

## Türk İşaret Dilindeki Harflerin Tespiti İçin Derin Öğrenme Tekniğinin Kullanımı

Ahmet ÇINAR<sup>1</sup>, Merve ERKUŞ<sup>2\*</sup> ve Taner TUNCER<sup>3</sup>

<sup>1</sup>Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>3</sup>Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*merverkus17@gmail.com

**Özet** – İşaret dili, işitme veya konuşma engelli bireylerin mimikler ve el hareketleri ile iletişim kurdukları görsel bir dildir. İşitme veya konuşma engelli bireylerin hem kendi aralarında hem de diğer insanlarla anlaşabilmesi için işaret dilini tanıma sistemlerine olan ihtiyaç her geçen gün artmaktadır. Bu çalışmada, el ve parmaklar ile gösterilen hareketleri kamera karşısında algılayan ve harekete karşılık gelen harfi tanıyan YOLOv5 mimarisinin kullanıldığı bir yapı esas alınmıştır. Kaggle'dan alınan Türk işaret dilinin, Türkçe Parmak Yazımı Alfabeti ile verildiği bir veri seti kullanılmıştır. Bu veri seti 29 sınıftan oluşmaktadır ve her sınıf, Türk alfabesinin bir harfini temsil etmektedir. Harflerin algılanması ve tespit edilmesinde, bütün sınıflar için mAP değeri %99.4 elde edilmiştir. Literatür çalışmalarına kıyasla daha yüksek mAP değerleri ve daha yüksek başarı oranları edilmiştir.

**Anahtar Kelimeler** – Türk İşaret Dili, İşaret Dili Tanıma, Derin Öğrenme, YOLOv5, Harf Tespiti

### I. GİRİŞ

İletişim, iletilmek istenen bilginin hem gönderici hem de alıcı tarafından anlaşıldığı ortamda bilginin bir göndericiden bir alıcıya aktarılma sürecidir. İletişim, insanların birbirini anlaması, bilgi alışverişi yapması ve ihtiyaçlarını karşılama adına bir gereklilik taşımaktadır. İşitme veya konuşma engelli bireylerin iletişimde yaşadığı zorluklar yadsınamaz bir sorundur. Bu sorunları ortadan kaldırmak için işaret dili geliştirilmiştir. İşaret dili, işitme veya konuşma engelli bireylerin mimikler ve el hareketleri ile iletişim kurdukları görsel bir dildir. Bu dil ile işitme veya konuşma engelli bireyler birbirleri ile çok rahat bir şekilde iletişim kurmaktadır. Fakat diğer insanları anlamakta ve kendilerini ifade etmekte zorlanırlar. Bu zorluğu aşmak adına engelli olsun ya da olmasın her insanın işaret dili öğrenmesi son derece önemlidir. Buna rağmen işaret dilini bilen insan sayısı oldukça azdır. Bu nedenle işaret dili tanıma sistemlerine olan ihtiyaç her gün artmaktadır. İşaret dili tanıma sistemleri, el ve parmak hareketine karşılık gelen harfi algılar ve tercüme eder. Bu sistemlerin

kullanılma nedeni işitme veya konuşma engelli bireylerin işaret dili ile diğer insanlarla arasındaki iletişimi daha anlaşılabilir ve sağlıklı kılmasıdır.

Antik Çağlarda işitme ve konuşma engelli bireylerin eğitilemeyeceği düşüncesi Orta Çağ sonlarına kadar devam etmiştir. Bu durum Rönesans'tan sonra değişmiştir [1]. Türkiye coğrafyasında ise bu bireyler işaret dilini kullanmasıyla sosyal hayata uyum sağlamışlardır. Güncel veriler dikkate alındığında Türkiye İstatistik Kurumu Türkiye'de 89.043 kişi (53.543'i erkek 35.500'i kadın) işitme engelli, 55.480 kişi de (34.672 erkek ve 20.808 kadın) konuşma engelli olduğunu raporlamıştır (Türkiye İstatistik Kurumu, 2021). İşitme veya konuşma engelli birey sayısının artışı ve yaşlandıkça işitme engeli riskinin de arttığı gösteren raporlar, işaret dili tanıma sistemlerine olan talebinde artışına neden olmaktadır. İşaret dili tanıma sistemlerinin ilgi gördüğü bugünlerde, derin öğrenme ve makine öğrenmesi tekniklerini kullanarak yapılan işaret dili tanıma çalışmaları mevcuttur. Çelik ve ark. 10 rakam ve 29 harfin hareketlerini algılayıp işaret diline çeviren bir

model önerdiler. Bu modelde Evrişimsel Sinir Ağı (CNN: Convolution Neural Network) ve Uzun Kısa Süreli Bellek (LSTM: Long Short Term Memory) derin öğrenme tekniklerini kullanarak %97 oranında bir başarı elde ettiler [2]. Özcan vd. Erciyes University Sign Language Recognition (ERUSLR) adı verilen ve 25 kelimedenden oluşan bir veri seti kullandılar. Önerdikleri GA (Genetik Algoritma) destekli GoogLeNet tabanlı CNN modeli ile %93,93'lük bir başarı elde ettiler [3]. Sevlı vd. 0-9 arasındaki rakamlardan oluşan bir veri seti kullandılar. CNN ile Adam optimize tekniğini kullandıkları bu modelden, eğitim aşamasında %98,42 ve test aşamasında %98,55 oranında bir doğruluk elde ettiler [4]. Karaca vd. Türkçe içeriklerin engelli bireyler tarafından anlaşılmasını sağlamak için 3 Boyutlu Sanal Model kullanımıyla Türk İşaret Dilinde simüle edilebileceği bir uygulama geliştirmişlerdir [5]. Yakut vd. Türk İşaret Dili harflerinin tanınmasına yönelik görüntü işleme algoritmalarını kullanan bir uygulama geliştirdiler. Ağırlıklandırılmış matris temelli ve açısal olarak görüntüdeki işaretin kenarlarının taranmasına dayalı bu uygulama ile %80 oranında başarı elde ettiler [6]. Yalçınkaya vd. kameradan alınan işaret diline ait hareket bilgilerini tanıyan ve hareketin ne anlama geldiğini önceden eğitilmiş işaret diline ait hareket bilgileri ile karşılaştıran bir yapı önerdiler. Makalede kullanılan k- en yakın komşuluk algoritması ile %95 doğruluk elde ettiler [7].

İşitme ve konuşma engelli bireyler kendi aralarında sağlıklı bir iletişim kurabilseler de, diğer insanlarla iletişimde ciddi güçlükler yaşamaktadırlar. Bu durumlarda yaşanan iletişimsizliği en aza indirmek için çalışmamızda işaret dili algılanarak, harekete karşılık gelen harf tespit edilmiştir. Böylece işitme veya konuşma engelli bireylerin iletişimde yaşayacağı aksaklık giderilmiştir.

Özetle çalışmamızın katkıları şunlardır:

- İşaret dili tanıma sistemleri üzerinde kameradan alınan gerçek zamanlı görüntülerde kullanılabilir olması.


- İşaret diline karşılık gelen el ve parmak hareketinin algılanmasında ve harfin tanınmasında yüksek doğruluk tespiti.

- Nesne tespitinde daha iyi performans sunan ve daha hızlı sonuç veren YOLOv5 algoritmasının kullanılması.

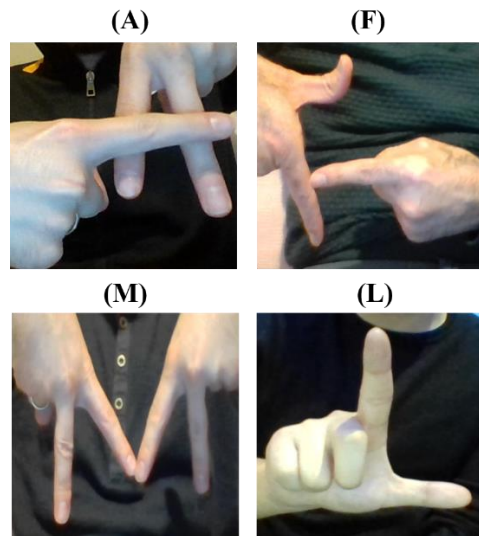
Makalemizin geri kalanı şu şekilde özetlenebilir: İkinci bölümde kullanılan veri seti ve özellikleri verilmiştir. Üçüncü bölümde kullanılan ve önerilen yapı sunulmuştur. Dördüncü bölümde elde edilen sonuçların karşılaştırılması ve çalışmadan elde edilen sonuçlar değerlendirilmiştir. Son olarak sonuçlar bölümünde çalışmanın katkıları sunulmuştur.

## II. MATERYAL

Bu çalışmada kullanılan veri seti, Kaggle [8] platformundan alınmıştır. Bu veri seti, 2974 adet Türkçe Parmak Yazımı Alfabesinin görüntülerini içermektedir. Görüntüler png formatındadır ve farklı piksellerden oluşur. Her görüntüde sadece bir harf vardır. Görüntüler, görüntüde yer alan işaret diline karşılık gelen harf ile isimlendirilmiştir. Bu veri setindeki Türk İşaret Dili 29 kategoride gruplandırılmıştır. Şekil 1'de gösterildiği gibi; her bir kategori, Türk İşaret Dili Alfabesinin bir harfine karşılık gelmektedir. Bu alfabeyle ait, veri setinde yer alan bazı gerçek görüntüler Şekil 2'de verilmiştir.



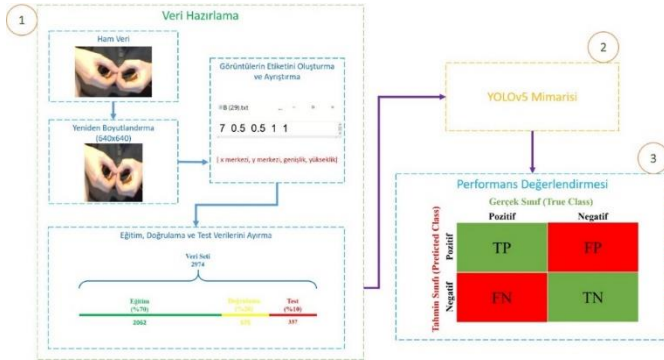
Şekil 1. Türk işaret dili alfabesi [9]



Şekil 2. Veri setindeki örnek bazı görüntüler

### III. YÖNTEM

Bu bölüm, YOLOv5 algoritması kullanılarak işaret dili algılanmasını ve tespit edilmesini sunar. Girdi olarak el ve parmak hareketlerinin çekildiği görüntüleri alan ve çıktı olarak görüntüdeki işaret dilini algılayıp sınırlayıcı kutu ile gösteren, bu hareketin harfini belirleyen, harfin doğruluğunu bulan bir yapı önerilmiştir. Önerilen yapı (1) veri hazırlama, (2) YOLOv5 mimarisi, (3) performans değerlendirmesi aşamalarından oluşmaktadır. Önerilen bu yapının 3 aşamalı diyagramı Şekil 3'te gösterilmektedir.



Şekil 3. Kullanılan yapı

#### A. Veri Hazırlama

Bu aşamada; veriler, YOLOv5 algoritmasına uygun olarak hazırlanmıştır. Veri hazırlığında, gerçekleştirilecek her bir adım için Python programlama dili ile gerçekleştirilmiştir. Öncelikle her bir görüntü 640x640 piksel olarak yeniden boyutlandırılmıştır. Sonraki adımda her bir görüntünün etiketi, YOLOv5 etiketleme biçimine uygun olarak oluşturulmuştur. YOLOv5 algoritmasında her bir görüntünün etiketi, görüntü ile aynı ada sahip metin dosyasından oluşmaktadır ve etiketleme [sınıf x\_merkezi y\_merkezi genişlik yükseklik] biçimindedir. 29 sınıftan oluşan kullandığımız veri setindeki görüntüler, görüntüdeki harf ile isimlendirilmiştir ve böylece sınıf değişkeni görüntü isimlerinden alınmıştır. Sınırlayıcı kutu koordinatları (x\_merkezi, y\_merkezi, genişlik, yükseklik) 0-1 arasına normalize edilmiştir. Etiketleme işlemi tamamlandıktan sonra, veri setindeki bütün görüntüler tek bir klasörde bulunduğu için bu veri seti sınıf bazında ayrıştırılmıştır. Ayrıştırılan veri seti sayesinde, eğitim, doğrulama ve test verilerinin sınıf bazında dengesiz ayrılması önlenmiştir. Son adımda, veri setindeki görüntülerin %70'i eğitim, %20'si doğrulama ve %10'u test veri kümesinden oluşacak şekilde ayrılmıştır. Böylece

kullanılan veri seti, YOLOv5 algoritmasına uygun hale getirilmiştir.

#### B. YOLOv5 Mimarisi

İlk aşamada veri setindeki yeniden boyutlandırılan 640x640 piksellik görüntüler, bu aşamada yer alan YOLOv5 mimarisinin Backbone(omurga) ağına verilmiştir. Backbone ağı, çoklu evrişim ve havuzlama yoluyla giriş görüntüsünden farklı boyutlarda özellik haritalarını çıkaran bir evrişimsel sinir ağıdır [10]. Bu ağ, girişine verilen görüntünün dört farklı özellik haritasını oluşturur. Backbone ağında bulunan odaklama modülü, görüntüleri dilimlere ayırır ve birleştirir. Böylece alt örnekleme esnasında özellikleri daha iyi çıkarır. Evrişim, normalizasyon ve Leaky\_relu aktivasyon katmanlarından oluşan CBL(cross-stage partial network) modülü ise, hem Backbone hem Neck(boyun) ağında bulunur. CSP ağı, çıkarma hızını iyileştirmeyi amaçlar ve model boyutunu küçülterek kesimliği korur. SPP (spatial pyramid pooling - uzamsal piramit havuzlama) modülü, farklı çekirdek boyutu ile maksimum havuzlamayı gerçekleştirir ve özellikleri bir araya getirir. Boyut azaltma işlemlerini gerçekleştiren havuzlama, yüksek bir soyutlama düzeyinde görüntü özelliklerini temsil etmek için kullanılır. Bu katman ve modüller ile elde edilen özellik haritaları, YOLOv5'in ikinci katmanı olan Neck ağına girdi olarak verilir. Bu ağda bilgi kayıplarını azaltmak ve daha fazla bağlamsal bilgi elde etmek için özellik haritaları birleştirilir. Neck ağının özellik birleştirme kabiliyetini güçlendiren, özellik piramit ağı (feature pyramid network-FPN) ve piksel toplama ağ (pixel aggregation network-PAN) yapıları kullanılır. FPN yapısı, üst özellik haritalarından alt özellik haritalarına güçlü semantik özellikleri taşıyan yapıdır. PAN yapısı, güçlü yerelleştirme özelliklerini düşük özellikli haritalardan yüksek özellikli haritalara taşıyan yapıdır. YOLOv5'in son katmanı olan çıkış ağı ise, elde edilen yeni özellik haritalarından işaret dilini algılar ve işaret dili alfabesindeki harfi tespit eder.


#### C. Performans Değerlendirmesi

Kullandığımız yapının son aşamasında karışıklık matrisi kullanılarak performans değerlendirme yapılmıştır. Karışıklık matrisi, temel olarak bir sınıflandırma algoritmasının performansını özetlemek için kullanılan bir tekniktir [11]. Şekil 4, ikili sınıflandırma için karışıklık matrisini göstermektedir. Bu çalışmada, 29 sınıflı doğrulama

veri setinin görüntüleri ile elde edilen karışıklık matrisi Şekil 5'te verilmiştir.

		Gerçek Sınıf (True Class)	
		Pozitif	Negatif
Tahmin Sınıfı (Predicted Class)	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 4. İkili sınıflandırma için karışıklık matrisi



Şekil 5. Çalışmada elde edilen karışıklık matrisi


Doğruluk, kesinlik, duyarlılık ve F1-skoru; karışıklık matrisi ile hesaplanan performans metrikleridir.

- Doğruluk: Doğru sınıflandırma oranıdır. 0-1 arasında değer döndürür. Bu değer 1'e yaklaştıkça başarı artar. Doğruluk değeri Denklem 1'deki gibi hesaplanır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FN+FP+TN} \quad (1)$$

- Kesinlik: Tahmin edilen pozitif sınıfların gerçekte ne kadar pozitif olduğunu gösterir. Kesinlik değeri Denklem 2'deki gibi hesaplanır. Çalışmada bütün sınıflar için elde edilen kesinlik değeri 0.984'tür. Şekil 6 elde edilen kesinlik eğrisini göstermektedir.

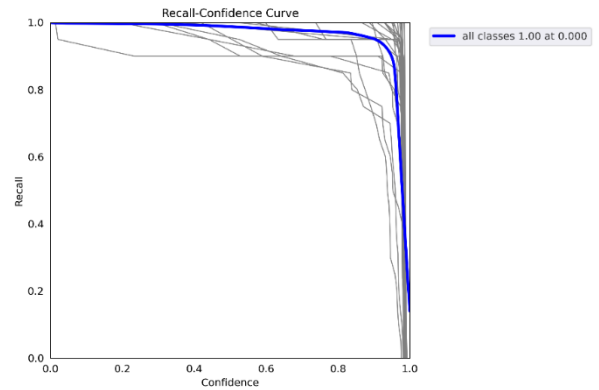
$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$



Şekil 6. Çalışmada hesaplanan kesinlik matrisi eğrisi

- Duyarlılık: Pozitif olarak tahmin edilmesi gereken sınıfların ne kadar pozitif olarak tahmin edildiğini gösterir. Duyarlılık değeri Denklem 3'deki gibi hesaplanır. Çalışmada bütün sınıflar için elde edilen duyarlılık değeri 0.972'dir. Şekil 7, elde edilen duyarlılık eğrisini göstermektedir.


$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$



Şekil 7. Çalışmada hesaplanan duyarlılık matrisi eğrisi

- F1-skoru: Kesinlik ve duyarlılık değerlerinin harmonik ortalamasını verir. F1-skoru denklem 4'deki gibi hesaplanır. Şekil 8, elde edilen F1-skoru eğrisini göstermektedir.


$$\text{F1 - skoru} = 2 * \frac{(\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (4)$$



Şekil 8. Çalışmada hesaplanan F1-skoru eğrisi

Ortalama Averaj Kesinliği (mAP – mean Average Precision); duyarlılık, kesinlik gibi değerlerin tek bir noktadan değerlendirilmesi için tasarlanmış bir performans metriğidir. Duyarlılık ve kesinlik eğrisinin altındaki alanın bulunmasını sağlar. mAP değeri denklem 5’te verilmiştir. Bu denklemde P kesinlik değerini, R ise duyarlılık değerini göstermektedir. Bu çalışmada elde edilen mAP değeri bütün sınıflar için %99.4’tür. mAP eğrisi Şekil 9’da gösterilmektedir.

$$mAP = \int_0^1 P(R) dR \quad (5)$$



Şekil 9. Çalışmada hesaplanan mAP eğrisi


#### IV. TARTIŞMA

YOLOv5 algoritmasında eğitim için 2062, doğrulama için 575 ve test için 337 görüntü kullanılmıştır. Eğitim aşamasında, epoch değeri 300 ve batch size değeri 16 olarak alınmıştır. Model 2062 görüntü ile eğitildikten sonra, 575 işaret dili alfabesinin harfini içeren doğrulama görüntüleri ile test edilmiştir. Doğrulama görüntülerinde hesaplanan ve her bir sınıfa ait mAP değeri Tablo 1’de verilmiştir. En düşük mAP değeri M sınıfında elde edilmiştir. Bütün sınıflar için elde edilen mAP değeri %99.4’dir.


Tablo 1. Eğitim aşamasında elde edilen mAP değerleri

Sınıf	mAP(%)	Sınıf	mAP(%)	Sınıf	mAP(%)
Tümü	99.4	H	99.5	P	99.5
A	99	I	99.5	R	99.5
B	99.5	İ	99.3	S	99
C	99.5	J	99.5	Ş	99.3
Ç	99.5	K	99.5	T	99.5
D	99.5	L	99.5	U	99.5
E	99.5	M	98.6	Ü	99.5
F	99.5	N	99.5	V	99.5
G	99	O	99.5	Y	99.5
Ğ	99	Ö	99.5	Z	99.5

Test aşamasında elde edilen 337 görüntüden bazıları Şekil 10 ve Şekil 11’de gösterilmektedir. Şekil 10’da gösterildiği gibi görüntülerin birçoğunda harfler %100’lük doğruluk oranıyla tespit edilirken, Şekil 11’de verilen Türk işaret dili alfabesinde yer alan noktalı ve şapkalı harfler daha düşük doğruluk oranıyla tespit edilmiştir.



Şekil 10. %100 doğruluk oranıyla tespit edilen görüntüler



Şekil 11. Daha düşük doğruluk oranıyla tespit edilen görüntüler

Önerilen yapı ile literatürde işaret dillerinin tanınması ve sınıflandırması mAP(mean Average Precision – Ortalama Hassasiyet) açısından

değerlendirildi. Karşılaştırma tablosu, Tablo 2’de verilmiştir. Amerikan İşaret Dilinin kullanıldığı [12] nolu ve Bengalce İşaret Dilinin kullanıldığı [13] nolu çalışmalarda sırasıyla CNN ve SVM kullanılmıştır, mAP değerleri %82.5 ve %96.4 elde edilmiştir. Kullandığımız yapı ile elde edilen mAP değeri %99.4’tür. Bu tabloya göre mAP değeri yapılan çalışmalardan daha yüksektir. Sonuç, YOLOv5’in algılama ve tespit çalışmalarındaki yüksek performans ve hassasiyetini göstermektedir.

Tablo 2. Önerilen yöntemler ve karşılaştırma

Referans	Tanım	mAP (%)
[12]	Veri: American Sign Language (ASL) Sınıflandırma: 26 harf Sınıflandırıcı: CNN	82,5
[13]	Veri: Bengali Sign Language (BdSL) Sınıflandırma: 11 rakam ve 16 kelime Sınıflandırıcı: SVM (Support vector machine)	96.4
Kullanılan Yapı	Veri: Türk işaret dili alfabesindeki 29 harfin yer aldığı 2974 görüntü Sınıflandırma: A, B, C, Ç, D, E, F, G, Ğ, H, I, İ, J, K, L, M, N, O, Ö, P, R, S, Ş, T, U, Ü, V, Y, Z Sınıflandırıcı: YOLOv5	99.4

## V. SONUÇLAR

İşitme veya konuşma engelli bireylerin iletişimde yaşadıkları zorluklar, işaret dili tanıma sistemleri ile ilgili çalışmalara hız vermiş ve bu sistemlerin hayata geçirilmesini sağlamıştır. Bu çalışmada Türk işaret dili alfabesindeki harf tabanlı hareketler algılanması ve tespit edilmesinde YOLOv5 tabanlı bir yapı önerilmiştir. Hareketler bireylerin ten renginden, hareketin yön ve mesafesinden bağımsızdır. Sistemin bu önemli özelliği ile beraber eğitim aşamasında bütün sınıflar için mAP değeri %99.4 elde edilmiştir. Ayrıca test aşamasında birçok görüntüde %100’e varan doğruluk değerleri elde edilmiştir. Bu sonuçlar, yapılan çalışmalara kıyasla, önerilen yapının yüksek başarısını göstermektedir.

## KAYNAKLAR

[1] H. Erten, N. Arıcı, “İşaret Dilinin Tarihi Serüveni ve Türk İşaret Dili”, *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*, 24 (1), 1-14, 2022.

[2] Ö. Çelik, A. Odabas, “Sign2Text: Konvolüsyonel Sinir Ağları Kullanarak Türk İşaret Dili Tanıma”, *Avrupa Bilim ve Teknoloji Dergisi*, sayı. 19, ss. 923-934, Ağu. 2020.

[3] T. Özcan, A. Baştürk, “ERUSLR: Yeni bir Türkçe işaret dili veri seti ve hiperparametre optimizasyonu destekli evrişimli sinir ağı ile tanınması”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 36, no. 1, pp. 527-542, Dec. 2020.

[4] O. Sevli, N. Kemalolu, “Turkish sign language digits classification with CNN using different optimizers”, *International Advanced Researches and Engineering Journal*, vol. 4, no. 3, pp. 200-207, Dec. 2020.

[5] M.F. Karaca, “Üç Boyutlu Sanal Model ile Türk İşaret Dili Simülasyonu”, *Doktora Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü*, pp. 1-198, 2018.

[6] H. Yakut, “İşaret Dili Harflerinin Görüntü İşleme Yöntemleriyle Tanınması için Bir Uygulama”, *Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü*, pp. 1-62, 2013.

[7] Ö. Yalçinkaya, A. Atvar, P. Duygulu, “Hareket Geçmiş Görüntüsü Yöntemi ile Türkçe İşaret Dilini Tanıma Uygulaması”, *24th Signal Processing and Communication Application Conference (SIU)*, pp. 1-4, 2016.

[8] Kaggle, 2018, “Turkish Sign Language (Fingerspelling)”, <https://www.kaggle.com/datasets/feronial/turkish-sign-language-finger-spelling>

[9] EGO Genel Müdürlüğü, 2021, “Türk İşaret Dili Alfabesi”, <https://isaret dili.ego.gov.tr/turk-isaret-dili-alfabesi/>

[10] L. Zhu, X. Geng, Z. Li, C. Liu, “Improving YOLOv5 with Attention Mechanism for Detecting Boulders from Planetary Images” *Remote Sensing* 13, no. 18: 3776, 2021.

[11] Medium, 2021, “What is a Confusion matrix?”, <https://medium.com/@shreyakhedkar05/task-05-86b72fd17b1>

[12] V. Bheda, D. Radpour, “Using deep convolutional networks for gesture recognition in American sign language”, arXiv preprint arXiv:1710.06836, 2017.

[13] S. M. Kamrul Hasan, M. Ahmad, “A new approach of sign language recognition system for bilingual users”, *2015 International Conference on Electrical & Electronic Engineering (ICEEE)*, pp. 33-36, 2015.