki maksimum değeri seçerek azaltan Havuzlama katmanları ve önceki katman çıkışlarına doğrusal olmayan fonksiyonlar uygulayan aktivasyon katmanları bulunur (Kaiming ve ark., 2016; Alzubaidi ve ark., 2021).

CNN'lerin sonunda, bağlantılı katmanlar, önceki katmanlarda çıkarılan özellikleri bir boyuta indirilmiş bir vektöre indirgeyerek, giriş görüntüsünü sınıflandırmak için kullanır. Son tam bağlı (FC) katmanın çıktısı, sınıf olasılıklarını belirlemek için "softmax" aktivasyon fonksiyonuyla işlenir. Evrişimli Sinir Ağları'nın (CNN'ler) eğitimi genellikle gradyan inişi veya türevlerini kullanarak öngörülen sınıf olasılıkları ile gerçek etiketler arasındaki farkı ölçen bir kayıp fonksiyonunu özimizelemeli olarak geliştirmek için kullanılır. CNN'ler, görüntü sınıflandırma faaliyetlerinde dikkate değer bir performans sergiler ve çeşitli uygulama alanlarında yaygın olarak kullanılır (Alzubaidi ve ark., 2021).

### 2.2.1. Önerilen CNN yapısı

Bu çalışmanın amacı, yeni bir veri kümesinin gereksinimlerini karşılamak için özelleştirilmiş bir CNN yapısı geliştirmektir. Bu doğrultuda, Model1, Model2 ve Model3 olmak üzere üç CNN modeli önerilmektedir. Araştırmacılar, model performansını optimize etmek için hiperparametreler de dahil olmak üzere farklı parametrelerde ayarlamalar yaparlar. CNN sonuçlarının karşılaştırmalı analizi, bu önerilen modelleri, veri kümeleriyle başa çıkmak için umut verici başlangıç noktaları olarak ortaya koymaktadır.

#### 2.2.1.1. ilk yapı (Model1)

Bu mimaride, başlangıç katmanı, boyutu (3,3) olan 32 filtre ile bir evrişimli katman (Conv2D) içerir. Giriş şekli, 64x64 piksel boyutlarındaki gri tonlamalı bir görüntüyü belirtir. Doğrusal Doğrultulu Birim (ReLU) aktivasyon fonksiyonu kullanılmıştır. Ardından, bir max-havuzlama katmanı (MaxPool2D) boyutu (2,2) olan bir havuzlama boyutu ile, birinci Conv2D katmanı tarafından oluşturulan özellik haritalarının mekansal boyutlarını azaltmak için uygulanır; bu, veri boyutunu minimize ederken temel özellikleri çıkarır. İkinci Conv2D katmanı, boyutu (3,3) olan 32 filtre ile 'aynı' olarak ayarlanmış dolgu ile birlikte gelir, böylelikle çıktı özellik haritalarının girişle aynı mekansal boyutları korunur. ReLU aktivasyon fonksiyonu kullanılarak, katman daha sonra daha fazla mekansal boyut azaltımı için (2,2) boyutunda bir başka max-havuzlama katmanı (MaxPool2D) ile devam eder. Bunun ardından, üçüncü Conv2D katmanı 'aynı' dolgu ile birlikte boyutu (3,3) olan 64 filtre içerir ve ReLU aktivasyon fonksiyonunu kullanır. Daha sonra, üçüncü havuzlama katmanı (MaxPool2D) boyutu (1,1) olan çıktı özellik haritalarına uygulanır, böylelikle soyut özellikler çıkarırken mekansal boyutlar korunur.

Bir Düzleştirme katmanı, üçüncü havuzlama katmanının çıktısını 1-D vektöre dönüştürür. Ardından, iki Tam Bağlı (FC) Yoğun katman tanıtılır. İlk katmanda, CNN içinde doğrusallığı tanıtan "ReLU" ile 256 birim bulunmaktadır.

İkinci Yoğun katman veya son katman, sınıflandırma problemi içindeki 23 birime sahiptir. softmax aktivasyon fonksiyonu, ağ çıkışı sınıflandırma görevlerine göre olasılık dağılımına dönüştürür.

Bu mimari, özellik haritalarının mekansal boyutlarını azaltmak için takiben "ReLU" aktivasyon fonksiyonları kullanan üç evrişimli katman (Conv2D) içerir. Son olarak, softmax aktivasyon fonksiyonu aracılığıyla final sınıflandırma çıkışına ulaşmak için iki FC Yoğun katmanı ile sonuçlanır. Model1'in yapısının grafik temsilini görmek için Şekil 2a'ye bakınız.

#### 2.2.1.2. ikinci yapı (Model2)

Bu mimari, bir Evrişimli Sinir Ağı (CNN), dört evrişimli (Conv2D) katman, üç maksimum havuzlama (MaxPool2D) katmanı ve üç tamamen bağlı (FC) katman içerir. Başlangıçta, birinci katman, boyutu (3,3) olan 32 filtreye sahip bir Conv2D katmanını içerir ve 'aynı' dolgu ile birlikte Doğrusal Doğrultulu Birim (ReLU) aktivasyon fonksiyonunu kullanır. Devamında, ikinci katman, boyutu (3,3) olan ve 64 filtre içeren bir Conv2D katmanını tanıtarak işlemi sürdürür. Bu katman aynı dolguyu ve ReLU aktivasyon fonksiyonunu kullanır. Daha sonra, üçüncü katman, (2,2) boyutunda bir havuzlama boyutu ve (2,2) adımlı bir MaxPool2D katmanı içerir. Dördüncü katman, %25'ini rastgele düşürmek için uygulanan 0.25'lik bir düşme oranına sahip bir Düşme katmanıdır, bu da aşırı uyumlanmayı azaltır. Devamında, beşinci katman, boyutu (3,3) olan 64 filtreye sahip başka bir Conv2D katmanını, 'aynı' dolgu ve ReLU fonksiyonunu içerir. Bunu, (2,2) boyutunda bir havuzlama boyutu ve (2,2) adımlı bir MaxPool2D katmanı olan altıncı katman takip eder. Daha sonra, yedinci katman, %25'ini rastgele düşürmek için uygulanan 0.25'lik bir düşme oranına sahip bir Düşme katmanını içerir. Sekizinci katman, 128 filtre ve (3,3) boyutunda Conv2D katmanını içerir. Bu katmanda aynı dolgu ve ReLU aktivasyon fonksiyonu kullanılır. MaxPool2D (2,2) dokuzuncu katmandır. Sonrasında, onuncu katman, 2D özellik haritalarını 1D özellik vektörüne dönüştüren bir Düzleştirme katmanını içerir. Bunun ardından, on birinci katman, 256 nöron ve bir ReLU fonksiyonu ile Tam Bağlı yoğun katmanları içerir. Aşırı uyumlanmayı önlemek için 0,5'lik bir düşme oranıyla bir Düşme katmanı daha sonradan uygulanır. Son olarak, son katmanda, sınıflandırma problemindeki çıkış sınıflarının sayısına eşit olan 23 birimden oluşan bir tam bağlı yoğun katman bulunmaktadır. Sınıflandırma için softmax aktivasyon fonksiyonu kullanılır ve sınıf olasılıkları üretilir. Model2'nin detaylı yapısını Şekil 2b'de gösterilmiştir.



Şekil. 2. Model yapısı. a) Model 1, b) Model 2, c) Model 3.

### 2.2.1.3. üçüncü yapı (Model3)

Üçüncü model, her birinin boyutu (3,3) olan 32 filtre kullanarak giriş görüntüsü üzerinde evrişim işlemleri uygulayan bir evrişimli sinir ağı (CNN) mimarisine başlar. Bu katman, 'aynı' olarak ayarlanmış bir dolgu parametresi kullanır ve aktivasyon fonksiyonu olarak Doğrusal Doğrultulu Birim (ReLU) kullanır. Ardından, ikinci katman olarak başka bir Conv2D katmanı kullanılır, her birinin boyutu (3,3) olan 32 filtre içerir ve 'aynı' dolgu ile birlikte ReLU fonksiyonunun çıktısına uygulanır. Üçüncü Conv2D katmanı, boyutu (3,3) olan 64 filtre ve

'aynı' dolgu işlemi için 'aynı' değeri korur ve tekrar ReLU aktivasyon fonksiyonunu kullanır. Conv2D katmanlarını takiben, maksimum havuzlama işlemi uygulamak için (2,2) boyutunda bir havuzlama boyutuna ve adımlara sahip bir MaxPooling2D katmanı tanıtılır. Devamında, beşinci katman olarak, boyutu (3,3) olan 64 filtre ve 'aynı' dolgu kullanılan başka bir Conv2D katmanı, ReLU fonksiyonuyla birlikte kullanılır. Sonrasında, altıncı katman, önceki ile aynı havuzlama boyutu ve adımlara sahip bir MaxPooling2D katmanını içerir. Yedinci katman, boyutu (3,3) olan ve 128 filtre ile donatılmış bir Conv2D

katmanını barındırır. Bu katman, aynı dolgu işlemini korur ve ReLU aktivasyon fonksiyonunu benimser. Ardından gelen MaxPooling2D katmanı, önceki havuzlama katmanlarının parametrelerine uyumlu olarak tasarlanmıştır. Önceki katmanlardan sonra bir Düzleştirme katmanı, çok boyutlu özellik haritalarını bir 1-D vektöre dönüştürmek için eklenir. Daha sonra, 256 birime sahip bir Yoğun katman ve ReLU fonksiyonu tanıtılır. Aşırı uyumlanmayı önlemek için 0,5'lik bir düşme oranıyla bir Düşme katmanı uygulanır. Modelin sonunda sınıflandırma görevi için 23 nöronlu bir Yoğun katman bulunmaktadır. Bu nedenle bu katman Softmax aktivasyon fonksiyonunu kullanır. Model3'ün yapısına ilişkin kapsamlı bir genel bakışı Şekil 2c'de verilmiştir.

### 3. Bulgular ve Tartışma

Bu bölüm, yeni veri kümesinin önerilen modellerde (Model1, Model2 ve Model3) eğitilmesinin sonuçlarını, Veri Artırma, Düzenleme ve hiperparametre ayarlama gibi çeşitli tekniklerle sonuçları geliştirme stratejileriyle birlikte sunar.

Veri Artırma teknikleri, yansıtma, döndürme ve ölçekleme gibi, eğitim veri kümesini genişletmek için kullanılır ve modellerin yeni veri örneklerine daha iyi genelleme yapmasını sağlar. Ayrıca, aşırı uydurmaya azaltmak ve modellerin genel genelleme yeteneğini güçlendirmek için özellikle düşme gibi Düzenleme teknikleri uygulanır.

Ayrıca, Ön Ayarlama Teknikleri, öğrenme hızı ve epok (epoch) sayısı gibi parametrelerdeki ayarlamaları içerir ve modeller için en uygun yapılandırmanın belirlenmesi için yapılır.

Önerilen modeller başlangıçta 100 epok için eğitilir, daha sonra performans iyileştirmeleri için 500 epoka kadar uzatılabilir. Ancak, etkili model eğitimi için yaklaşık 150 epokun yeterli olduğu gözlemlenmiştir.

Adam optimizyer, en çok tercih edilen optimizyer yapısıdır, 0.001 öğrenme oranı en umut verici sonuçları verir. 0.01 ve 0.0001 gibi alternatif öğrenme oranları, seçilen yapılandırmanın sağlamlığını gösterebilir fakat önemli bir iyileşme sağlamaz. Ayrıca, Stokastik Gradyan İnişi (SGD) gibi diğer optimizasyonlarla yapılan denemeler tatmin edici sonuçlar vermez.

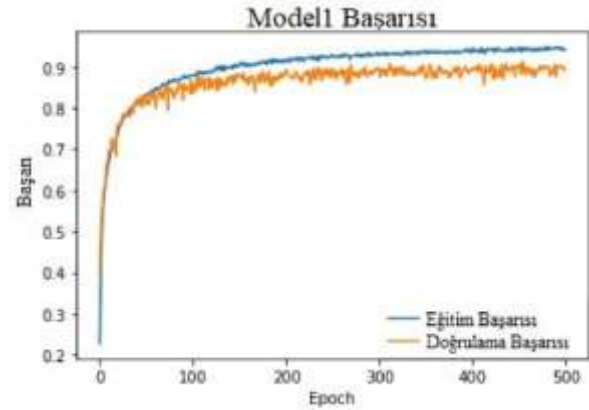
Özetle, Veri Artırma, Düzenleme ve Hiperparametre Ayarlama kombinasyonu, CNN modellerinin performansını artırmaya önemli ölçüde katkı sağlar. Modeller arasında, en yüksek doğruluğu %98 ve 0,097 kayıpla elde eden Model3 öne çıkmıştır. Bu model, istenen doğruluğa sadece 80 epok sonunda ulaşarak etkili bir eğitim gösterir.

#### 3.1. Model 1


Bu yapılandırmada, adaptif öğrenme oranı optimizasyon algoritması Adam kullanılarak öğrenme oranı 0.001 olarak belirlendiğinde araştırma en iyi sonuçları verir. Genellikle çoklu sınıflandırma senaryolarında kullanılan kayıp fonksiyonu 'categorical\_crossentropy' olarak adlandırılır. Değerlendirme metriği 'doğruluk'tur ve modelin doğrulama veya test verileri üzerindeki tahmin

doğruluğunu değerlendirir. Bu ayarlar altında, Model 1, 300 epok sonrasında %88 doğruluk oranı ve 0.413 kayıp, ve 500 epok sonrasında %89.72 doğruluk oranı ve 0.42 kayıp elde edilmiştir. Özellikle, epok sayısını arttırmanın bu durumda önemli faydalar sağlamadığı dikkat çekmektedir. Şekil 3, 500 epok ve 0.001 öğrenme oranı ile Model 1'in eğitim ve doğrulama doğruluğunu (a) ve kaybını (b) göstermektedir.

Model 1'in öğrenme oranı 0.0001'e ayarlandığında, model 300 epok sonrasında %80 doğruluk oranı ve 0,57 kayıpla elde eder, bu da bu öğrenme oranının Model 1 için alt-optimal olduğunu göstermiştir. Tersine, öğrenme oranını 0.01'e düşürmek, yaklaşık %50 doğruluk oranı ve 2 kayıp ile sonuçlanır, bu da bu öğrenme oranının Model 1 için uygun olmadığını gösterir.



a



b


Şekil 3. Model 1'in eğitim ve doğrulama doğruluğu (başarısı) (a) ve kaybı (b).

#### 3.2. Model 2


Bu yapılandırmada, tüm Düşme katmanları kullanıldığında, doğrulama doğruluğu eğitim doğruluğunu aşar, bu da potansiyel aşırı uydurmaya işaret eder. Şekil 4, 500 epok ve 0.001 öğrenme oranı ile Model 2'nin eğitim ve doğrulama doğruluğunu (a) ve kaybını (b) göstermektedir. Sonuç olarak, ilk ve ikinci Düşme katmanları kaldırıldığında, modelin performansında iyileşme gözlemlenmiştir. Adaptif öğrenme oranı optimizasyon algoritması olan Adam kullanılarak,

öğrenme oranı 0.001 olarak ayarlandığında ve sadece Yoğun (23) Öncesi son Düşme katmanının korunduğu durumda, Model 2 en iyi sonuçlarını vermiştir. 0,5 ve 0.25 Düşme oranlarıyla deney yapıldığında, 0,5 Düşme oranının en iyi sonucu verdiği görülmüştür. Öğrenme oranı 0.001 ve kayıp fonksiyonu olarak kategorik çapraz-entropi kullanılarak Adam optimizier ile Model 2 yaklaşık %97 doğruluk oranı ve 0.099 kayıp vermiştir.

Şekil 5, iki Düşme katmanı kaldırıldıktan sonra 500 epok ve 0.001 öğrenme oranı ile Model 2'nin eğitim ve doğrulama doğruluğunu (a) ve kaybını (b) göstermektedir. Özellikle, belirli Düşme katmanlarının kaldırılmasının ardından Model 2, Model 1'i geride bırakmıştır. Ayrıca, Model 2, istenen doğruluğa 100 epok içinde ulaşırken, Model 1'in yaklaşık 500 epok gerektirmektedir.

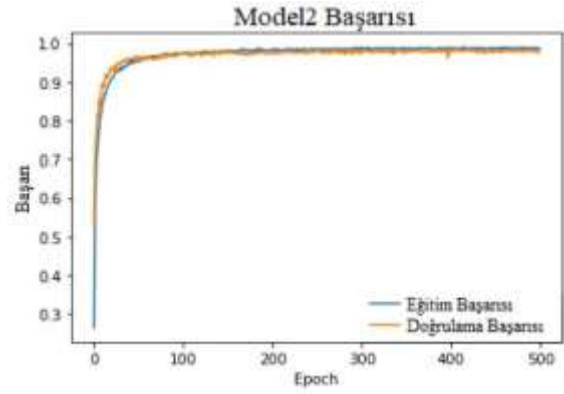


a

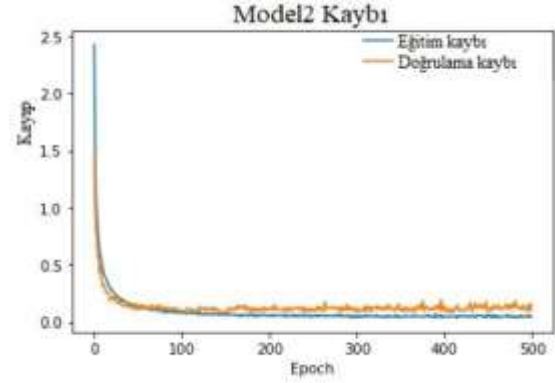


B

Şekil 4. Model 2'in (a) eğitim ve doğrulama doğruluğu (başarısı) ve (b) kaybı.



a




b

Şekil 5. Model 2 yapısından iki Dropout katmanı çıkarıldıktan sonra (a) eğitim ve doğrulama doğruluğu (başarısı) ve (b) kaybı.

### 3.3. Model 3

Model 3, girişte üç Conv2D katmanı kullanılması ve çıkış aşamasında bir Dropout katmanının dahil edilmesi nedeniyle üstün performans sergiler. Adam optimizier ve öğrenme oranı 0.001 olarak derlenen Model 3, çoklu sınıflandırma problemleri için uygun olan kategorik çapraz-entropiyi kayıp fonksiyonu olarak kullanır ve doğruluk üzerinden performansı değerlendirir. Bu koşullar altında Model 3, yaklaşık %98 doğruluk oranı ve 0.097 kayıp neticesini vermiştir. Şekil 6, Model 3 yapısının 500 epok ve 0.001 öğrenme oranı ile eğitim ve doğrulama doğruluğunu (a) ve kaybını (b) göstermektedir.

Model 3, performans açısından hem Model 1'i hem de Model 2'yi geçmektedir. Özellikle, Model 3, istenen doğruluğa sadece 80 epok sonunda ulaşırken, yaklaşık 500 epok gerektiren Model 1 ve daha düşük doğruluk elde etmek için yaklaşık 100 epok gerektiren Model 2'ye kıyasla verimlidir. Ayrıca, Adam optimizier kullanılarak 0.0001 öğrenme oranı ile yapılan deneyler, 200 epok sonrasında tatmin edici bir doğruluk sağlayamamış, bu da bu bağlamda 0.001 öğrenme oranının optimal bir seçim olduğunu yeniden doğrulamıştır.



**Şekil 6.** Model 3 yapısının (a) eğitim ve doğrulama doğruluğu (başarısı) ve (b) kaybı.

Tablo 1, farklı koşullar altında eğitilen çeşitli sinir ağı modellerinin kapsamlı bir analizini sunmaktadır. Her modelin yapısını, epoch sayısını, optimizasyon edici fonksiyonunu, öğrenme oranını, kayıp fonksiyonunu ve elde edilen doğruluğu ayrıntılı olarak açıklamaktadır. Bu analiz, model performansını en üst düzeye çıkarmak için en uygun yapılandırmayı belirlemeyi amaçlamaktadır. Sonuçlar, model etkinliğini belirlemede optimizasyon fonksiyonu seçimi, öğrenme oranı ve eğitim süresinin kritik rolünü vurgulamaktadır. Model 1, artan epoch sayısı ve uygun öğrenme oranları ile kademeli olarak iyileşme göstermiş ve Adam optimize edici her durumda SGD'den daha iyi sonuçlar vermiştir. Model 2'nin başlangıçtaki aşırı uyum sorunu, dropout katmanlarının azaltılmasıyla etkili bir şekilde giderilmiş ve önemli bir doğruluk artışı sağlanmıştır. Model 3'ün daha az epoch ile üstün performansı, potansiyel olarak daha verimli bir mimari veya optimal hiperparametre ayarlarını göstermektedir. Sonuç olarak, bulgular, derin öğrenme modellerini optimize etmede hassas hiperparametre ayarlarının ve mimari yapının önemini göstermektedir. Farklı model yapıları arasındaki performans varyasyonlarında görüldüğü gibi, en kullanışlı yapıları belirlemek için tekrarlı deneyler ve iyileştirmeler gereklidir.

Tablo 2, işaret dili tanıma üzerine odaklanan çeşitli

çalışmaların kapsamlı bir karşılaştırmasını sunmaktadır ve kullanılan işaret dili veri setleri, önerilen algoritmalar ve bunların doğruluk oranları detaylandırılmaktadır. Bu karşılaştırmalı çalışma ile farklı işaret dili veri setleri ve yaklaşımlar arasında algoritmik performanstaki eğilimleri belirlenmiştir. Analiz, Konvolüsyonel Sinir Ağlarının (CNN'ler) çeşitli işaret dili veri setleri ve türlerinde yüksek doğruluk oranlarına eriştiğini göstermektedir. Alfabe, kelime veya jestler için CNN kullanan çalışmalarda, doğruluk oranları %80.85 ile %98 arasında değişmektedir.

AlexNet ile farklı sınıflandırıcıları (KNN, SVM, Naive Bayes) birleştiren hibrit modellerin performansı hem alfabe hem de rakamları içeren veri setleri için kabul edilebilir seviyededir. Bu kategoride gözlemlenen en yüksek doğruluk oranı, AlexNet ile Naive Bayes'in birleştirilmesiyle elde edilen %97.92'dir. Önerilen CNN modelinin (Model3) %98 seviyesindeki doğruluk oranları mevcut en yüksek doğruluk oranları ile eşdeğerdir ve modelin Türk işaret dilini tanıma gücünü göstermektedir. Önerilen model işaret dili tanıma alanında rekabetçi bir yaklaşımdır.

#### 4. Sonuç

İşitme engelliler için topluluk içinde iletişim aracı olarak işaret dili önemli bir rol oynar. Derin öğrenme teknolojisindeki ilerlemelerin kullanılması, işitme engelli bireylerle işitme engeli olmayanlar arasındaki iletişimi kolaylaştıran sistemlerin tasarlanmasında hayati öneme sahiptir. Bu araştırma yeni bir veri kümesi oluşturmuştur. Ardından, yeni oluşturulan veri kümesini işlemek için özel olarak tasarlanmış bir Evrişimli Sinir Ağı (CNN) modeli geliştirilmiştir. Bu makalede sunulan modeller, yeni veri kümesinin ortaya çıkardığı zorlukları ele almayı amaçlayan sonraki araştırma çabaları için temel bir çerçeve olarak kurgulanmıştır. Geniş parametre ayarlamaları ve model katmanlarında yapılan değişikliklerle, yaklaşık %98 doğruluk oranına sahip bir son model elde edilmiştir. İlerleyen çalışmalar, veri kümesini genişletme ve doğruluk oranlarını daha da artırmak için model iyileştirme üzerine odaklanacaktır.



**Tablo 1.** Farklı koşullar altında eğitilen çeşitli sinir ağı modellerinin kapsamlı bir analizi.

Yapı	Epok Sayısı	Optimizasyon Fonksiyonu	Öğrenme Oranı	Kayıp Fonksiyonu	Doğruluk
Model1	100	SGD	0.001	'categorical_crossentropy	45.62%
Model1	500	Adam	0.01	'categorical_crossentropy	56.54%
Model1	300	Adam	0.0001	'categorical_crossentropy	80%
Model1	100	Adam	0.001	'categorical_crossentropy	84.06%
Model1	300	Adam	0.001	'categorical_crossentropy	88%
Model1	500	Adam	0.001	'categorical_crossentropy	89.72%
Model2 (3 Dropout katmanı)			Aşırı Uyum (Overfitting)		
İki Dropout katmanı çıkarıldıktan sonra Model2	100	Adam	0.001	'categorical_crossentropy	97.53%
Model3	80	Adam	0.001	'categorical_crossentropy	98%

**Tablo 2.** İşaret dili tanıma üzerine odaklanan çeşitli çalışmaların kapsamlı bir karşılaştırmalı analizi.

Kaynak	İşaret Dili Türü	Önerilen Algoritma	Doğruluk
Unutmaz ve ark., 2019,	9 TİD kelimesi	CNN	80.85%
		Karar Ağacı	53.83%
		Ağırlıklı KNN	61.40%
		Doğrusal SVM	71.47%
		Gauss SVM	49.95%
Sabeenian ve ark., 2020	MNIST AİD veri seti (alfabeler)	CNN	93%
Hurroo ve Walizad, 2020	10 AİD alfabeti	CNN	90%
Öztürk ve ark., 2021	TİD alfabeler	Faster R-CNN	88%
Shokoori ve ark.,2022	10 Pashto İşaret Dili alfabeti	CNN	98%
Shanmuga Priya ve ark., 2023	10 jest	CNN	90%
Addepalli ve ark., 2023	AİD (Alfabeler + rakamlar)	AlexNet + KNN	96.97%
		AlexNet + SVM	96.98%
		AlexNet + Naive Bayes	97.92%
Bizim Yapımız	TİD alfabeler	Model3-CNN	98%

#### Katkı Oranı Beyanı

Yazar(lar)ın katkı yüzdesi aşağıda verilmiştir. Tüm yazarlar makaleyi incelemiş ve onaylamıştır.

	T.O.	R.U.
K	50	50
T	50	50
Y	50	50
VTI	50	50
VAY	50	50
KT	50	50
YZ	50	50
KI	50	50
GR	50	50
PY	50	50
FA	50	50

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

#### Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

#### Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

#### Destek ve Teşekkür Beyanı

Bu çalışmada yer alan kısmi nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) gerçekleştirilmiştir. Bu çalışma Ankara Yıldırım Beyazıt Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince Desteklenmiştir. Proje Numarası: FDK-2022-2283.

#### Kaynaklar

- Addepalli N, Pabolu RK, GaneshChennuru S, Vissampalli VL, Madhumati GL. 2023. Conversion of American Sign Language to text using deep learning for feature extraction and naive bayes for classification. In: IEEE 8th International Conference for Convergence in Technology (I2CT), April 07-09, Lonavla, India, pp: 1.
- Alshehri S. 2023. The Relationship between Language and Identity. Int J Linguist Lit Transl, 6(7): 156-161.
- Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, Santamaria J, Fadhel MA, Al-Amidie M, Farhan L. 2021. Review of deep learning: concepts CNN architectures

- challenges applications future directions. *J Big Data*, 8(52): 1-74.
- Anand K, Urolagin S, Mishra RK. 2021. How does hand gestures in videos impact social media engagement - Insights based on deep learning? *Int J Inf Manag Data Insights*, 1(2): 100036.
- Arora S, Roy A. 2018. Recognition of sign language using image processing. *Int J Bus Intell Data Min*, 13(1-3): 163-176.
- Bantupalli K, Xie Y. 2019. American Sign Language recognition using deep learning and computer vision. In: *IEEE International Conference on Big Data*, December 10-13, Seattle, WA, USA, pp: 4896.
- Hurroo M, Walizad ME. 2020. Sign language recognition system using convolutional neural network and computer vision. *Int J Eng Res Technol*, 9(12): 59-64.
- Jantunen T, Rousi R, Rainò P, Turunen M, MoeenValipoor M, García N. 2021. Is there any hope for developing automated translation technology for sign languages? In: *Hämäläinen M, Partanen N, Alnajjar K. Editors. Multilingual Facilitation. University of Helsinki Rootroo*, pp: 61-73.
- Kaiming H, Xiangyu Z, Shaoqing R, Jian S. 2016. Deep residual learning for image recognition. In: *IEEE Conference on Computer Vision and Pattern Recognition*, June 27-30, Las Vegas, NV, USA, pp: 770.
- Karaca MF, Bayır Ş. 2018. Türk işaret dili incelemesi: İletişim ve dil bilgisi. *Ulus Eğitim Akad Derg*, 2(2): 35-58.
- Katılmış Z, Karakuzu C. 2020. Recognition of two-handed posture finger turkish sign language alphabet. In: *5th International Conference on Computer Science and Engineering (UBMK)*, September 09-11, Diyarbakir, Türkiye, pp: 5.
- Kaya F, Tuncer AF, Yildiz Ş. K. 2018. Detection of the turkish sign language alphabet with strain sensor based data glove. In: *26th IEEE Signal Processing and Communications Applications Conference SIU*, May 02-05, Izmir, Turkey, pp: 1.
- Khan SU, Haq IU, Khan N, Muhammad K, Hijji M, Baik SW. 2022. Learning to rank: An intelligent system for person reidentification. *Int J Intell Syst*, 37(9): 5924-5948.
- Khan SU, Khan N, Ullah FUM, Kim MJ, Lee MY, Baik SW. 2023. Towards intelligent building energy management: AI-based framework for power consumption and generation forecasting. *Energy Build*, 279(2023): 112705.
- Lu D, Yu Y, Liu H. 2016. Gesture recognition using data glove: An extreme learning machine method. In: *2016 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, December 03-07, Qingdao, China, pp: 1349.
- MacHiraju S, Urolagin S, Mishra RK, Sharma V. 2021. Face mask detection using keras opencv and tensorflow by implementing mobilenetv2. In: *2021 3rd International Conference on Advances in Computing Communication Control and Networking (ICAC3N)*, December 17-18, Greater Noida, India, pp: 1485.
- Nguyen HBD, Do HN. 2019. Deep learning for American Sign Language fingerspelling recognition system. In: *2019 26th International Conference on Telecommunications (ICT)*, April 08-10, Hanoi, Vietnam, pp: 314.
- Oktekin B. 2018. Development of Turkish sign language recognition application. MSc thesis, Near East University the Graduate School Of Applied Sciences, Nicosia, Turkish Republic of Northern Cyprus, pp: 71.
- Öztürk A, Karatekin M, Saylar İA, Bardakci NB. 2021. Recognition of sign language letters using image processing and deep learning methods. *J Intell Syst Theory Appl*, 4(1): 17-23.
- Qi J, Jiang G, Li G, Sun Y, Tao B. 2020. Surface EMG hand gesture recognition system based on PCA and GRNN. *Neural Comput Appl*, 32(10): 6343-6351.
- Sabeenian RS, SaiBharathwaj S, MohamedAadhil M. 2020. Sign language recognition using deep learning and computer vision. *J Adv Res Dyn Control Syst*, 12(5 Special Issue): 964-968.
- Sadeddine K, Chelali ZF, Djeradi R, Djeradi A, BenAbderrahmane S. 2021. Recognition of user-dependent and independent static hand gestures: Application to sign language. *J Vis Commun Image Represent*, 79(March): 103193.
- Sevli O, Kemaloğlu N. 2020. Turkish sign language digits classification with CNN using different optimizers. *Int Adv Res Eng J*, 4(3): 200-207.
- ShanmugaPriya G, NitishaSree V, Magisha K, Pooviga S. 2023. Gesture recognition using convolutional neural network. In: *2023 Second International Conference on Advances in Computational Intelligence and Communication (ICACIC)*, December 07-08, Puducherry, India, pp: 1.
- Shokoori AF, Shinwari M, Popal JA, Meena J. 2022. Sign language recognition and translation into pashto language alphabets. In: *6th International Conference on Computing Methodologies and Communication (ICCMC)*, March 29-31, Erode, India, pp: 1401.
- Singh P, Krishn Mishra R, Urolagin S, Sharma V. 2021. Enhancing Security by identifying facial check-in using deep convolutional neural network. In: *3rd International Conference on Advances in Computing Communication Control and Networking (ICAC3N)*, December 17-18, Greater Noida, India, pp: 1006.
- Tan YS, Lim KM, Tee C, Lee CP, Low C. Y. 2021. Convolutional neural network with spatial pyramid pooling for hand gesture recognition. *Neural Comput Appl*, 33(10): 5339-5351.
- Thomas J, Mcdonagh D. 2013. Shared language: Towards more effective communication. *Australas Med J*, 6(1): 46-54.
- Toğaçar M, Cömert Z, Ergen B. 2021. Recognition of the digits in Turkish sign language using siamese neural networks. *Dokuz Eylul Uni Fac Eng J Sci Eng*, 23(68): 349-356.
- Unutmaz B, Karaca A. C, Güllü M. K. 2019. Kinect iskelet ve evrişimsel sinir ağları ile Türkçe işaret dili tanıma. In: *2019 27th Signal Processing and Communications Applications Conference (SIU)*, April 24-26, Sivas, Türkiye, pp: 2.
- Vijayalakshmi P, Aarthi M. 2016. Sign language to speech conversion. In: *2016 International Conference on Recent Trends in Information Technology (ICRTIT 2016)*, April 08-09, Chennai, India, pp: 1.
- Yalçın M, Ilgaz S, Özkul G, KumbayYildiz Ş. 2018. Türkçe işaret dili alfabeti çevirici / Turkish sign language alphabet translator. In: *26th Signal Processing and Communications Applications Conference (SIU)*: May 02-05 Izmir, Türkiye, pp: 4.
- Yıldız Z, Yıldız S, Bozyer S. 2018. İşitme engelli turizmi sessizturizm: dünya ve türkiye potansiyeline yönelik bir değerlendirme. *Süleyman Demirel Üniv Vizyoner Derg*, 9(20): 103-117.