



## International Journal of Engineering and Innovative Research

<http://dergipark.gov.tr/ijeir>

### RESNET34 DERİN ÖĞRENME MİMARİSİ KULLANILARAK YÜZ GÖRÜNTÜLERİNDEN VÜCUT AĞIRLIĞI TAHMİNİ UYGULAMASI

Bekir AKSOY<sup>1</sup>, Hamdi SAYINI<sup>1</sup>, Osamah SALMANI<sup>1</sup>

<sup>1</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği, Isparta, Türkiye.

\*Sorumlu Yazar: [bekiraksoy@isparta.edu.tr](mailto:bekiraksoy@isparta.edu.tr)

<https://doi.org/10.47933/ijeir.776106>

(Received: 30.07.2020; Accepted: 11.09.2020)

**ÖZET:** Görüntü işleme teknolojileri günlük hayatımızda sıklıkla kullanılan yöntemlerden birisidir. Özellikle yapay zeka teknolojisinin hızla gelişmesi ile birlikte görüntü işleme teknolojilerinde yapay zeka yöntemleri kullanılmaya başlanmıştır. Örneğin biyomedikal görüntülerden hastalık teşhisi yapılması, yüz görüntülerinden kişilerin duygu analizlerinin yapılması, tarım alanında bitkilere ait görüntüler üzerinden hasat zamanı ve miktarının belirlenmesi gibi birçok alanda yapay zeka yöntemleri kullanılmaktadır. Çalışmada açık erişimli internet sitesi <https://academictorrents.com>'dan 61110 kişiye ait yüz görüntüleri ve bu görüntülere ait vücut ağırlığı veri seti alınmıştır. Alınan veri seti üzerinde ResNet34 derin öğrenme yöntemi kullanılarak yüz görüntülerinden bu görüntülere ait vücut ağırlığı değerlerini tahminleme için bir model oluşturulmuştur. Oluşturulan ResNet34 modeli RMSE performans değerlendirme ölçütüne göre değerlendirilerek 0.071797 hata değeri elde edilmiştir. Elde edilen hata değeri ResNet34 modelinin kullanılan veri seti üzerinde başarılı olduğunu göstermektedir.

**Anahtar Kelimeler:** Resnet34; Regresyon; Vücut Ağırlık Tahmini; Yapay Zeka.

### BODY WEIGHT ESTIMATION APPLICATION FROM FACE IMAGES USING RESNET34 DEEP LEARNING ARCHITECTURE

**ABSTRACT:** Image processing technologies are one of the methods used in daily life. With the rapid development of artificial intelligence technology in technology, artificial intelligence methods have been used. For example, diagnosis of diseases from biomedical images, confident emotion analysis of facial images, artificial intelligence methods are used in various fields of harvest time and amount of images of plants in agriculture. In the study, faces of 61110 people and body weight data set of these images were obtained from the open access website <https://academictorrents.com>. A model was created for the body weight estimation of these images to learn ResNet34 on the data set. The ResNet34 model created was evaluated according to the RMSE performance criteria and an error value of 0.071797 was obtained. The error value obtained indicates that the used data set of the ResNet34 model is successful.

**Keywords:** Resnet34; Regression; Body Weight Estimation; Artificial Intelligence.

#### 1. GİRİŞ

Görüntü işleme, insan gözü ile yapılabilen işlemlerin bilgisayar ortamında çeşitli arayüz yazılımlarıyla gerçekleştirilmesi ile hızlı sonuçlar üreten bir teknolojidir. Bu teknolojiye farklı tanıma modelleri geliştirilmiş ve bu modeller kullanılarak yapılan çalışmalar bilime önemli ölçüde katkıda bulunmuştur. Görüntü işleme ve sınıflandırma yöntemleri kullanılarak, görüntü üzerinde; nesne algılama, etiketli sınıflandırma, nesne ayırma, alt sınıflara bölme gibi birçok kategoride analizler yapılabilmektedir [1]. Görüntü işleme uygulamaları geliştirilirken

problemin türüne ve istenen sonuca göre çeşitli derin öğrenme algoritmaları kullanılmaktadır [2]. Makine öğrenmesine göre çok katmanlı bir yapıya sahip olan ve insan beyninin işleyişinden esinlenen derin öğrenmenin kullanımı, birçok alanda giderek artmaktadır [3]. Derin öğrenme ile ilgili ilk çalışmalar 1950'li yılların sonlarına dayanmasına rağmen son yıllarda başarılı bir şekilde kullanılmasının başlıca sebebi teknolojik cihazların çeşitliliği ile giderek artan büyük veri miktarıdır [4,5]. Derin öğrenmenin geleneksel makine öğrenmesi yöntemlerinden farkı, kodlanmış kurallar ile öğrenmek yerine; resim, video, ses ve metinlere ait veri simgelerinden otomatik olarak öğrenebilme özelliğine sahip olmasıdır [6].

Derin öğrenmenin önemli kullanım alanlarından birisi de bilgisayarlı görüdür. Bilgisayarlı görü; bir görüntüdeki nesnelere tanıma amacıyla, kamera görüntülerindeki özniteliklerin analiz edilerek görüntüden bilgi çıkarma işlemidir[7]. Nesne tanıma, görüntü üzerinde bulunan nesnelere, insan algısına en yakın şekilde tanımlanabilmesini sağlamak amacıyla gerçekleştirilen işlemlerdir. Yüz tanıma sistemleri ise nesne tanıma uygulamaları arasında en çok ilgi gören ve en sık kullanılan sistemlerden birisidir [8]. Yüz tanıma özellikle kimlik doğrulaması için önde gelen biyometrik tekniktir. Bu teknik askeri uygulamalar, finans, kamu güvenliği gibi birçok alanda yaygın olarak kullanılmaktadır [9]. Özellikle havaalanları, iş yerleri, oteller ve hastaneler gibi halka açık alanlarda güvenliğin sağlanması ve kimlik tespiti yapma amacıyla yoğun olarak kullanılan yüz tanıma sistemleri, aynı amaç doğrultusunda pasaport, kimlik kartı ve sürücü belgesi gibi devlet uygulamalarında da tercih edilmektedir [10]. Yüz tanıma sistemlerinde yüz görüntülerinin birbirine benzerliğinden dolayı sınıflandırma işlemlerinin hassas bir şekilde yapılması gerekmektedir [11]. Biyometri tabanlı sistemler kişinin parmak izi, yüz tanıma gibi dış görünüm veya imza yürüyüşü gibi davranış özelliklerini inceleyen sistemlerdir [12] Yakın zamanda, cinsiyet, yaş, boy ve kilo gibi özellikleri içeren biyometri uygulamaları [13-17], semantik yorumlarından dolayı sıklıkla kullanılan uygulamalardan birisi olmuştur. Yüz tanıma sistemlerinin sınıflandırılmasında genellikle derin öğrenme modelleri kullanılmaktadır.

Çalışmada açık kaynak erişimli internet sitesinden (<https://academictorrents.com>) alınan toplam 61110 insan yüzü görüntüsü ve bu görüntülere ait vücut ağırlığı verilerinden oluşan veri seti kullanılmıştır. Veri seti 48888 eğitim ve 12222 doğrulama verisi olmak üzere rastgele şekilde ikiye ayrılmıştır. Eğitim veri seti Resnet34 derin öğrenme modeli ile eğitilerek fotoğraf bilgisinden kişinin vücut ağırlığı tahminlenmiştir. Eğitilen model doğrulama veri seti ile değerlendirilmiştir. Elde edilen sonuçlar karekök ortalama hata (Root Mean Square Error-RMSE) performans değerlendirme ölçütüne göre değerlendirilerek 0.071797 hata değeri elde edilmiştir.

## 2. MATERYAL VE YÖNTEM

Çalışmada açık kaynak erişimli internet sitesinden (<https://academictorrents.com>) temin edilen 61110 adet insan yüzü fotoğrafı ve bu insanlara ait kişisel bilgilerini içeren csv dosyası veri seti olarak kullanılmıştır [18]. Kullanılan veri seti ve ResNet34 derin öğrenme modeline ait detaylı bilgiler çalışmanın materyal bölümünde verilmiştir.

### 2.1. Materyal

#### 2.1.1. Çalışmada kullanılan veri seti

Çalışmada kullanılan veri seti, iki bölümden oluşmaktadır. İlk bölüm; ABD İllinois eyaletinde tutuklu bulunan farklı yüz özelliklerine sahip erkek ve kadın toplam 61110 adet mahkûma ait

yüz fotoğrafından oluşmaktadır.



Şekil 1. Veri seti fotoğraf örnekleri.


İkinci veri seti ise yüz görüntüleri verilen mahkumlara ait kişisel bilgileri(ad, soyad, doğum tarihi, ağırlık, boy, saç rengi, göz rengi, ten rengi, cinsiyet vb.) içeren metinsel bilgilerden oluşmaktadır.

ID	Adı Soyadı	Doğum Tarihi	Kilo	Saç Rengi	Cinsiyet	Boy	İrk	Göz Rengi
0	A00147 MCCUTCHEON, JOHN	06/14/1949	185.0	Brown	Male	67.0	White	Blue
1	A00220 WALKER, ISIAH	03/30/1957	155.0	Black	Male	73.0	Black	Brown
2	A00360 BELL, HOWARD	12/18/1946	167.0	Gray or Partially Gray	Male	69.0	White	Green
3	A00367 GARVIN, RAYMOND	1.12.1954	245.0	Black	Male	72.0	Black	Brown
4	A01054 TIPTON, DARNELL	03/25/1954	166.0	Salt and Pepper	Male	67.0	Black	Brown

Şekil 2. Veri setinde yer alan kişisel bilgiler,

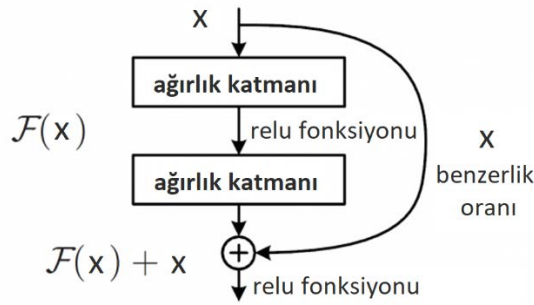
### 2.1.2. ResNet(residual network) mimarisi

ResNet mimarisi derin ve kompleks sınıflandırma problemlerini çözmek için önerilmiş olan bir evrişimli sinir ağı CNN(Convolutional Neural Network) mimarisidir [19] ResNet, VggNet, AlexNet gibi geleneksel ardışık ağ mimarilerinden farkı mikro mimari bir modül yapısına sahip olmasıdır [20]. Microsoft ekibi tarafından oluşturulan bu model [21], çok katmanlı derin ağlarda gradyan değerlerinin sıfıra yakınsama problemini ortadan kaldırmak için geliştirilmiştir. ResNet mimarisinde, alt katmanlardan elde edilen öznitelik bilgileri sıralı olarak üst katmanlara taşınmasıyla alt ve üst katmanlar arasında bir köprü kurulmaktadır [19]. ResNet mimarisi kullanılan katman sayısına göre farklı mimarilere evrilmiştir. Örneğin; ResNet101 mimarisi, 101 adet katmandan oluşmaktadır. ResNet'te katmanlar arasında yapılan atlama işlemine ResBlock ismi verilir. ResBlock sayesinde bir önceki katmanda bir şey öğrenilirse bile eski katmandaki bilgiyi yeni katmana uygulanarak model daha güçlü hale getirilir. Böylece gradyan silinmesi problemi de ResBlock ile çözülmüş olur. Optimizasyon algoritması olarak eğitim düşümü kullanılır [22]. Sıklıkla kullanılan ResNet mimarilerinden birisi de 34 katmandan oluşan ResNet34 mimarisidir. (Şekil 3)[23]



Şekil 3. ResNet-34 mimarisi [23].

Derin öğrenme mimarilerinde ağ derinleşmeye başladığında, bozulma problemi ortaya çıkmaktadır. Bu bozulma yüksek oranda eğitim hatasına yol açmakta, bu da sonuçta tüm sistemin optimize edilmesini zorlaştırmaktadır [19].



Şekil 4. ResNet mimarisi [18].

Bu problemin çözümü için Microsoft tarafından, derin artık öğrenme modeli oluşturulmuştur. Bu modelde birkaç yığılmış katmanın her birinin doğrudan istenen bir haritaya uymasını beklemek yerine, bu katmanların artık bir haritaya uymasına izin verilmektedir [21].  $F(x) + x$ 'in formülasyonu, kısayol bağlantılarına sahip ileri beslemeli sinir ağlar ile gerçekleştirilebilmektedir. Kısayol bağlantıları, Şekil 4'de gösterilen bir veya daha fazla katmanı atlayan bağlantılardır. Kısayol bağlantıları kimlik eşlemesi yapmakta ve bunların çıktılarını yığınlanmış katmanların çıktılarına eklenmektedir [22]. Bu sayede kolayca optimize edilebilen ResNet mimarisinin ağıdaki derinlik arttıkça daha yüksek eğitim hatası oluşumu önlenmekte ve diğer mimarilerden daha iyi sonuçlar üretebilmektedir [24].

### 2.1.3. Performans ölçütleri

#### 2.1.3.1 RMSE performans değerlendirme ölçütü

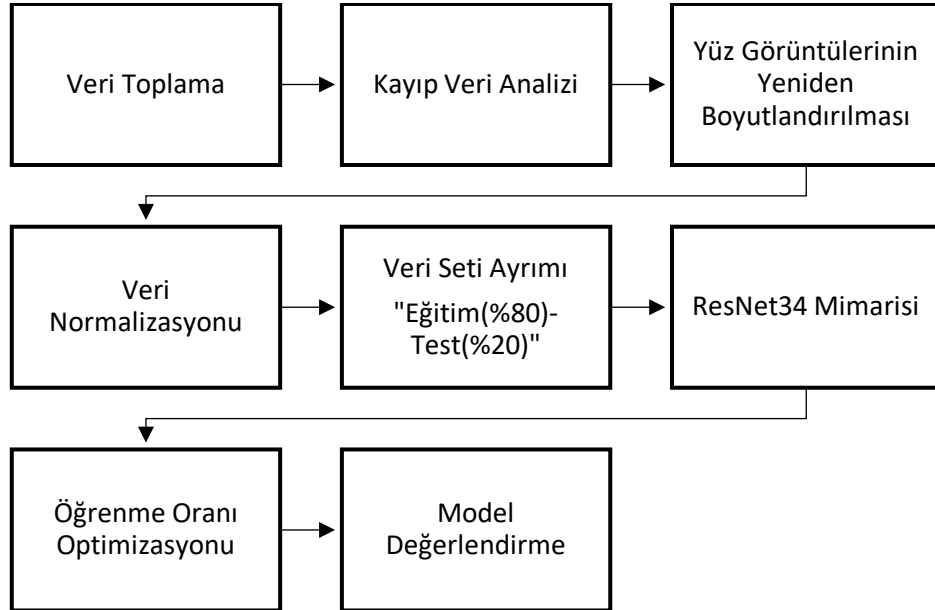
Bir modelde tahminlenen değerler ile gerçek değerler arasındaki uzaklığın hesaplanmasında kullanılan, hatanın büyüklüğünü belirten ölçüttür. RMSE tahmin hatalarının standart sapmasıdır. Yani, kalıntılar, regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür; RMSE ise bu kalıntıların ne kadar yayıldığına bir ölçüsüdür. Başka bir deyişle, verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE değeri 0'dan  $\infty$ 'a kadar değişebilir. Negatif yönelimli puanlar yani daha düşük değerlere sahip tahminleyiciler daha iyi performans gösterir. RMSE, birçok matematiksel hesaplamada istenmeyen mutlak değer kullanılmamasını engeller.

RMSE değerinin sıfıra yakın çıkması, modelin tahmin performansının mükemmel yakın olduğunu ifade etmektedir [25]. Denklem 1 de verilen  $y_i$  gerçek değeri,  $\hat{y}_i$  model tarafından tahmin edilen değeri,  $n$  veri miktarını göstermek üzere RMSE matematiksel olarak şöyle ifade edilebilir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (1)$$

## 2.1. Metot


Şekil 5’da çalışmanın iş akış diyagramı verilmiştir. Şekil 6 incelendiğinde ilk aşamada açık erişimli internet sitesinden(<https://academictorrents.com>) alınan yüz görüntüleri ve bu görüntülere ait veri seti alınmıştır. Çalışmada ilk veri setindeki yüz görüntüleri ile, ikinci veri setindeki bu görüntülere ait vücut ağırlığı bilgisi kullanılmıştır. Veri setinde yer alan diğer kişisel bilgiler analize dahil edilmemiştir. İkinci aşamada ise alınan veri seti üzerinde kayıp veri analizi gerçekleştirilmiştir. Toplam 61110 görüntüden 393 adet görüntüye ait vücut ağırlığı verileri veri setinde bulunamamıştır. Bu durumu çözebilmek için vücut ağırlıklarının ortalama değeri alınarak kayıp veriler ile değiştirilmiştir. Çalışmanın üçüncü aşamasında ise ResNet34 modelinde görüntü verilerini eğitebilmek için tüm yüz görüntüleri eşit boyutlara getirilmiştir. Bir sonraki aşamada ise verilerin ResNet34 modelinde eğitim süresini ve hesaplama gücünü azaltarak modelin performansını arttırmak için veriler 0-1 arasına normalize edilmiştir. Çalışmanın beşinci aşamasında ise eğitime hazırlanan yüz görüntüsü ve bu görüntülere ait vücut ağırlık değerleri rastgele olarak %80 eğitim ve %20 test olmak üzere iki bölüme ayrılmıştır. Eğitim veri seti ResNet34 mimarisi ile eğitilerek öğrenme oranı belirlenerek model üzerinde öğrenme oranı için optimizasyon işlemi gerçekleştirilmiştir. Çalışmanın son aşamasında ise ResNet34 modeli ile eğitilen verilerin test verileri kullanılarak modelin tahminleme doğruluğu belirlenmiştir.



Şekil 5. İş Akış Diyagramı.

## 3. ARAŞTIRMA BULGULARI


Çalışmada ilk olarak ResNet34 mimarisi kullanılarak eğitilen modelin öğrenme oranı belirlenerek şekil 6’de verilmiştir.



Şekil 6. Çalışmada kullanılan modelin öğrenme oranı grafiği.

Şekil 6 incelendiğinde ResNet34 modelinin öğrenme oranını değiştikçe kayıp oranının da değiştiği görülmektedir. Çalışmada kullanılan model için en iyi öğrenme oranını belirleyebilmek için en iyi olan değer en yüksek sabit öğrenme oranına yakın olan değerdir. Ayrıca öğrenme hızı doğrusal yada üstel olarak eğitim boyunca kullanılır. Yerel hata yüzeyinin daha hassas bir şekilde kullanılması uygun öğrenme oranı belirlemede oldukça önemlidir. Bu nedenle şekil 6'de görüldüğü gibi kırmızı işaret ile gösterilen 0.00209 değeri öğrenme oranı olarak belirlenmiştir.

Şekil 7'de çalışmada kullanılan ResNet34 modelinin eğitim ve doğrulama kayıplarına ait grafik verilmiştir. Grafik incelendiğinde eğitim boyunca eğitim ve doğrulama kayıplarının sürekli olarak düştüğü görülmektedir. Mimarinin son tekrarlamada(epoch) eğitim kayıp oranı değeri 0.002624, doğrulama kayıp oranı değeri ise 0.002601'a ulaştığı görülmektedir. Mevcut veri seti için uygulanan Resnet34 modelinin başarılı bir sonuç verdiği görülmüştür.



Şekil 7. ResNet34 modeli için eğitim-doğrulama kayıp grafiği.

Çalışmada kullanılan ResNet34 mimarisinin kayıp oranı değeri tablo 1'de verilmiştir.

Tablo 1. ResNet34 model sonuçları.

ResNet34	Eğitim kaybı	Doğrulama kaybı	RMSE hata değeri
	0.002624	0.002601	0.071797

Tablo 1 incelendiğinde oluşturulan ResNet34 modelinin RMSE hata değerinin (0.071797) sıfıra yakın olması modelin kullanılan veri seti için başarılı bir model olduğunu göstermektedir.

Çalışmada kullanılan ResNet34 modeli için örnek yüz görüntülerine ait ağırlık tahminleri şekil 8’de verilmiştir.



Şekil 8. ResNet34 modelinden elde edilen örnek sonuçlar.

Şekil 8’de görüldüğü gibi yüz görüntüleri üzerinde modelin vücut ağırlığı tahmininde oldukça başarılı olduğu görülmektedir.

#### 4. SONUÇLAR

Çağımızda bilgi ve iletişim teknolojilerinin hızla gelişmesi ile birlikte yapay zeka yöntemleri de sıklıkla kullanılmaya başlanmıştır. Özellikle yapay zeka yöntemleri kullanılarak görüntüler üzerinden kimlik tespiti, biyometrik analizler gibi birçok uygulama gerçekleştirilmektedir. Yapay zeka yöntemleri, görüntüler üzerinden tıp, tarım ve hayvancılık gibi alanlarda çeşitli çıkarımlar elde etmek için kullanılmaktadır. Bu çıkarımlardan birisi de yüz görüntüleri üzerinden vücut ağırlığının tahmin edilmesidir. Çalışmada açık erişimli internet sitesinden alınan yüz ve vücut ağırlığı veri seti için kişinin yüz görüntüsünden vücut ağırlığı ResNet34 derin öğrenme mimarisi kullanılarak tahminlenmiştir. ResNet34 modeli RMSE performans değerlendirme ölçütüne göre değerlendirilerek 0.071797 hata değeri elde edilmiştir. Elde edilen bu hata değeri oluşturulan ResNet34 mimarisinin çalışmadaki veri seti ile uyumlu olduğunu göstermektedir.

İlerdeki akademik çalışmalarda farklı yapay zeka modelleri kullanılarak model başarısının artırılması düşünülmektedir.

#### Teşekkür

Çalışmada kullanılan veri setini erişime açan <https://academictorrents.com> açık erişimli internet sitesine ve verisetini sisteme dahil eden “İllinois DOC”a teşekkür ederiz.

#### KAYNAKLAR

- [1] J. Zhang, Y. Xia, Y. Xie, M. Fulham, and D. Feng, “Classification of Medical Images in the Biomedical Literature by Jointly Using Deep and Handcrafted Visual Features,” IEEE J. Biomed. Heal. Informatics, vol. 2194, no. 2, pp. 1–10, 2017.
- [2] Süzen, A. A., & Cakiroglu, M. A. (2019). Prediction of rebound in shotcrete using deep bi-directional LSTM. Computers and Concrete, 24(6), 555-560.
- [3] S. Koitka and C. M. Friedrich, “Traditional feature engineering and deep learning ap [3] Kaya U., Yılmaz A. (2019). Derin Öğrenme, 1-2, ISBN:978-605-2118-399
- [4] Rosenblatt, F. (1957). The perceptron, a perceiving and recognizing automaton Project Para. Cornell Aeronautical Laboratory.
- [5] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.
- [6] Kaya U., Yılmaz A. (2019). Derin Öğrenme, 1-2, ISBN:978-605-2118-399
- [7] Çağlayan, A. (2018). Derin Öğrenme Tekniklerini Kullanarak RGB-D Nesne Tanıma. Hacettepe Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı Doktora Tezi

- [8] Elmas Ç. 2011. Yapay Zekâ Uygulamaları, Seçkin Yayıncılık, 4.Basım.
- [9] Wang, M., & Deng, W. (2018). Deep Face Recognition: A Survey. arXiv, arXiv-1804.
- [10] Çetinkaya H. H., ve Akçay M. 2012. Yüz Tanıma Sistemleri ve Uygulama Alanları, XIV. Akademik Bilişim Konferansı Bildirileri, Uşak Üniversitesi.
- [11] Aburomman, A. A., & Reaz, M. B. I., 2016. Ensemble of binary SVM classifiers based on PCA and LDA feature extraction for intrusion detection. In 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 636-640, IEEE. DOI: 10.1109/IMCEC.2016.7867287
- [12] Hamdan, B., & Mokhtar, K. (2018). Face recognition using angular radial transform. Journal of King Saud University-Computer and Information Sciences, 30(2), 141-151.
- [13] A. K. Jain, S. C. Dass, and K. Nandakumar, "Soft biometric traits for personal recognition systems," in Proc. of ICBA, 2004.
- [14] A. Dantcheva, P. Elia, and A. Ross, "What else does your biometric data reveal? a survey on soft biometrics," IEEE Transactions on Information Forensics and Security, pp. 1–26, 2015.
- [15] M. S. Nixon, P. L. Correia, K. Nasrollahi, T. B. Moeslund, A. Hadid, and M. Tistarelli, "On soft biometrics," Pattern Recognition Letters, vol. 68, pp. 218–230, 2015.
- [16] A. Dantcheva and F. Bremond, "Gender estimation based on smiledynamics," IEEE Transactions on Information Forensics and Security (TIFS), 2016.
- [17] C. Chen, A. Dantcheva, and A. Ross, "Impact of facial cosmetics on automatic gender and age estimation algorithms," in Proceedings of IEEE International Conference on Computer Vision Theory and Applications (VISAPP), vol. 2, 2014, pp. 182–190
- [18] Yüz ve vücut ağırlığı veriseti, (2020), <https://academictorrents.com>, Erişim Tarihi: 28.06.2020
- [19] He K. Zhang X. Ren S. & Sun J. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 770–778. 2016.
- [20] Almyrad, A. S. S. (2020). Identification Of Butterfly Species Using Machine Learning And Image Processing Techniques (Doctoral Dissertation).
- [21] He, K., Zhang, X., Ren, S., Sun, J. (2015). Deep residual learning for image recognition. CoRR, abs/1512.03385.
- [22] Figurnov, M., Collins, M. D., Zhu, Y., Zhang, L., Huang, J., Vetrov, D., & Salakhutdinov, R. (2017). Spatially adaptive computation time for residual networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 1039-1048).
- [23] Jian, L., Li, Z., Yang, X., Wu, W., Ahmad, A., & Jeon, G. (2019). Combining unmanned aerial vehicles with artificial-intelligence technology for traffic-congestion recognition: Electronic eyes in the skies to spot clogged roads. IEEE Consumer Electronics Magazine, 8(3), 81-86.
- [24] Targ, S., Almeida, D., & Lyman, K. (2016). Resnet in resnet: Generalizing residual architectures. arXiv preprint arXiv:1603.08029.
- [25] Çınaroğlu, S. (2017). Sağlık harcamasının tahmininde makine öğrenmesi regresyon yöntemlerinin karşılaştırılması. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 22(2), 179-200.