

## GAN ile İnsan Yüzlerinde Değişiklik Yapma

Emre Kardal<sup>1\*</sup>, Vasıf Nabiye<sup>2</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü/ Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği Bölümü/ Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Türkiye  
(\*emrekrdl314@gmail.com) Başlıca yazarın mail adresi

**Özet** – GAN bilindiği üzere gün geçtikçe yapay görüntü üretiminde oldukça başarılı bir hale gelmiştir. Fakat birçok GAN modelinde görüntüler tamamen rastgele ya da belli kurallara bağlı olarak kısmi rastgele görüntüler oluşturmak üzerinedir. Bu çalışmada insan yüzünde belirlenen bazı kurallara bağlı değişikliklerin GAN ile yapılması üzerinde durulmuştur. Önerilen model yardımıyla verilen insan yüzünün fotoğrafı bay/bayan olarak değiştirilmesi sağlanmıştır. Aynı model sadece koşul verisi değiştirilerek ve yeniden eğitilerek farklı koşulları da öğrendiği gözlemlenmiştir. Oluşturulan görüntü tekrar terslenerek ilk girişteki verinin üretilmesinde ortalama %90 oranında bir başarı elde edilmiştir.

**Anahtar Kelimeler** – Yapay Sinir Ağı, Üretken Çekişmeli Ağlar, Yapay Zekâ, Makine Öğrenmesi, Bilgisayar Bilimi

### I. GİRİŞ

Günümüzde özellikle eğlence sektöründe genellikle yapay zekâ uygulamaları ya da teknolojileri kullanılmaktadır [1]. Film sektöründe ya da herhangi medya sektöründe çözünürlüğün artırılması gibi problemlerde, eski görüntülerin yenilenerek daha yüksek çözünürlükte tekrar sunulması gibi alanlarda bir Çekişmeli Üretici Ağlar (Generative Adversarial Networks)- GAN modeli olan SRGAN [2] kullanılabilir. Ayrıca NVIDIA tarafından geliştirilen DSS [3], [4] eğlence sektörlerinden biri olan oyun sektöründe görüntünün çözünürlüğünün düşürülerek ekran kartına düşen işlem yükünü azaltmak, fakat bunu yaparken görüntüyü hala eskisi gibi net bir şekilde yüksek çözünürlükte sunabilmek, için bu tarz bir yapay zekâ teknolojisi geliştirmiştir. Diğer yandan güvenlik açısından bir tehdit olarak görülen sahte videoların oluşturulmasında da benzeri uygulamaların kullanıldığı görülmektedir [5]. Sahtecilik tarzı uygulamalara karşı tespit de yine yapay zekâ yöntemleri ile yapılmaktadır [5]. Bunların yanı sıra var olmayan bir kişinin fotoğrafının oluşturulması, görüntüde belli özelliklerin değiştirilerek farklı görüntülerin üretilmesi gibi durumlarda GAN modelleri devreye girmektedir.

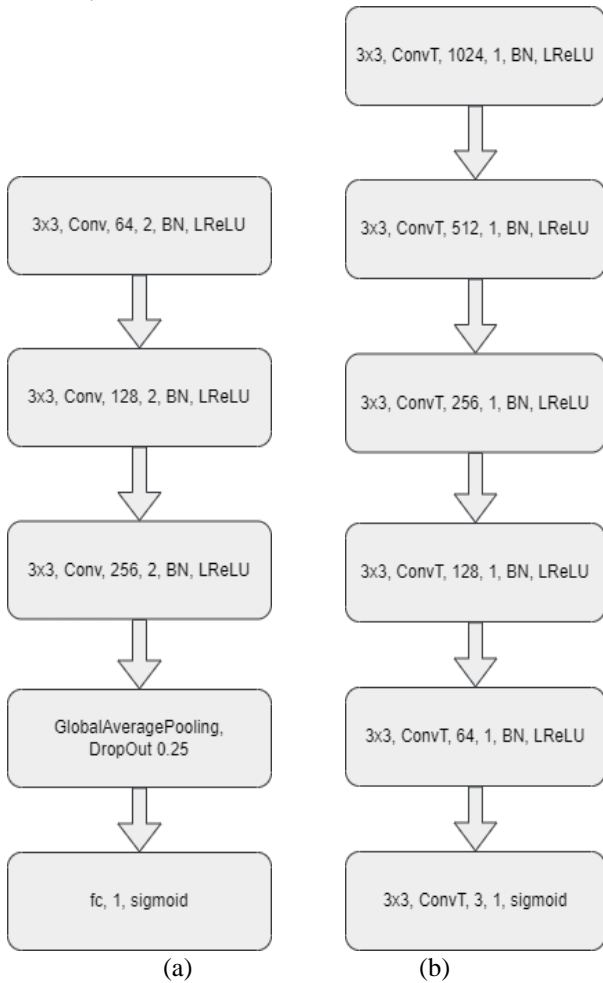
GAN yarı denetimli ve denetimsiz öğrenme yöntemi olarak 2014 yılında Ian Goodfellow tarafından önerilmiştir [6]. GAN modeli birbirine rakip iki ağdan oluşmaktadır. Ayırt Edici ağ sonucu en üste çıkartmak için yani hem Üretici ağdan gelen hem de gerçek görüntüleri doğru bilmesi sağlanırken, Üretici ise Ayırt Edicinin ürettiği görüntüleri yanlış bilmesini sağlamaya çalışmaktadır [6]. Bu anlamda yöntemin temelinde gömülü olan minimax oyununun denklemi aşağıdaki gibidir [6]:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_{data}(z)} [\log (1 - D(G(z)))] \quad (1)$$

GAN bu iki ağın birbirlerini eğitmesi ile çalışmaktadır. Üretici ağ bir görüntü oluşturur. Ayırt Edici ağ ise karıştırılarak verilen gerçek ve üretici tarafından üretilen sahte görüntüleri alır ve değerlendirir. Değerlendirme sonucunda hangisinin gerçek görüntü hangisinin sahte görüntü olduğunu anlamaya çalışır. Ayırt Edicinin hata oranı gerçek görüntülere ne kadar sahte dediği ve sahte görüntülere ne kadar gerçek dediği ile hesaplanır. Üretici de ise Ayırt Edici tarafından ürettiği görüntülerin ne oranda sahte olarak anlaşıldığı, Üreticinin hata oranıdır.

## II. MATERYAL VE YÖNTEM

Bu çalışma insan yüzlerinde belirlenen kurallara göre kadın/erkek gibi modifikasyonların yapılması üzerinedir. Bunun için CelebA [7] veri setinden bu türlere göre rasgele seçilen 10.000 fotoğraf ile eğitim gerçekleştirilmiştir. Aynı ağ farklı iki tür içinde eğitilmiştir. İlk tür amaç olan kadın/erkek olarak yüz görüntülerini değiştirmek içindir. Bunun için 5000 erkek, 5000 kadın fotoğrafı bu veri setinden rasgele seçilmiştir. Sakal ekleme türü için ise 5000 sakallı, 5000 sakalsız olmak üzere 10.000 fotoğraf seçilmiştir. Eğitim için Python Tensorflow Keras'dan yararlanılmıştır. Ön işlem olarak seçilen rasgele fotoğraflar 64x64'e sıkıştırılmıştır. Eğitim sırasında ayrıca rastgele düşük Gauss gürültüleri ayırt edici ağına girişindeki görüntüye eklenmiştir. Bu gürültüler, az örnekler ile eğitim yaparken veri çeşitliğinin artırılması ve Üretici-Ayırt Edici dengesinin sağlanması içindir. Oluşturulan yeni GAN modelinin Ayırt Edici ağ yapısı Şekil 1 a'daki gibidir. Üretici ağ yapısı ise Şekil 1 b'deki şekildedir.



Şekil 1. Üretici (a) ve Ayırt Edici ağ (b)

Conv ve ConvT katmanlarında piksel ekleme (padding) işlemi yapılmıştır. Adım sayısı Ayırt Edici ağda 2, Üretici ağda ise 1'dir. Ayrıca bu katmanlarda normalizasyon işlemi uygulanmıştır.

Üretici ve Ayırt Edici ağlarda hata oranlarının hesabı için eğitimde ikili çapraz entropi (BCE) kayıp fonksiyonu kullanılmıştır. Ayrıca Üretici tarafından değiştirilen görüntünün tekrar eski haline getirilmesini sağlamak için Üretici ağa hata fonksiyonu olarak ortalama mutlak hata (MAE) fonksiyonu da eklenmiştir. Yani üretici 2 hata sonucunun toplamına göre kendini eğitmektedir.

## III. BULGULAR

Yapılan deneylerde Üretici ağın daha karmaşık bir yapıya sahip olması gerektiği tespit edilmiştir. Ayırt Edici ağ daha kolay bir şekilde sahte ve gerçek görüntüleri ayırt ettiğinde Üretici ağ için yeterli düzenleme bilgisini vermemektedir [6]. Bu yüzden Ayırt Edici ağ ile Üretici ağın denge durumunda olması için Ayırt Edici zayıflatılmalı, Üretici ise daha karmaşık bir yapıya sahip olmalıdır.

## IV. TARTIŞMA


Çalışmamıza benzer sonuçlar üreten CNN modeller olmakla birlikte ticari olduklarından bu modellerin yapısı açık olarak verilmemiştir. Ayrıca bu tarz modellerin kendi özel veri setleri olduğundan ve bunlar da ticari olarak saklandığından oluşturulan model ile doğrudan karşılaştırma yapılamamıştır. Fakat ağın çalışmasının doğruluğu oluşturulan model görüntüsünün tekrar eski haline getirebilirliğinin testi ile gerçekleştirilmiştir. Bu test sonucunda MAE hata fonksiyonu ile arka planı silinmiş fotoğraflarda Yapısal benzerlik indeksi ölçüsü (SSIM) kullanılarak %90 oranında ortalama bir başarı elde edilmiştir. Yapısal benzerlik indeksi ölçüsü (2) denklemi ile verilmektedir [8]:

$$SSIM(x, y) = \left( \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \left( \frac{2\sigma_{xy} + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \quad (2)$$


Ayrıca Eğitim sayısı yetersiz olduğundan Kadın/Erkek olarak değişme ve sakallı sakalsız olarak değiştirme oranında tam olarak başarılı elde edilememiştir. Eğitim döngüsü ilerledikçe model daha başarılı sonuçlar ürettiği gözlemlenmiştir.

## V. SONUÇLAR

Bu çalışmada GAN ile insan yüzünde değişikliklerin yapılması üzerinde durulmuştur. Önerilen modellerle verilen insan yüzü fotoğrafı üzerinde bay/bayan dönüştürülmesi sağlanmıştır. Aynı modelin koşul verisi değiştirilerek ve yeniden eğitilerek ağı farklı durumları da öğrendiği gözlemlenmiştir. Oluşturulan görüntü tekrar terslenerek ilk girişteki verinin üretilmesinde ise ortalama %90 oranında bir başarı elde edilmiştir. Deneysel bazı sonuçlar Şekil 2- 4'te verilmiştir.



Şekil 2. Erkek/Kadın olarak değiştirme sonucu



Şekil 3. Bir önceki değiştirilen sonucun geri dönüştürülmesi orijinal girişle arasındaki fark



Şekil 4. Sakal ekleme sonucu

## TEŞEKKÜR

Bu araştırmada yer alan tüm/kısmi nümerik hesaplamalar TÜBİTAK ULAKBİM, Yüksek Başarım ve Grid Hesaplama Merkezi'nde (TRUBA kaynaklarında) gerçekleştirilmiştir.

## KAYNAKLAR

- [1] <https://www.forbes.com/sites/danpontefract/2023/04/24/can-artificial-intelligence-help-the-film-industry-it-already-is>
- [2] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the*

*IEEE conference on computer vision and pattern recognition* (pp. 4681-4690).

- [3] Watson, A. (2020). Deep learning techniques for super-resolution in video games. *arXiv preprint arXiv:2012.09810*
- [4] <https://www.nvidia.com/en-us/geforce/news/dlss3-ai-powered-neural-graphics-innovations/>
- [5] Masood, M., Nawaz, M., Malik, K. M., Javed, A., Irtaza, A., & Malik, H. (2023). Deepfakes Generation and Detection: State-of-the-art, open challenges, countermeasures, and way forward. *Applied Intelligence*, 53(4), 3974-4026.
- [6] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, 'Generative adversarial nets', in *Advances in neural information processing systems*, pp. 2672-2680, 2014.
- [7] Liu, Ziwei and Luo, Ping and Wang, Xiaogang and Tang, Xiaoou (2015). *Proceedings of International Conference on Computer Vision (ICCV)*. Deep Learning Face Attributes in the Wild
- [8] Otero, D., La Torre, D., Michailovich, O., & Vrscay, E. R. (2021). Optimization of structural similarity in mathematical imaging. *Optimization and Engineering*, 22, 2367-2401.