



EEG sinyallerinden bakılan görselin üretilmesi Generating the image viewed from EEG signals

Gaffari ÇELİK^{1*} , Muhammed Fatih TALU² 

¹Bilgisayar Teknolojileri Bölümü, Meslek Yüksekokulu, Ağrı İbrahim Çeçen Üniversitesi, Ağrı, Türkiye.
gcelik@agri.edu.tr

²Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, İnönü Üniversitesi, Malatya, Türkiye.
fatih.talu@inonu.edu.tr

Geliş Tarihi/Received: 29.12.2019
Kabul Tarihi/Accepted: 05.05.2020

Düzeltilme Tarihi/Revision: 05.05.2020

doi: 10.5505/pajes.2020.76399
Araştırma Makalesi/Research Article

Öz

EEG sinyalleri kullanılarak engelliler için kontrol edilebilir tekerlekli sandalyelerin üretildiği veya yapılması düşünülen aktivitenin tahmin edildiği çalışmalara literatürde sıklıkla rastlanmaktadır. Genel olarak bu çalışmalarda elektroensefalografi (EEG) sinyalinin önceden belirlenen sınıflara aktarımı gerçekleştirilir. Bu çalışmalar EEG sinyalinin sınıflandırmasından ibarettir. Ancak son yıllarda yapay öğrenme alanında yaşanan gelişmelerle sınıflandırmadan öteye gidildiği, EEG sinyalinden bakılan görselin üretilebildiği görülmektedir. Klasik çekişmeli üretici ağlar (Generative adversarial networks-GAN) ve otomatik kodlayıcı (Auto encoder-AE) yaklaşımlarının kullanıldığı sınırlı sayıda bu çalışmalar incelendiğinde, EEG sinyallerinden kabaca görsellerin üretilebildiği görülmektedir. Bu çalışmanın özgün yönü, görsel üretim kabiliyetini arttıracak matematiksel yaklaşımlar içermesidir. Klasik GAN mimarileri üretilen görüntülerin çeşitliliğini sağlayabilmek için rastgele vektör girişini kullanırlar. Bu yaklaşım ile EEG sinyalinden üretilen görsellerin düşük kalitede olduğu gözlemlenmiştir. Önerilen yöntemde giriş iki kısım (kodlanmış EEG ve rastgelelik) olarak düşünülmüştür. EEG'nin kodlanması için değişken oto kodlayıcı (Variational auto encoder-VAE) ve fourier dönüşümü (FD) kullanılırken, rastgelelik için iki farklı yaklaşım önerilmiştir. Bu özgün GAN kullanımı, EEG sinyallerinden daha kaliteli görsel üretilmesini sağlamıştır. Bu kalitenin sayısal olarak anlaşılabilmesi için önceden eğitilmiş evrimsel sinir ağları (ESA) kullanılmıştır. Yapılan deneysel çalışmalar neticesinde, klasik GAN ile EEG'den üretilen görsellerin başarımlarının %93 civarındayken, önerilen yaklaşımda bu seviyenin %95-%100 aralığına çıktığı görülmektedir.

Anahtar kelimeler: EEG sinyalleri, Çekişmeli üretici ağlar, Yardımcı sınıflandırıcı GAN (ACGAN), Otomatik kodlayıcı, Fourier dönüşümü, Değişken oto kodlayıcı.

Abstract

In the literature, it is encountered a vast amount of studies related to the production of controllable wheelchairs for people with disabilities or the prediction of activity thought to be performed. In general, the electroencephalography (EEG) signal is transferred to predetermined classes in these studies. These studies consist of the classification of the EEG signal. However, it has been observed that in the recent years, with the developments in the field of artificial learning, the classification has gone beyond. It can be seen that the visual viewed from the EEG signal can be produced. When the limited number of studies using classical generative adversarial networks (GAN) and auto encoder (AE) approaches are examined, it is seen that visuals from EEG signals can be produced roughly. The original aspect of this study is that it includes mathematical approaches to increase the visual production capability. Classical GAN architectures use random vector input to provide a variety of images produced. With this approach, it is observed that the visuals produced from the EEG signal are of low quality. In the proposed method, the input is considered as two parts (coded EEG and randomness). Variable auto encoder (VAE) and fourier transform (FT) are used to encode the EEG, while two different approaches are proposed for randomness. The use of this original GAN has enabled higher quality visuals to be produced than EEG signals. In order to understand this quality numerically, pre-trained convolutional neural networks (CNN) was used. As a result of experimental studies, While the performance level of the visuals produced from EEG signals with classical GAN is around 93%, it is seen that this level rises to 95% -100% in the proposed approach.

Keywords: EEG signals, Generative adversarial networks, Auxiliary classifier GAN (ACGAN), Auto encoder, Fourier transform, Variational auto encoder (VAE).

1 Giriş

İnsanların elektronik cihazlarla iletişim kurmasını sağlayan Beyin/Bilgisayar Arayüzleri (BCI)'nin en temel çalışma alanlarından biri EEG verilerinin anlaşılması olmuştur. BCI'lar, engellilerden alınan bir EEG sinyalinin sınıflandırılması ve makinelerin kumanda edilmesini amaçlamaktadır [1]. BCI, insan beyni ve harici cihazlar arasında alternatif bir iletişim şekli sağlamaktadır [2]-[4]. EEG, beyin aktivitesini kaydetmek için kolay ve ucuz bir tekniktir. EEG sinyali, kafatasının çeşitli yerlerinde saniyede yüzlerce kez elektrik potansiyelinin ölçülmesiyle elde edilir. Sinyaller, belirli kafa derisi bölgelerine yerleştirilmiş çoklu elektrotlar kullanılarak kaydedilir.

EEG sinyalleri, bilgisayarlı tomografi (computed tomography-CT) veya manyetik rezonans görüntüleme (magnetic resonance

imaging-MRI) gibi en yeni görüntüleme teknikleriyle hala mümkün olmayan, milisaniye aralığında bir çözünürlüğe sahiptir. Beyin fonksiyonlarının veya bozukluklarının daha iyi anlaşılabilmesini sağlayan bu özellik EEG sinyalini oldukça önemli hale getirmiştir [5].

EEG sinyallerinin yapay öğrenme teknikleriyle sınıflandırmasını içeren birçok bilimsel çalışma yapılmıştır [1],[5]-[7]. Son yıllarda sınıflandırma faaliyetlerinin ötesinde çalışmaların olduğu bilinmektedir. EEG-GAN olarak adlandırılan yeni öğrenme mimarileri yardımıyla EEG sinyallerinden bakılan görselin üretilebildiği görülmektedir [8].

GAN, AE ve ESA gibi güncel yapay öğrenme tekniklerinin birlikte kullanıldığı bu mimarilerle basit görsellere

* Yazışılan yazar/Corresponding author

bakıldığında üretimin yapılabildiği, ancak karmaşık görsellerde üretim kalitesinin oldukça düştüğü görülmektedir.

EEG sinyallerinin sınıflandırılması [9], EEG sinyallerinden yeni EEG sinyalleri üretme [10],[11] ve EEG/EOG sinyallerinden sürücünün uyku hali tespiti [12] gibi çalışmalar EEG-GAN'lar yapılan diğer çalışmalardır. EEG-GAN'lar, sadece veri artırma ile sınırlı kalmamakla birlikte, bozuk sinyallerin onarımı gibi yeni uygulama alanları yaratmaktadır [13]. Belli bir sınıftan ve/veya belirli özelliklere sahip sinyaller üretme olasılığı, beyin sinyallerinin altında yatan yapının araştırılması için yeni bir yol açılabilir [14]. Üzerinde çalışmaların hızla devam ettiği bu mimariler birçok farklı uygulama sahasında kullanılabileceği gibi ilk akla gelenlerden biri adli vakaların çözümüne ışık tutabilme potansiyeline sahip olmasıdır. Ayrıca tıbbi olarak kalp durduktan yaklaşık altı dakika sonraya kadar beyin aktivitelerinin devam etmesi [15], sadece canlılar üzerinde değil, yeni ölmüş kişiler üzerinde de görselleştirme faaliyetlerinin yapılabileceğini göstermektedir.

Çekişmeli üretken ağlar (GAN), derin öğrenme alanındaki en ilgi çekici buluşlarından biri olarak görülmektedir [16]. Goodfellow [17] tarafından önerilen GAN'lar görüntü üretiminde büyük başarılar sergilemiştir. GAN, bir üretici (generator, G) ve bir ayırıcı (discriminator, D) olmak üzere iki farklı derin ağdan oluşur. Bu iki ağın çekişmeli olarak çalışmasıyla öğrenme işlemi gerçekleşir. Ayırıcı, üretici tarafından üretilen sahte görüntüleri gerçeklerden ayırtmaya çalışırken; Üretici, giriş olarak aldığı bir görüntü sinyalinin gerçek görüntülere benzer görüntüleri üretmeyi amaçlar. G , aynı zamanda ürettiği görüntüler gerçekmiş gibi ayırıcıyı kandırmaya çalışır. Her iki ağ da paralel olarak rekabetçi bir şekilde eğitilir. Bu işlemler belli bir tekrar aşamasından sonra üretici ağ gerçek görüntülere benzer yeni görüntüler üretir [17]. GAN mimarileri, doku transferi [18]-[21], çözünürlük artırma [22], görüntü desen aktarımı [23], görüntü giderme ve kesik parçaları doldurma [24], yüz yaşlandırma/gençleştirme [25] gibi çeşitli çalışmalar yapılmıştır. Son yıllarda metinden görüntü üretimi [26], sestten görüntü üretimi [27] ve EEG sinyallerinden görüntü üretimi [8] yapılan diğer çalışmalardır.

Bu çalışmada EEG-GAN mimarisinin geliştirilmesi ve üretilen görüntü kalitesinin artırılmasına odaklanılmıştır. İkinci bölümde referans olarak alınan Yardımcı Sınıflandırıcı Çekişmeli Üretici Ağ (ACGAN) mimarisinden bahsedilmektedir. Üçüncü bölümde önerilen kodlama yaklaşımları sunulmuştur. Dördüncü bölümde genel olarak önerilen mimariden bahsedilmektedir. Beşinci bölümde kullanılan veri kümesi anlatılmıştır. Altıncı bölümde yapılan deneysel faaliyetler ve elde edilen sonuçlar paylaşılmaktadır. Son bölümde makalenin sonucu verilmektedir.

2 ACGAN mimarisi

Literatürde ACGAN olarak bilinen Yardımcı Sınıflandırıcı Çekişmeli Üretici Ağ'ın detaylı iç mimarisi Şekil 1'de verilmektedir. Bu mimari bir üretici (G) ve bir ayırıcıdan (D) oluşmaktadır. Üretici girişinde görüntü vektörüne (z) ek olarak sınıf bilgisini (c) alır ve sahte görüntüyü $X_{sahte} = G(z, c)$ üretir.

Ayırıcı ağ, giriş olarak gerçek ve sahte görüntüleri alır. Çıkış olarak bu görüntüler için [0-1] aralığında bir olasılık değeri üretir. Üretilen olasılık değeri sahte(0)/gerçek(1) aralığında yer alır. Böylece girdinin sahte-gerçek ayırımını yapabileme kabiliyetini arttırmaya çalışır. Ayrıca girdinin sınıf bilgisini de

tahmin etmeyi amaçlar. Bu iki tahmini kullanarak bir maliyet değerini hesaplar.

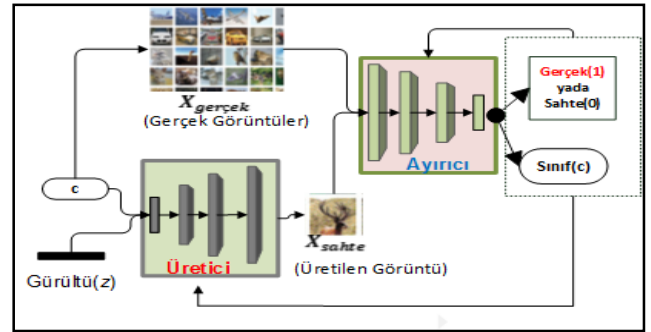
Ayırıcı ağ, bu maliyet değerini geriye yayılım algoritması içerisinde kullanarak ağırlıklarını günceller. Ayrıca ayırıcı ağın çıktısındaki hata değeri, üretici ağın eğitiminde kullanılır. Ayırıcı ağın yüksek hata değerleri üretmesi için üretilen sahte görüntüler gerçekmiş gibi ayırıcıya verilir. Bu hata değeri üreticiye yansıtılır ve gerçek görüntülere benzer görüntüler üretmeye zorlanır. ACGAN'nın maliyet fonksiyonu L_S ve L_C olmak üzere iki kısımdan oluşur:

$$L_S = E[\log P(S = \text{gerçek} | X_{\text{gerçek}})] + E[\log P(S = \text{sahte} | X_{\text{sahte}})] \quad (1)$$

$$L_C = E[\log P(C = c | X_{\text{gerçek}})] + E[\log P(C = c | X_{\text{sahte}})] \quad (2)$$

$X_{\text{gerçek}}$, veri kümesindeki gerçek görüntüleri, X_{sahte} üretici tarafından üretilen sahte görüntüleri ifade eder. c giriş görüntüsünün sınıf bilgisini gösterir. L_S , giriş görüntüsünün gerçek mi yoksa sahte mi olduğu hakkındaki maliyeti ifade eder. L_C , giriş görüntüsünün ilgili sınıfa ait olma maliyetini ifade eder.

Ayırıcı ağ, $L_S + L_C$ 'yi maksimum yapmaya çalışırken, üretici ağ $L_C - L_S$ 'yi maksimum yapmaya çalışır ve bunun için eğitim süreci boyunca ağlardaki ağırlıklar süreli güncellenir [28].



Şekil 1. ACGAN mimarisi.
Figure 1. ACGAN architecture.

3 Kodlama teknikleri

Kodlama işlemiyle, tek boyutlu ve yüksek çözünürlükteki EEG sinyalleri temel karakteristiğini kaybetmeden daha düşük boyuta taşınmaktadır [29]. Orijinal veri boyutunun azaltılması ve daha düşük boyutlu temel yapının keşfedilmesi, hesaplama karmaşıklığını azaltır ve öğrenme performansını olumlu yönde etkiler. Bilindiği gibi sınıflandırıcının performansı, özneliliklerin kalitesine büyük ölçüde bağlıdır [30]. Kodlama işlemi, sınıflandırma, regresyon, bilgi görselleştirme gibi birçok farklı alanda sıklıkla kullanılmaktadır [31]. Bu çalışmada üç farklı kodlama tekniğinin (AE, VAE ve FD) görsel üretme üzerindeki performansları incelenmiştir. Bu bölümde her bir yaklaşımdan detaylıca bahsedilmektedir.

3.1 Otomatik kodlayıcılar (Auto encoder-AE)

Eğitimsiz bir öğrenme tekniği olan AE, kodlayıcı (encoder) ve çözücü (decoder) ağlardan oluşur. Giriş verisi x 'i önce kodlayıcı daha sonra çözücü ağdan geçirerek girişe benzer yeni bir çıkış z elde etmeye çalışır. Kodlayıcı, m boyutlu giriş vektörü x 'i, m' boyutlu kodlanmış vektöre h 'a dönüştürür. Çözücü ise giriş vektörü x ile çıkış vektörü z arasındaki farkı minimize etmeye çalışır. Yeniden yapılanma kaybı yeterince küçük olduğunda;

kodlanmış h vektörünün giriş vektörünü en iyi temsil ettiği düşünülür [31],[32].

Kodlayıcı modül aşağıdaki gibi ifade edilebilir:

$$h = f_{kodlayıcı}(W_e x + b_e) \quad (3)$$

W_e , $m' \times m$ boyutunda ağırlık matrisi, x giriş verisi, b_e , m' boyutunda bias vektörü, $f_{kodlayıcı}$ aktivasyon fonksiyonunu (*sigmoid, tanh* v.b) ifade etmektedir.

Çözücü modül aşağıdaki gibi ifade edilebilir:

$$z = f_{çözücü}(W_d h + b_d) \quad (4)$$

W_d , $m \times m'$ boyutunda ağırlık matrisi, h , x giriş verisinin kodlanmış bilgisi, b_d , m boyutunda bias vektörü, $f_{çözücü}$ ise aktivasyon fonksiyonunu ifade etmektedir. AE'nin amaç fonksiyonu (J), giriş ve çıkış arasındaki maliyetin minimizasyonuna dayanır [33].

$$J(z, x) = \min \frac{1}{N} \sum_{i=1}^N \|z_i - x_i\| \quad (5)$$

3.2 Değişken oto kodlayıcı (Variational auto encoder-VAE)

VAE [33], giriş görüntülerinin yeniden üretilmesinde etkileyici bir performans sergilemiştir. AE benzeri bir yapıya sahip olmasına rağmen, çok daha büyük bir amaca hizmet etmektedir. AE'den farkı, gizli katman nöronlarında normal dağılım parametrelerini saklamasıdır. Böylece giriş görüntüleri yönden bağımsız (izotropik) normal dağılımlarla ifade edilmektedir [34]. Veri karmaşıklığı arttıkça normal dağılımla modellemenin yetersiz kalacağı görülmektedir. Maliyet fonksiyonu, dağılımın girdiye oturma hatasını (\mathcal{L}_{MSE}) ve düzgünleştirme hatasını ($\mathcal{L}_{KLD}(\mu, \sigma)$) içerir [35].

$$\mathcal{L}_{VAE} = \mathcal{L}_{MSE}(x, G_\theta(z)) + \lambda \mathcal{L}_{KLD}(\mu, \sigma) \quad (6)$$

$$\mathcal{L}_{MSE}(x, G_\theta(z)) = \|x - G_\theta(z)\|^2 \quad (7)$$

$$\mathcal{L}_{KLD}(\mu, \sigma) = \frac{1}{2} (1 + \log(\sigma^2) - \mu^2 - \sigma^2) \quad (8)$$

Burada, \mathcal{L}_{MSE} girişler (x) ve bunların yeniden yapılanmaları ($G_\theta(z)$) arasındaki ortalama karesel hatayı göstermektedir. μ, σ sırasıyla giriş (x) verisinin ortalama ve standart sapma değerini ifade etmektedir.

3.3 Fourier dönüşümü (FD)

Zaman gösterimli bir sinyalin frekans uzayına taşınması FD ile sağlanır. Oldukça yaygın bir kullanımı olan FD, sinyali harmonikler toplamı şeklinde ifade eder. Kayıpsız gerçekleştirilen bu dönüşüm tersine alınabilir [36],[37]. Özellikle tek boyutlu sinyal analiz uygulamalarının en temel dönüşümlerinden biridir ve aşağıdaki gibi ifade edilebilir.

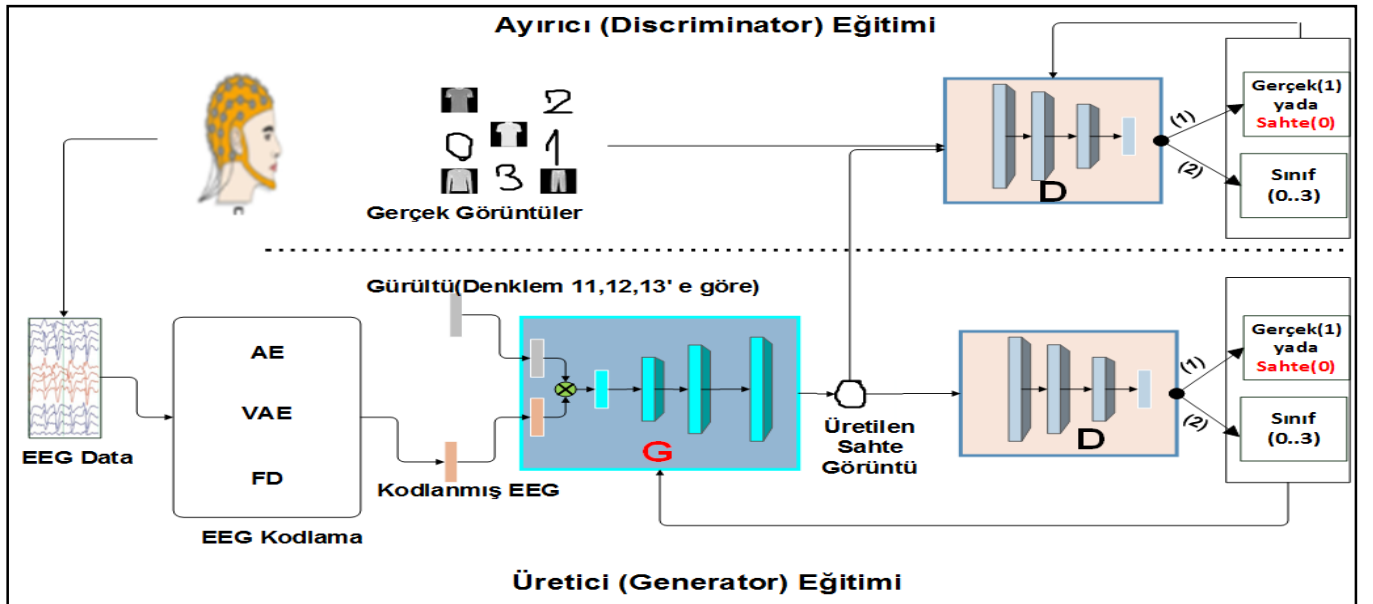
$$X_{FD}(f) = \int_{-\infty}^{+\infty} x(t) e^{-i2\pi f t} dt \quad (9)$$

$$x(t) = \int_{-\infty}^{+\infty} X_{FD}(f) e^{i2\pi f t} df \quad (10)$$

$x(t)$ EEG sinyalinin zaman alanı gösterimi, $X_{FD}(f)$ ise frekans alan gösterimidir.

4 Önerilen EEG-GAN mimarisi

Önerilen mimari Şekil 2'de detaylı gösterilmektedir. Buna göre, gerçek görseller deneklere gösterilmekte ve görsellere bakılırken EEG sinyalleri kaydedilmektedir. Kaydedilen EEG sinyalleri çeşitli kodlamalardan (AE, VAE ve FD) geçirilerek EEG-GAN mimarisine giriş olarak verilmekte ve EEG-görsel arasındaki eşlemeyi sağlayabilen bir ağı eğitilmesi hedeflenmektedir.



Şekil 2. Önerilen EEG-GAN mimarisi.
Figure 2. Recommended EEG-GAN architecture.

Önerilen mimari, temel olarak ACGAN'ın güncellenmiş bir versiyonudur. ACGAN görüntü üretiminde, sınıf bilgisi ve gürültü vektörünü (z) girdi olarak alırken, önerilen mimaride, kodlanmış EEG sinyali ve Denklem (11)-(13) ile üretilen gürültü vektörü girdi olarak kullanılır. Her iki GAN yaklaşımının maliyet fonksiyonu aynıdır.

ACGAN'ın üzerinde yapılan bu modifikasyonların temel nedeni, EEG sinyalinden kaliteli görüntülerin üretilmesini sağlamaktır. Klasik kullanımda oldukça kaba görüntülerin üretildiği görülmektedir. Bunu düzeltmenin bir yolu olarak rasgele girdi vektörünün (Denklem (11)) rasgelelik düzeyinin indirgenmesi (Denklem (12),(13)) ve anlamlı bir yapı (sınıfların ortalama ve standart sapma değerleri) ile birlikte kullanılmasının görsel üretim kalitesi üzerinde pozitif etkisi oluşturacağı öngörülmüştür. Bahsedilen rasgelelik düzeyi Denklem (12) ve (13)'deki gibi indirgenmektedir. Her iki kullanımda sınıfların ortalaması ve standart sapma değerleri göz önüne alınmıştır.

$$z = randn(1, sizeEEG) \quad (11)$$

$$z = \mu_{class} + \sigma_{class} * randn(1,1) \quad (12)$$

$$z = \mu_{class} + \sigma_{class} * randn(1, sizeEEG) \quad (13)$$

$sizeEEG$, EEG sinyalin vektörel uzunluğunu, μ_{class} ve σ_{class} , EEG sınıfların sırasıyla ortalamasını ve standart sapmasını, $randn$ normal dağılım fonksiyonunu ifade etmektedir.

5 Veri seti

Bu çalışmada, EEG sinyallerinden bakılan görselin üretilmesi amaçlandığı için veri kümelerinde hem EEG sinyali hem de bakılan görsel imgenin yer alması gerekmektedir. Bu gereklilik gözetilerek yapılan literatür çalışmasında aşağıda listelenen veri kümelerine ulaşılmıştır.

- 1) MindWave [38]: EEG sinyalleri deneklerin iki saniye boyunca rakam (0...9) görsellerine bakmasıyla elde edilmiştir. Veri tabanında toplam 54.934 adet EEG sinyali içermektedir. Her bir EEG sinyal uzunluğu 441-1017 arasında değişkenlik göstermektedir.
- 2) DB [6]: EEG sinyalleri deneklerin üç buçuk saniye boyunca dört farklı görsele bakmasıyla elde edilmiştir. Toplam 2670 adet EEG sinyali elde

edilmiştir. Her bir sinyalin boyutu 1344'tür. EEG sinyalleri zaman alanından frekans alanına dönüştürülerek kaydedilmiştir.

İlk olarak veri kümelerinin güvenilirliği hesaplanmıştır. Bu veri setlerini eğitmek için Tablo 1-sol'daki ESA mimarisi kullanılmıştır. Yukarıda bahsedilen veri kümelerinin yaklaşık %75'i eğitim, %25'i test için kullanılmıştır. Her veri seti için eğitim işlemi 100 iterasyon gerçekleştirilmiştir.

MindWave veri kümesinin eğitilmiş ESA ile sınıflandırılma başarımın (%9.6) oldukça düşük çıktığı görülmüştür. Elde edilen bu sonuç, MindWave adlı veri kümesindeki EEG sinyallerinin sağlıklı bir şekilde elde edilmediğini göstermektedir (bk. Tablo 1-sağ-üst). Bu nedenle bu veri kümesinin kullanımından vazgeçilmiştir. Benzer veri doğrulama işlemi DB [6] veri kümesindeki EEG sinyalleri üzerinde gerçekleştirilmiştir ve %91 başarımla sinyallerin sınıflandırılabilirliği görülmüştür (bk. Tablo 1-sağ-alt). Yapılan güvenlik testi sonucunda DB veri kümesinin kullanımına karar verilmiştir.

6 Deneysel çalışmalar

Deneysel çalışmalar Nvidia Quard M4000 GPU, 20 çekirdekli 2 işlemciden oluşan bir CPU, 64 GB ram bileşenlerine sahip bir sunucu bilgisayarda gerçekleştirilmiştir. Yapılan uygulamalar Python ve Matlab programlama dilleri kullanılmıştır.

Bu bölümde önerilen yaklaşımlarla klasik EEG-GAN [8] yaklaşımının görüntü üretim performansları değerlendirilmektedir. Klasik EEG-GAN yöntemi kodlama işlemi için AE yöntemini kullanırken, önerilen yöntemde VAE ve FD kullanılması tercih edilmiştir.

DB veri kümesinde EEG sinyallerinin frekans yanıtları yer almaktadır. AE ve VAE yöntemleri zaman serisi sinyallerini giriş olarak aldığı için DB kümesinin frekans→zaman dönüşümü yapılmıştır. Zaman alanı dönüşümü tamamlandıktan sonra Tablo 2'de gösterilen AE ve Tablo 3'te VAE mimarileri oluşturulmuştur. Her iki mimarinin giriş ve çıkış katmanına EEG sinyalleri verilerek 1000 iterasyon eğitim gerçekleştirilmiştir. Eğitim sonrası 2670x1344 (kayıt sayısı x EEG sinyal boyutu) veri kümesi AE yönteminin kodlayıcı ağı ile kodlanarak 2670x100 boyutuna indirgenmiştir.

Tablo 1. Veri kümelerinin güvenilirlik sonuçları. (sol) Kullanılan ESA mimarisi, (sağ-üst) MindWave veri seti için eğitim ve test sonuçları, (sağ-alt) DB veri seti için eğitim ve test sonuçları.

Table 1. Reliability results of data sets. (left) Used CNN architecture, (right-top) training and test results for MindWave data set, (right-bottom) training and test results for DB data set.

ESA Mimarisi	Veri Setlerin Eğitim ve Test Sonuçları
	MindWave veri setinin güvenlik testi sonuçları
	iterasyon 100/100
	- 12s - loss: 14.4965 - acc: 0.1006 - val_loss: 14.5560 - val_acc: 0.0969
	Sonuçlar: Test Loss 14.55, Test Accuracy 0.096 (%9.6)
	1.331 doğru sınıflandırılmış
	12.403 yanlış sınıflandırılmış
	DB Veri setinin güvenlik testi sonuçları
	iterasyon 100/100
	- 1s - loss: 0.0793 - acc: 0.9693 - val_loss: 0.4423 - val_acc: 0.9108
	Sonuçlar: Test Loss 0.44, Test Accuracy 0.91 (%91)
	592 doğru sınıflandırılmış
	58 yanlış sınıflandırılmış

Tablo 2. AE mimarisi.
Table 2. AE architecture.

Kodlayıcı	Çözücü
TamBağlıKat.(16, "relu")	Boyutlandırma((5, 5, 4))
Boyutlandırma((4, 4, 1))	2BEvrişimKat .(8, (3, 3))
2BEvrişimKat.(16, (3, 3))	Düğümdüşürme .(0.25)
Düğümdüşürme(0.25))	Büyütme((2, 2))
Max.Havuzlama((2, 2))	2BEvrişimKat .(8, (3, 3))
2BEvrişimKat. (8, (3, 3))	Düğümdüşürme (0.25))
Düğümdüşürme (0.25)	Büyütme ((2, 2))
Max.Havuzlama ((2, 2))	2BEvrişimKat (16, (3, 3))
2BEvrişimKat. (8, (3, 3))	Düğümdüşürme (0.25)
Vektörleştirme()	Vektörleştirme ()
TamBağlıKat. (100)	TamBağlıKat.(1344, "sigmoid")

Tablo 3. VAE mimarisi.
Table 3. VAE architecture.

Katman	Bağlantı
Giriş (1344)	
KODLAYICI	
TamBağlıKat.(16)	kodlayıcı_giriş[0][0]
TamBağlıKat .(1344)	TamBağlıKat _4[0][0]
TamBağlıKat.(1344)	TamBağlıKat _4[0][0]
z (Lambda)	z_ortalama[0][0] z_log_var[0][0]
z_örneklendirme (Giriş(shape=(100,))	
ÇÖZÜCÜ	
TamBağlıKat (512)	
TamBağlıKat (1344)	

İkinci aşamada DB veri kümesindeki her bir EEG sinyalinin etiket (sınıf) değerleri kullanılarak MNIST [39] veya Fashion MNIST [40] veri setlerinden görsel atama işlemi gerçekleştirilmiştir. Amaç sinyalden görüntüye ulaşmaktır. MNIST veri kümesi el yazısıyla yazılmış rakamlardan (0-9) oluşur. Fashion MNIST veri kümesi 0-9 arasında etiketlenmiş (0=tişört, 1=pantolon, 2=kazak, 3=elbise, 4=ceket, 5=sandalet, 6=gömlek, 7=spor ayakkabı, 8=çanta, 9=kısa bot) görüntülerini içerir. Her iki veri seti 60.000 eğitim, 10.000 test olmak üzere toplamda 70.000 adet görüntüden oluşmaktadır. Veri setleri 10 sınıftan (0-9) oluşurken, görsel atama işlemi gerçekleştirmek için bu veri setlerin sadece ilk dört sınıfın (0-3) görselleri kullanılmıştır. EEG sinyallerin etiket numarası ile örtüşen veri setlerden rasgele bir görsel alınarak EEG sinyalinin yanına yerleştirilmiştir. Bu şekilde dört farklı veri seti (AE, Orijinal, VAE, FD) hazırlanmıştır. Her bir veri seti 2670 adet kayıttan oluşmakta ve her kayıt sınıf bilgisini, kodlanmış EEG sinyalini ve görsel bilgisini içermektedir. Tablo 4'te sinyal-görsel

birleştirme işlemi sonucunda oluşan bir kaydın boyutları ifade edilmektedir.

Üçüncü aşamada önerilen EEG-GAN mimarisi hazırlanmış ve farklı yöntemler ile bu mimari eğitilmiştir. Önerilen model Şekil 2'de, mimari yapısı Tablo 5'te sunulmuştur. EEG-GAN mimarisi, her bir kodlama yöntemi (AE, Orijinal, VAE, FD) ve her bir görüntü elde etme metodu (Denklem (11)-(13)) ile ayrı ayrı 12 farklı şekilde 100 iterasyon eğitilmiştir. Tablo 4'e göre hazırlanan dört farklı veri setinin %75'i eğitim, %25'i test için kullanılmıştır.

Dördüncü aşamada, eğitim tamamlandıktan sonra mimarilerin sadece üretici kısımları kullanılarak görüntü üretimi sağlanmıştır. Test veri kümesindeki her sınıftan 100 adet EEG sinyali, EEG-GAN mimarisinde üretici ağı giriş olarak verilmiş ve görselin inşa edilmesi sağlanmıştır. Sınıf sayısı dört olduğu için her bir yöntemden 400 EEG sinyalinden 400 görsel üretilmiştir. Üretilen örnek görseller Tablo 6'da sunulmuştur.

Tablo 4. EEG-Görsel birleşimi sonrası bir kaydın uzunluğu.

Table 4. Length of a recording after EEG-Visual combination.

Kodlayıcılar	Etiket	Kodlanmış EEG	Görsel	Toplam
AE	1	100	784	885
Orijinal	1	1344	784	2129
VAE	1	1344	784	2129
FD	1	1344	784	2129

Tablo 5. EEG-GAN mimarisi.

Table 5. EEG-GAN architecture.

Ağ	Katman	Özellik Haritası	Çıkış Boyutu	Filtre Boyutu	Adım	Aktivasyon
Üretici	Giriş EEG(EEG) (input)	-	100	-	-	-
	Giriş_gürültü(Denklem (11)-(13) göre)(input)	-	100	-	-	-
	Çarpma (Multiply) (Giriş_EEG.x Giriş_gürültü)	-	100	-	-	-
	Tam Bağlı Katman(Dense)	-	6272	-	-	-
	Yeniden Boyutlandırma(Reshape)	-	7x7x128	-	-	-
	Normalizasyon(BatchNormalizasyon)	-	7x7x128	-	-	-
	Büyütme(UpSampling2D)	-	14x14x128	-	-	-
	2B Evrişim Katmanı (Conv2D)	128	14x14x128	3x3	-	relu
	Normalizasyon(BatchNormalizasyon)	-	14x14x128	-	-	-
	Büyütme(UpSampling2D)	-	28x28x128	-	-	-
	2B Evrişim Katmanı (Conv2D)	64	28x28x64	3x3	-	-
	Normalizasyon(BatchNormalizasyon)	-	28x28x64	-	-	relu
	2B Evrişim Katmanı (Conv2D)	1	28x28x1	3x3	-	tanh
	Ayrııcı	Giriş(input)	-	28x28x1	-	-
2B Evrişim Katmanı (Conv2D)		16	14x14x16	3x3	2	-
Aktivasyon(LeakyReLU(alpha=0.2))		-	14x14x16	-	-	-
Düğüm düşürme katmanı- (Dropout((0.25))		-	14x14x16	-	-	-
2B Evrişim Katmanı (Conv2D)		32	7x7x32	3x3	2	-
Sıfırla doldurma(ZeroPadding2D())		-	8x8x32	-	-	-
Aktivasyon(LeakyReLU(alpha=0.2))		-	8x8x32	-	-	-
Düğüm düşürme katmanı- (Dropout((0.25))		-	8x8x32	-	-	-
Normalizasyon(BatchNormalizasyon)		-	8x8x32	-	-	-
2B Evrişim Katmanı (Conv2D)		64	4x4x64	3x3	2	-
Aktivasyon(LeakyReLU(alpha=0.2))		-	4x4x64	-	-	-
Düğüm düşürme katmanı(Dropout((0.25))		-	4x4x64	-	-	-
Normalizasyon(BatchNormalizasyon)		-	4x4x64	-	-	-
2B Evrişim Katmanı (Conv2D)		128	4x4x128	3x3	1	-
Aktivasyon(LeakyReLU(alpha=0.2))		-	4x4x128	-	-	-
Düğüm düşürme katmanı(Dropout((0.25))		-	4x4x128	-	-	-
Vektöre Dönüştürme (Flatten)		-	2048	-	-	-
<i>Ayrııcı ağın devamı olan aşağıdaki katmanlar, görselin gerçek / sahte durumu için (a), sınıf bilgisi için (b) seçilir.</i>						
(a) Tam Bağlı Katman(Dense)			1	sigmoid		
(b) Tam Bağlı Katman(Dense)			Sınıf sayısı	softmax		

Son aşamada üretilen görsel kalitesinin belirlenebilmesi için MNIST ve Fashion MNIST veri setlerin ile ayrı ayrı eğitilmiş ESA yardımıyla üretilen görsellerin sınıflandırılması sağlanmıştır. Bu aşamada ilk olarak ESA eğitimi için MNIST ve Fashion MNIST veri setlerinden ilk dört sınıfın (0-3) verilerini içeren görseller alınarak ayrı ayrı iki eğitim veri seti hazırlanmıştır. Hazırlanan bu yeni MNIST veri seti 0'dan 3'e kadar rakamları içeren görüntülerden oluşurken, Fashion MNIST veri seti 0'dan 3'e kadar etiketlenmiş (0=Tişört, 1=Pantolon, 2=Kazak, 3=Elbise) kıyafet görüntülerinden oluşmaktadır. ESA mimarisi bu veri setleri ile ayrı ayrı 100 iterasyon (MNIST başarı oranı=%99.9, Fashion MNIST başarı oranı=%99.8) eğitilerek hazırlanmıştır. Eğitim bittikten sonra üretici ağ tarafından üretilen görüntüler ESA ağına girdi olarak verilmiş ve

gerçekten uygun sınıfa aktarılıp aktarılmadığına bakılmıştır. Üretilen görsellerin ESA doğrulukları Tablo 7'de verilmiştir.

Tablo 6'da üretilen görseller incelendiğinde kodlama tekniği olarak FD kullanılmasıyla kaliteli ve kendi sınıfından görseller ürettiği görülmektedir.

Üretilen görsellerin sınıflandırma doğrulukları için karışıklık matrisi (confusion matrix) kullanılmıştır. Karışıklık matrisi sınıflandırma performansını ölçmek için kullanılan bir yöntemdir. Sınıflandırma performansı Denklem (14)'te verilen formül ile hesaplanmaktadır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

Burada, *TP* doğru sınıflandırılmış pozitif örnek (True Positive), *TN* doğru sınıflandırılmış negatif örnek (True Negative), *FP* yanlış sınıflandırılmış pozitif örnek (False Positive) ve *FN* yanlış sınıflandırılmış negatif örnek (False Negative) değerlerini ifade etmektedir [41].

Tablo 7'deki sonuçlar incelendiğinde, önerilen kodlama teknikleri (FD ve VAE) ve önerilen EEG-GAN mimarisinin kullanılmasıyla EGG sinyallerinden üretilen görsellerin eğitilmiş ESA ile sınıflandırma başarısının oldukça yüksek

olduğu görülmektedir. Elde edilen sonuçlar, önerilen kodlama ve GAN mimarisinin EEG sinyallerini görsele dönüştürme kabiliyetinin klasik yaklaşımlardan iyi olduğunu ortaya koymaktadır. Tablo 6 ve Tablo 7'deki sonuçlar dikkatlice incelendiğinde, özellikle kodlama tekniği olarak FD ve gürültü vektörü olarak Denklem (12)'nin kullanılmasıyla kaliteli görseller ve daha yüksek başarı elde edildiği görülmektedir. Daha sonra VAE ve AE tekniklerinin uygun sonuçlar sağladığı görülmektedir.

Tablo 6. Farklı kodlama yöntemleri ve gürültü teknikleri ile EEG-GAN mimarisi kullanılarak test veri setindeki EEG sinyallerinden üretilen örnek görseller.

Table 6. Sample images produced from EEG signals in the test data set using EEG-GAN architecture with different coding methods and noise techniques.

Kodlayıcı	Gürültü (z)	MNIST görselleri				
		0	1	2	3	
[8] AE	Denklem (11)					
	Denklem (12)					
	Denklem (13)					
Orijinal Orijinal	Denklem (11)					
	Denklem (12)					
	Denklem (13)					
Önerilen	VAE	Denklem (11)				
		Denklem (12)				
		Denklem (13)				
	FD	Denklem (11)				
		Denklem (12)				
		Denklem (13)				

Kodlayıcı	Gürültü (z)	Fashion MNIST görselleri				
		0 (Tişört)	1 (Pantolon)	2 (Kazak)	3 (Elbise)	
[8] AE	Denklem (11)					
	Denklem (12)					
	Denklem (13)					
Orijinal Orijinal	Denklem (11)					
	Denklem (12)					
	Denklem (13)					
Önerilen	VAE	Denklem (11)				
		Denklem (12)				
		Denklem (13)				
	FD	Denklem (11)				
		Denklem (12)				
		Denklem (13)				

Tablo 7. Farklı kodlama yöntemleri ve gürültü teknikleri ile EEG-GAN mimarisi kullanılarak test veri setindeki EEG sinyallerinden üretilen görsellerin ESA doğrulukları.
Table 7. CNN accuracy of visuals produced from EEG signals in the test dataset using different coding methods and noise techniques and EEG-GAN architecture.

		MNIST doğruluk																						
		[8]	Orjinal_EEG		Önerilen																			
		AE	Orjinal		VAE	FD																		
Denklem (11)	Gerçek Değer	0	0	0	100	0	0	0	0	0	26	23	23	28	0	23	30	0	27	0	77	9	7	7
	1	0	0	0	100	0	0	0	0	1	36	28	11	25	1	22	34	0	24	1	9	65	12	14
	2	0	0	0	100	0	0	0	0	2	25	28	15	32	2	23	26	23	28	2	11	21	60	8
	3	0	0	0	100	0	0	0	0	3	23	30	16	31	3	24	23	30	23	3	5	12	14	69
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		
Denklem (12)	Gerçek Değer	0	98	0	1	1	0	59	0	0	41	0	100	0	0	0	0	100	0	0	0			
	1	2	0	95	0	3	1	0	95	5	0	1	0	100	0	0	1	0	100	0	0			
	2	3	1	0	96	0	2	0	0	100	0	2	0	0	100	0	2	0	0	100	0			
	3	9	0	4	0	87	3	47	0	0	53	3	0	0	0	100	3	0	0	0	100			
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		
Denklem (13)	Gerçek Değer	0	38	20	4	38	0	59	8	8	25	0	80	1	2	17	0	100	0	0	0			
	1	35	30	20	15	1	16	37	23	24	1	2	80	17	1	1	0	100	0	0				
	2	12	21	66	1	2	17	15	51	17	2	1	17	81	1	2	0	0	100	0				
	3	33	7	1	59	3	46	9	12	33	3	58	4	0	38	3	0	0	0	100				
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		
		[8]	Orjinal_EEG		Önerilen																			
		AE	Orjinal		VAE	FD																		
Denklem (11)	Gerçek Değer	0	0	0	100	0	0	16	33	30	21	0	22	25	30	23	0	53	7	14	26			
	1	0	0	0	100	0	1	11	32	38	19	1	30	27	24	19	1	3	72	11	14			
	2	0	0	0	100	0	2	11	34	31	24	2	26	36	22	16	2	15	32	30	23			
	3	0	0	0	100	0	3	13	34	30	23	3	17	40	21	22	3	14	11	24	51			
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		
Denklem (12)	Gerçek Değer	0	92	3	0	5	0	43	0	2	55	0	100	0	0	0	0	99	0	0	1			
	1	0	0	100	0	0	1	0	41	59	0	1	0	100	0	0	1	0	100	0	0			
	2	0	7	0	61	12	2	0	43	57	0	2	5	0	95	0	2	0	0	100	0			
	3	6	2	0	0	92	3	49	0	1	50	3	11	0	0	89	3	0	0	0	100			
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		
Denklem (13)	Gerçek Değer	0	32	34	4	30	0	43	11	18	28	0	41	37	3	19	0	100	0	0	0			
	1	25	37	21	17	1	4	75	15	6	1	0	66	17	17	1	0	99	1	0				
	2	6	24	67	3	2	6	19	73	2	2	0	9	75	16	2	0	0	100	0				
	3	18	33	3	46	3	34	9	7	50	3	46	30	2	22	3	3	0	2	95				
		Tahmini Değer	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3	0	1	2	3		

7 Sonuçlar

Bu çalışmada klasik EEG sinyal sınıflandırıcılardan ötede, EEG sinyalinin kullanarak bakılan görselin üretilmesi alanında yeni matematiksel yaklaşımlar önerilmiştir. Mevcut görüntü üretme teknikleri klasik GAN modeli ve AE kodlayıcı modüllerini kullanırken, önerilen yaklaşım ACGAN modelini ve FD/VAE kodlayıcı modülünü kullanmayı önermektedir.

Önerilen yaklaşımla GAN girişindeki rastgelelik düzeyi sınıf karakteristikleri (ortalama, standart sapma) göz önüne alınarak ayarlanmıştır. Yapılan deneysel çalışmalarda mevcut ve önerilen kodlama tekniklerinin her birine üç farklı gürültü ekleme operasyonu uygulanmış ve görsel üretim kalitesi incelenmiştir. EEG sinyallerine karşılık MNIST ve Fashion MNIST veri kümelerinin kullanıldığı bu çalışmada, üretilen görsel kalitesi önceden eğitilmiş bir ESA ile belirlenmiştir. Sonuç olarak, EEG sinyallerinden görsel üretim işlemi için önerilen EEG-GAN modeli ve FD/VAE tekniğinin klasik yöntemlerden başarılı olduğu görülmüştür. Bir sonraki çalışmada rakam görselleri yerine harf ve gerçek ortam görüntülerinin üretilmesi planlanmaktadır.

8 Conclusions

In this study, new mathematical approaches are proposed in the field of producing visuals using EEG signal, beyond the classical EEG signal classifiers. While current image generation techniques use the classic GAN model and AE encoder modules, the proposed approach suggests using the ACGAN model and the FT/VAE encoder module.

With the proposed approach, the randomness level in the GAN entry was adjusted considering the class characteristics (mean, standard deviation). In experimental studies, three different noise adding operations were applied to each of the existing and proposed coding techniques and visual production quality was examined. In this study, where MNIST and Fashion MNIST datasets were used against EEG signals, the visual quality produced was determined with a pre-trained CNN. As a result, EEG-GAN model and FT / VAE technique proposed for visual production from EEG signals were found to be successful than classical methods. In the next study, it is planned to produce letter and real environment images instead of digit images.

9 Yazar katkı beyanı

Gerçekleştirilen çalışmada Gaffari Çelik özet, giriş, ACGAN mimarisi, önerilen EEG-GAN mimarisi, veri seti, deneysel çalışmalar ve sonuçlar başlıklarında; Muhammed Fatih Talu: özet, giriş, önerilen EEG-GAN mimarisi, deneysel çalışmalar ve sonuçlar başlıklarında katkı sunmuşlardır.

10 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

11 Kaynaklar

[1] Sampinato C, Palazzo S, Kavasidis I, Giordano D, Souly N, Shah M. "Deep learning human mind for automated visual classification". *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21-26 July 2017.

- [2] Greenfield LJ, Geyer JD, Carney PR. "Reading EEGs: A Practical Approach". https://books.google.com.tr/books?hl=tr&lr=&id=DuzmRe5p7cYC&oi=fnd&pg=PR7&ots=vohxi2Wmlt&sig=asw948ngWgNjhnRbkFT9oGM0ojo&redir_esc=y#v=onepage&q&f=false, (10.09.2019).
- [3] Pfurtscheller G, Lopes Da Silva FH. "Event-Related EEG/MEG synchronization and desynchronization: Basic principles". *Clinical Neurophysiology*, 110(11), 1842-1857, 1999.
- [4] Grosse-wentrup M, Member S, Buss M. "Multiclass Common Spatial Patterns and Information Theoretic Feature Extraction". *IEEE Transactions on Biomedical Engineering*, 55(8), 1991-2000, 2008.
- [5] Amin SU, Alsulaiman M, Muhammad G, Mekhtiche MA, Hossain MS. "Deep Learning for EEG motor imagery classification based on multi-layer CNNs feature fusion". *Future Generation Computer Systems*, 101, 542-554, 2019.
- [6] Bashivan P, Rish I, Yeasin M, Codella N. "Learning representations from EEG with deep recurrent-convolutional neural networks". *4th International Conference on Learning Representations, ICLR 2016*, San Juan, Puerto Rico, 2-4 May 2016.
- [7] Chen H, Song Y, Li X. "A deep learning framework for identifying children with ADHD using an EEG-Based brain network". *Neurocomputing*, 356, 83-96, 2019.
- [8] Tirupattur P, Spampinato C, Rawat YS, Shah M. "ThoughtViz: Visualizing human thoughts using generative adversarial network". *2018 ACM Multimedia Conference on Multimedia Conference, MM 2018*, Seoul, Republic of Korea, 22-26 October 2018.
- [9] Hwang S, Hong K, Son G, Byun H. "EZSL-GAN: EEG-based Zero-Shot Learning approach using a Generative Adversarial Network". *2019 7th International Winter Conference on Brain-Computer Interface (BCI)*, Gangwon, Korea (South), 18-20 February 2019.
- [10] Luo Y, Lu BL. "EEG Data Augmentation for Emotion Recognition Using a Conditional Wasserstein GAN". *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Honolulu, HI, USA, 18-21 July 2018.
- [11] Fahimi F, Ang KK. "Towards EEG Generation Using GANs for BCI Applications". *2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, Chicago, IL, USA, USA, 19-22 May 2019.
- [12] Jiao Y, Deng Y, Luo Y, Lu B. "Driver Sleepiness Detection from EEG and EOG signals Using GAN and LSTM Networks". *Neurocomputing*, 408, 100-111, 2019. doi: 10.1016/j.neucom.2019.05.108, 2020.
- [13] Corley IA, Huang Y. "Deep EEG super-resolution: Upsampling EEG spatial resolution with Generative Adversarial Networks". *2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, Las Vegas, NV, USA, 4-7 March 2018.
- [14] Hartmann KG, Schirrmeyer RT, Ball T. "EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals". *arXiv*, 2018. <https://arxiv.org/abs/1806.01875>.

- [15] Olson LC. "How Brain Death Works". <https://science.howstuffworks.com/life/inside-the-mind/human-brain/brain-death1.htm><https://science.howstuffworks.com/life/inside-the-mind/human-brain/brain-death1.htm> (13.11.2019).
- [16] Yi X, Walia E, Babyn P. "Generative adversarial network in medical imaging: A review". *Medical Image Analysis*, 58, 101552, 2019.
- [17] Goodfellow IJ, Pouget-Abadie J, Mirza M, Xu B, Warde Farley D, Ozair S, Courville A, Bengio Y. "Generative Adversarial Networks". *Veterinary Immunology and Immunopathology*, 155(4), 270-275, 2014.
- [18] Kim T, Cha M, Kim H, Lee JK, Kim J. "Learning to discover cross-domain relations with generative adversarial networks". *ICML 2017: 34th International Conference on Machine Learning*, Sydney, Australia, 6-11 August 2017.
- [19] Zhu JY, Park T, Isola P, Efros AA. "Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks". *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, 22-29 October 2017.
- [20] Yi Z, Zhang H, Tan P, Gong M. "DualGAN: Unsupervised Dual Learning for Image-to-Image Translation". *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, 22-29 October 2017.
- [21] Mao X, Wang S, Zheng L, Huang Q. "Semantic invariant cross-domain image generation with generative adversarial networks". *Neurocomputing*, 293, 55-63, 2018.
- [22] Ledig C, Theis L, Huszár F, Caballero J, Cunningham A, Acosta A, Aitken A, Tejani A, Totz J, Wang Z, Shi W. "Photo-realistic single image super-resolution using a generative adversarial network". *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21-26 July 2017.
- [23] Li C, Wand M. *Precomputed Real-Time Texture Synthesis with Markovian Generative Adversarial Networks*. Editors: Leibe B, Matas J, Sebe N, Welling M. *Computer Vision-ECCV 2016*, 702-716, Springer, Cham, 2016.
- [24] Xu L, Zeng X, Li W, Huang Z. "Multi-granularity generative adversarial nets with reconstructive sampling for image inpainting". *Neurocomputing*, 2020, <https://doi.org/10.1016/j.neucom.2020.04.011>.
- [25] Antipov G, Baccouche M, Dugelay JL. "Face aging with conditional generative adversarial networks". *2017 IEEE International Conference on Image Processing (ICIP)*, Beijing, China 17-20 September 2017.
- [26] Zhang H, Xu T, Li H, Zhang S, Wang X, Huang X, Metaxas D. "StackGAN: Text to photo-realistic image synthesis with stacked generative adversarial networks". *2017 IEEE International Conference on Computer Vision*, Venice, Italy, 22-29 October 2017.
- [27] Duarte A, Roldan F, Tubau M, Escur J, Pascual S, Salvador A, Mohedano E, McGuinness K, Torres J, Giro-I-Nieto X. "Wav2Pix: Speech-Conditioned face generation using generative adversarial networks". *ICASSP 2019*, Brighton, UK, 12-17 May 2019.
- [28] Odena A, Olah C, Shlens J. "Conditional image synthesis with auxiliary classifier GANs". *ICML'17 Proceedings of the 34th International Conference on Machine Learning*, Sydney, NSW, Australia, 06-11 August 2017.
- [29] Meziani A, Djouani K, Medkour T, Chibani A. "A Lasso quantile periodogram based feature extraction for EEG-based motor imagery". *Journal of Neuroscience Methods*, 2019. <https://doi.org/10.1016/j.jneumeth.2019.108434>.
- [30] Gao J, Li L. "A robust geometric mean-based subspace discriminant analysis feature extraction approach for image set classification". *Optik*, 2019. <https://doi.org/10.1016/j.ijleo.2019.163368>.
- [31] Luo X, Li X, Wang Z, Liang J. "Discriminant autoencoder for feature extraction in fault diagnosis". *Chemometrics and Intelligent Laboratory Systems*, 2019. <https://doi.org/10.1016/j.chemolab.2019.103814>.
- [32] Zhao X, Jia M, Lin M. "Deep Laplacian Auto-encoder and its application into imbalanced fault diagnosis of rotating machinery". *Measurement*, 2020. <https://doi.org/10.1016/j.measurement.2019.107320>.
- [33] Kingma DP, Welling M. "Auto-encoding variational bayes". *2nd International Conference on Learning Representations*, ICLR 2014, Banff, AB, Canada, 14-16 April 2014.
- [34] Fu X, Wei Y, Xu F, Wang T, Lu Y, Li J, Huang JZ. "Semi-supervised aspect-level sentiment classification model based on variational autoencoder". *Knowledge-Based Systems*, 171, 81-92, 2019.
- [35] Wang X, Du Y, Lin S, Cui P, Shen Y, Yang Y. "adVAE: A self-adversarial variational autoencoder with Gaussian anomaly prior knowledge for anomaly detection". *Knowledge-Based Systems*, 2020. <https://doi.org/10.1016/j.knosys.2019.105187>.
- [36] Merry RJE. "Wavelet theory and applications: a literature study". Department of Mechanical Engineering, Eindhoven University of Technology, Eindhoven, Netherlands, 41, DCT Rapporten (2005.053), 2005.
- [37] Öztürk H. Eeg Sinyallerinde Farklı Boyut İndirgeme ve Sınıflandırma Yöntemlerinin Karşılaştırılması. Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Aydın, Türkiye, 2016.
- [38] Vivancos D. "MindBigData The "MNIST" of Brain Digits". <http://www.mindbigdata.com/opencv/index.html> (15.08.2019).
- [39] LeCun Y, Cortes C, Burges CJC. "THE MNIST DATABASE of Handwritten Digits". <http://yann.lecun.com/exdb/mnist/> (22.11 2019).
- [40] Xiao H, Rasul K, Vollgraf R. "Fashion-MNIST: a novel image dataset for benchmarking machine learning algorithms". *arXiv*, 2017. <https://arxiv.org/abs/1708.07747>.
- [41] Acı Çİ, Çırak A. "Türkçe haber metinlerinin konvolüsyonel sinir ağları ve Word2Vec kullanılarak sınıflandırılması". *Bilişim Teknol. Dergisi*, 12(3), 219-228, 2019.