



Denim Kumaşından Otomatik Yüksek Çözünürlüklü Bıyık Desen Sentezi

Automatic High-Resolution Mustache Pattern Synthesis From Denim Fabric

Emrullah ŞAHİN¹ , Muhammed Fatih TALU² 

¹Yazılım Mühendisliği Bölümü, Dumlupınar Üniversitesi, Kütahya, Türkiye

²Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

(essahin950@gmail.com, fatihtalu@gmail.com)

Received:Sep.08,2022

Accepted:Sep.16,2022

Published:Oct.10,2022

Özetçe—Denim kumaşlarındaki bıyık desenlerinin elde edilmesi uzman bir kişi tarafından manuel olarak yaklaşık 2-3 saat sürmektedir. Zamansal maliyetle birlikte kişi bazlı üretimden kaynaklı hatalar meydana gelmektedir. Bu problemin çözümü için bu çalışmada güncel Çekişmeli üretici ağlardan biri olan Pix2PixHD mimarisi kullanılmıştır. Derin öğrenme tabanlı bu mimarinin kullanımı için 2048x1024 ebatlarındaki 589 adet Denim kumaşı-Bıyık Deseni görüntü çiftinden oluşan Denim2BıyıkHD veri kümesi hazırlanmıştır. Mimarinin en uygun sonuçları verebilmesi için üzerinde iyileştirmeler yapılarak geliştirilmiş versiyonu önerilmiştir. Eğitim işleminden sonra geliştirilmiş yöntemle birlikte görüntü kalitesinde yaklaşık %92 oranında başarımlar sağlanırken, zamansal üretim işlem maliyeti 1 saniyenin altına düşürülmüştür. Bu çalışmayla birlikte Denim kumaşlarındaki bıyık desenlerinin otomatik, yüksek kalitede, hızlı ve nesnel bir şekilde üretimini sağlayan yazılımsal bir sistem geliştirilmiştir.

Anahtar Kelimeler : Denim kumaş, Bıyık deseni, Görüntü Sentezi, Çekişmeli üretici ağlar

Abstract— Obtaining the mustache patterns on denim fabrics takes about 2-3 hours manually by an expert. Along with the temporal cost, errors occur due to person-based production. To solve this problem, Pix2PixHD architecture, one of the up-to-date Generative adversarial networks, is used in this study. For the use of this deep learning-based architecture, Denim2BıyıkHD dataset consisting of 589 Denim fabric-Mustache Pattern image pairs in 2048x1024 dimensions was prepared. For the architecture to give the most appropriate results, its improved version has been proposed. With the improved method after the training process, approximately %92 of the image quality was achieved, while the temporal production process cost was reduced to less than 1 second. With this study, a software system was developed that enables the automatic, high quality, fast and objective production of mustache patterns on denim fabrics.


Keywords : Denim fabric, Mustache pattern, Image synthesis, Generative adversarial networks

1. Giriş

Tekstil ve hazır giyim sektörü ülkemizde ve dünyada hızlı gelişme göstermektedir. Bu noktada teknolojiye hızlı gelişime uyum sağlayabilen yerli firmalar, üretim maliyetleri ve personel giderlerindeki azalma nedeniyle global ölçekte rekabet edebilir düzeye çıkabilecektir. Günümüzde tekstil ve hazır giyim sektörünün en önemli çalışma alanlarından biri Denim kumaşları ve bu kumaşların işlenmesidir. Denim kumaşlarının hayatın her alanında rahatlıkla kullanılabilir olması talebin gün geçtikçe artmasına neden olmakta ve kumaş üreticilerini artan talebi karşılama noktasında yeni aksiyonlar almaya itmektedir. Teknolojinin gelişmesine bağlı olarak denim kumaş üretiminde personel giderleri ve üretim maliyetlerin düşürülmesi, yüksek konfor ve kaliteye sahip ürünlerin hızlı bir şekilde üretilmesi gibi konular işletmeler için gün geçtikçe artan bir öneme sahip olmaktadır [1-3].

Denim ürünlerindeki sade görünüm yerine bu kumaşlara tarz kazandırmak için lazer makinesiyle “Bıyık Deseni” çizilir. Bıyık deseni, denim kumaşları üzerine çizilen koyu motiflerin birleştirilmiş görüntüsüdür. Bu desenler, kumaşa farklı bir tarz katmaktadır. Üretilen sade denim kumaşları üzerine bıyık motiflerinin aktarılabilmesi için lazer makinesiyle yakma işlemi yapılır.

Bıyık desen görüntüsünün denim kumaşı üzerine kazınma işlemi 4 aşamadan oluşmaktadır. Bu aşamalar: bıyık desen oluşturulması, desenin zemin üzerine aktarılması, denim kumaşının desenle aynı koordinatlara gelecek şekilde serilmesi ve lazer cihazıyla yakma işlemidir. Bu aşamaların görsel hali **Şekil 1**'de gösterilmektedir.



Şekil 1. Lazer kazıma makinesi ile denim kumaşı üzerine aşamalı bıyık desen çizimi [4].

Lazer kazıma makinesine girdi olarak verilecek bıyık desen görüntüleri için ya yeni bir tasarım yapılırsa veya hazır bir numuneden (bıyıklı denim kumaşı) bıyık efekti çıkarılmaktadır. Bu nedenle işletmede Photoshop gibi görsel düzenleme programlarında uzmanlaşmış personellere ihtiyaç duyulmaktadır. Uzmanların bir bıyık desen görselini inşa edebilmesi için yaklaşık 2-3 saat süren bir çalışmaya ihtiyaç duyulur. Üretilen bıyık desen görselindeki küçük bir hata veya istenmeyen bir efekt ürüne yansıtacağından dolayı oldukça hassas bir işlem olduğu açıktır. **Şekil 2**'de örnek denim kumaşı ve bıyık desen görüntüsü gösterilmektedir.



Şekil 2. Örnek Denim kumaşı – Bıyık desen görselleri.

Bıyık deseninin manuel olarak üretimi yüksek maliyete sahip olduğu için bu çalışmada güncel Yapay öğrenme tekniklerinden olan ve literatürde sentetik görüntü üretiminde yüksek bir başarı sağlayan Çekişmeli üretici ağlar kullanıldı. Çekişmeli Üretici Ağlar (ÇÜA [5]), 2014 yılında ünlü matematikçi John Nash'in oyun teorisini baz alınarak geliştirilen ve iki ayrı ağı birbirleriyle çekişmeli olarak çalıştığı bir öğrenme yöntemidir. Ağlardan biri sentetik veri üretimini sağlarken diğeri üretilen verinin ne kadar gerçekçi olduğunu öğrenerek üretici ağı beslemeye çalışır. ÇÜA mimarileri ile ilgili literatürde pek çok çalışma bulunmaktadır. Bu çalışmalar; görüntü dönüşümü, çözünürlük artırma, stil aktarımı ve alanlar arası çeviri benzeri görüntü manipülasyonu işlemleridir [5-12].

Bu alandaki ilk çalışmalardan biri olan DCGAN [6] belirli bir kümedeki verilerin özniteliklerini öğrenerek benzer görüntüler sentezleyebilen evrimsel bir ÇÜA mimarisidir. Alandaki çalışmaların ilerlemesiyle birlikte 2015 yılında Ledig ve diğerleri tarafından geliştirilen SRGAN [7] mimarisi yüksek kalitede görüntü üretiminde önemli başarımlar elde etmiştir. ÇÜA mimarilerinin bir görüntü alanından diğere çeviri işlemi yapabilmesi için koşullu versiyonları geliştirilmiştir. Bu mimarilerin ilklerinden bir tanesi Pix2Pix'tir [8]. Genel ÇÜA maliyet fonksiyonuna ek olarak L_1 metriğinin eklenmesiyle birlikte Pix2Pix mimarisi denetimli ikili alanlar arası görüntü dönüşümünde önemli bir rol oynamıştır. Denimsiz veri kümelerinde ikili alanlar arası dönüşüm yapabilmek için CycleGAN [9] mimarisi geliştirilmiştir. Ardından yüksek çözünürlükte görüntü üretimi için görüntüleri ölçekleyerek aşamalı bir şekilde öğrenen Progressive GAN [10] mimarisi geliştirilmiştir. Bir görüntüdeki stilin bir içerik görüntüsüne aktarabilen StyleGAN [11] mimarisi 2018 yılında geliştirilmiştir. ÇÜA mimarilerinin çeşitlenmesiyle birlikte dikkat mekanizmaları geliştirilmeye başlandı. Bu alandaki öncü mimarilerinden bir tanesi de Zhang ve diğerleri tarafından geliştirilen, konumsal dikkat ve spektral normalleştirme tabanlı, SAGAN [12] mimarisidir. Sentetik görüntü üretiminde, özellikle de yüksek çözünürlükte, üretim yapılırken çeşitliliğin ve kalitenin artmasını sağlayan BigGAN [13] mimarisi, ikili filtreler arasındaki normları kısıtlamadan kosinüs benzerliğini kullanır. Nvidia tarafından geliştirilen Pix2PixHD [14] mimarisi ile yüksek çözünürlükte anlamsal harita tabanlı görüntü çevirisi sağlanabiliyorken, üretici ağı kod çözücü kısmına mekânsal uyarlanabilir normalleştirme özelliği dahil edilerek SPADE [15] geliştirilmiştir. Çeşitli içerik üretimine farklı bir bakış açısı

getiren MixNMatch [16] mimarisi, içerik, şekil ve poz gibi görsellerin kullanıcı tarafından alınımına olanak sağlamaktadır. Wang ve diğerleri tarafından geliştirilen GFP-GAN [17] mimarisi ile insan yüzüne ait eski görüntülerin renkli, kaliteli ve gürültüsüz bir biçimde sentezlenmesini sağlamaktadır. StyleGAN [11] mimarilerindeki döndürme ve öteleme gibi temel rotasyon işlemlerinden kaynaklanan sinyal probleminin çözümü için Fourier dönüşüm tabanlı StyleGAN3 [18] mimarisi geliştirilmiştir. 2021 yılında Suvorov ve diğerleri tarafından, ana yapıyı bozmadan, görüntüler üzerindeki istenmeyen bölgelerin veya nesnelere kaldırarak görüntü sentezleyebilen LaMa [19] mimarisi geliştirilmiştir. Doğal dil işleme alanında, çok başlıklı dikkat mekanizmalarına sahip, Transformer [20] mimarilerinin üstün başarılarından sonra araştırmacılar dikkatini bu alana çevirmiştir. Birçok araştırmacı bu mimarilerin ÇÜA mimarilerine uygulanarak dikkat mekanizmasının verimli kullanımı üzerine çalışmalar yapmışlardır [21-26]. Bu mimarilerin temel özelliği görüntünün eş parçalara bölündükten sonra doğrusal projeksiyonu alınıp konumsal bilgisiyle birlikte Transformer tabanlı kod çözücüyü aktarılmasıdır [21-26]. Elde edilen öznitelik vektörleri kodlayıcı ağına gönderilerek görüntü yeniden inşa edilir. Böylece sadece evrişimsel bloklardan oluşan ÇÜA mimarilerinin uzun süreli bilgiyi tutmada eksik kaldığı yönlerini kapatmada daha efektif yöntemler ortaya çıkmıştır.

Denim kumaşından otomatik bıyık desen üretimi üzerine daha önce yapılan çalışmalarda Baykan Denim A.Ş. [27] firmasının Malatya lokasyonundaki fabrikasından çekilen görüntülerden elde edilen 950 adet denim-bıyık görselleri veri kümesi kullanılmıştı [28,29]. Her ne kadar veri kümesindeki görüntülerin standart olmaması, aynı ortamda çekilmemesi ve arkaplan bozukluğu gibi problemlere sahip olsa da belirli bir oranda başarımlar sağlanmış ve bu çalışmanın temelleri atılmıştı. Bu çalışmada önceki çalışmalardan elde edilen tecrübeler ve Baykan Denim A.Ş. firmasının katkılarıyla yüksek çözünürlükte denim kumaş görüntülerinin çekimi yapılarak aynı zamanda firmadaki alanında uzman bıyık desen üretim ekibinin bu kumaşlara ait bıyık desenlerini çizmesiyle 589 adet 2048x1024 ebatlarında Denim2BıyıkHD veri kümesi inşa edilmiştir. Bu veri kümesi ile Pix2PixHD mimarisinin eğitimi yapılarak otomatik bıyık desen üretiminde %88 oranında başarımlar sağlanmıştır. Çalışmanın daha da ileri taşınması için hem mimari üzerinde hem de veri kümesi üzerinde çeşitli değişiklikler yapılarak yeni bir bıyık desen üretim yöntemi sunulmuştur. Bu önerilen yöntem ile denim kumaşından otomatik bıyık desen üretimi %92 oranında görüntü üretim başarımlarını sağlamıştır.

Çalışma da bölüm 2.1’de klasik yöntem, bölüm 2.2’de Pix2PixHD mimarisi ve bölüm 2.3’te Önerilen yöntem ile bıyık desen üretimi anlatılmıştır. Ardından bölüm 2.4’te Denim2BıyıkHD veri kümesinin hazırlanması, bölüm 2.5’te performans gösteriminde kullanılan görüntü karşılaştırma metrikleri, bölüm 3’te deneysel sonuçlar ve bölüm 4’te sonuç ve tartışmalar kısmı anlatılmıştır.

2. Materyal ve Metot

2.1. Klasik Yöntem ile Bıyık Deseni Üretimi


Bıyık deseni, Photoshop veya emsalleri ile hazırlanan ve denim kumaşından elde edilen ürünlerin üzerindeki beyaz veya grimsi desenleri içeren yüksek kalitedeki görselin üretimidir. Bıyık desen üretiminin talebi müşteriden gelir. Müşteri örnek bir denim kumaş (pantolon, etek, şort) örneği getirir ve firmadan getirilen ürün ile aynı desenlerden oluşan ürünler talep eder. Firma bu örnek denim kumaşını beyaz bir zemin veya görüntüleme kabinine serip yüksek çözünürlükte ön ve arka çekimlerini yapar. Elde edilen bu görseller Photoshop vb. görsel düzenleme programına aktarılır. Görsel düzenleme programları alanında uzman bir kişi bu görselin ilk önce renk spektrumlarını düzenler. Böylece kumaş üzerindeki desenlerin en belirgin halini almasını sağlar. Daha sonra Brush tool vb. araçları kullanarak kumaşın üstündeki parmak, üst geçiş ve rodeo gibi motifleri çizmeye başlar [27]. Her bir işlem yeniden düzenlenebilmesi için bir katman olarak kaydedilir. Tüm motifler çizildikten sonra motiflerin tamamı görünebilir ayarına alınarak kumaş üzerine aktarılıp gözlemlenir. Kumaşın kenarlarına doğru sert geçişler varsa yumuşatma yapılır. En son aşamada motiflerin tamamı tek bir katman da birleştirilip Bıyık desen görselini oluşturur. Bu görsel dışarıya aktarılıp uygun ayarlarda lazer cihazına gönderilir. Örnek numune üzerinde test edilir. Eğer müşteriden gelen örnek kumaşa yeterli derecede benzemiyorsa bıyık desen görseli yenilenip tekrar düzenlenir. Bu işlem kumaşın üzerindeki motiflerin karmaşıklığı, uzman kişinin el becerisi, kumaşın kalitesi ve rengi gibi parametrelere göre değişkenlik gösterir. Bu görsel birden fazla motif içerir. Ortalama bıyık desen görsel üretim süreci 2-3 saattir, eğer desen revize edilirse süre katlanarak artar. Bu yüzden hassas ve maliyetli bir işlemdir. Aynı zamanda uzman personel ihtiyacı doğurur. **Şekil 3**’te Photoshop programı üzerinde örnek bir denim kumaş ve bıyık desen görselinin hazırlanıp kumaş üzerine aktarılıp hali gösterilmektedir.



(a)



(b)



(c)

Şekil 3. Klasik yöntemle bıyık deseni üretimi. a) Denim kumaşı, b) Bıyık motifleri çizilen denim kumaş, c) Bıyık desen görseli.


2.2. PixPixHD Mimarisi ile Bıyık Desen Üretimi

Anlamsal görüntü haritalarından yüksek çözünürlükte gerçekçi görüntüler üretebilmek için Pix2PixHD [14] mimarisi 2018 yılında Wang ve diğerleri tarafından geliştirilmiştir. Pix2Pix [] tabanlı olarak geliştirilen bu mimari 2048x1024 boyutunda görüntü üretimi yapabilmektedir. Otomatik bıyık desen üretiminde bu mimarinin özellikle tercih edilme sebebi literatürde bulunan ÇÜA mimarilerindeki en yüksek kalitede koşullu görüntü üretimine

olanak sağlamasıdır. Diğer mimariler ne kadar daha güncel katmanlara ve modellere sahip olsalar bile boyut ve yüksek çözünürlükte koşullu görüntü üretimi için yetersiz kalmaktadır.

2.2.1. Üretici Ağ

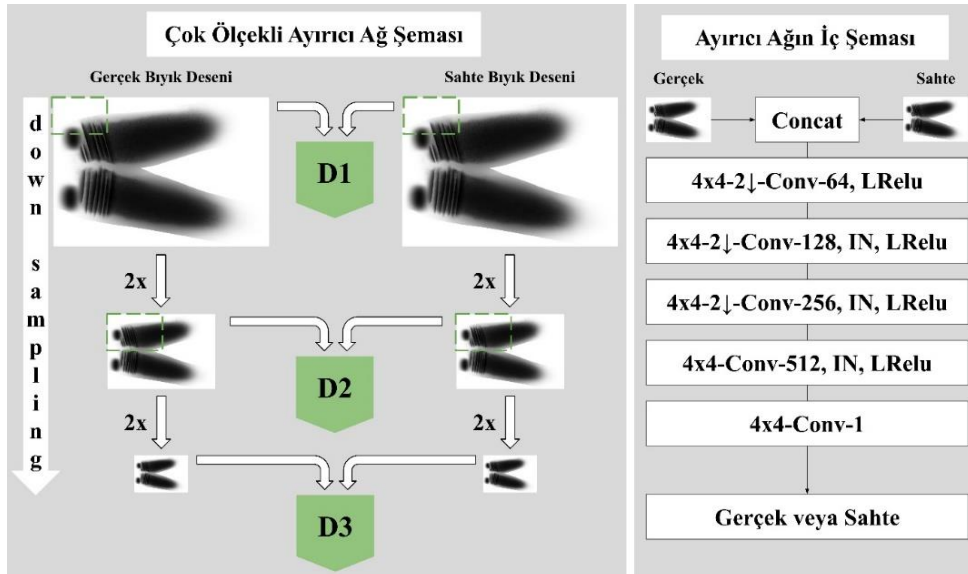
Pix2PixHD [14] mimarisi 2 üretici ağı (G1, G2) sahiptir. Bu ağlar birbiriyle etkileşimli olarak çalışmaktadır [5,14]. İlki küresel ağıdır (Global network = G1). Bu ağın temel görevi $2x$ küçültülmüş görüntünün X alanından Y alanına (Denim kumaşı → Bıyık deseni) dönüşümünü sağlamaktır. Ağın çalıştığı görüntü boyutu $1024x512$ 'dir. Görüntü kodlayıcı bloklardan işlendikten sonra 9 ayırık bloktan (residual blocks) geçerek kod çözücü bloklara aktarılır [14]. İkincisi yerel güçlendirici (Local enhancer = G2) ağıdır. Bu ağın temel görevi yüksek çözünürlüklü ($2048x1024$) görüntü üretimidir. Ağ görüntüleri kodlayıcı bloklardan geçirdikten sonra küresel ağın çıktısı ile birleştirir. Ardından bu çıktılarının birleşimini 3 ayırık bloklarda (residual blocks) işleyerek kod çözücü bloklara aktarır ve böylece yüksek çözünürlüklü görüntü üretimi sağlanmış olur. Yerel güçlendirici ağ ile eğitim yapılabilmesi için öncelikle küresel ağın eğitilmesi lazımdır. Bu ağların temel şeması Şekil 4'de gösterilmektedir.



Şekil 4. Pix2PixHD mimarisinin üretici ağ şeması.

2.2.2. Ayırıcı Ağ

Yüksek çözünürlüklü görüntü üretimindeki temel problemlerden biride ağın görüntüdeki detayları atlayabilmesidir. Ağın detaylara odaklanabilmesi için görüntüyü farklı ölçeklerde inceleyebilmesi gerekir. Bu yüzden Pix2PixHD mimarisinin ayırıcı ağı çok ölçekli PatchGAN mimarisi kullanmaktadır [14]. Ayırıcı ağ gerçek ve üretici ağ tarafından üretilen sahte görüntüyü 3 farklı ölçekte ($D1$, $D2$ ve $D3$) değerlendirmektedir. Herbir ölçekte görüntülerin $2x$ küçültülmüş formunun bir parçası ayırıcı ağına verilmektedir. Böylece ayırıcı ağ görüntünün hem genel hatlarına hemde iç hatlarına odaklanabilmektedir. Ayırıcı ağın temel çalışma mekanizması Şekil 5'te verilmektedir.



Şekil 5. Pix2PixHD mimarisinin ayırıcı ağ şeması.

2.2.3. Maliyet Fonksiyonları

Pix2PixHD mimarisinin üretici ağ maliyeti 3 ayrı kayıptan oluşur. Bunlar tartışmalı (adversarial), özellik eşleştirme (feature matching) ve algısal (perceptual) kayıplardır [14]. Algısal kayıpta VGG [14] ağı kullanılmaktadır. Ayırıcı ağın maliyet fonksiyonu tartışmalı kayıp tabanlıdır.

Üretici Ağ Maliyeti:

Tartışmalı kayıp, üretici ağ tarafından sentezlenen görüntünün (y) ayırıcı ağa verilir elde edilen çıktısı ile aynı boyuttaki 1'lerden oluşan vektör arasında hesaplanır. Bu işlem birler vektörü ile sahte görüntü arasındaki piksel farkının karesi alınarak hesaplanır. Bu hesaplamanın formülü Denklem 1'de verilmiştir.

$$\mathcal{L}_{adv} = (1 - D(y))^2 \quad (1)$$

Özellik eşleştirme kaybı, üretici ağdan gelen sentezlenmiş (y) ile gerçek (x) görüntülerinin ayırıcı ağa verilerek elde edilen özellik haritalarının L_1 metriği ile karşılaştırmasıyla hesaplanır. Bu işlem Denklem 2'de gösterilmektedir. Denklemdeki T değeri ayırıcı ağdaki özellik katmanlarının toplam sayısını vermektedir.

$$\mathcal{L}_{FM} = \sum_{i=1}^T L_1(D(x_i) - D(y_i)) \quad (2)$$

Algısal kayıp, üretici ağdan gelen sentezlenmiş (y) ile gerçek (x) görüntülerinin özellik çıkartıcı ağa (VGG) verilerek elde edilen özellik haritalarının L_1 metriği ile karşılaştırmasıyla hesaplanır. Bu işlem Denklem 3'de gösterilmektedir. Denklemdeki T değeri özellik çıkartıcı ağdaki kullanılan katmanların toplam sayısını vermektedir.

$$\mathcal{L}_{perceptual} = \sum_{i=1}^T L_1(Vgg(x_i) - Vgg(y_i)) \quad (3)$$

Üretici ağın toplam kayıp fonksiyonu Denklem 4 gibi tanımlanır. Denklemdeki λ değerleri orijinal çalışmada 10 olarak alınmıştır.

$$\mathcal{L}_G = \lambda_1 * \mathcal{L}_{adv} + \lambda_2 * \mathcal{L}_{FM} + \lambda_3 * \mathcal{L}_{perceptual} \quad (4)$$

Ayırıcı Ağ Maliyeti:

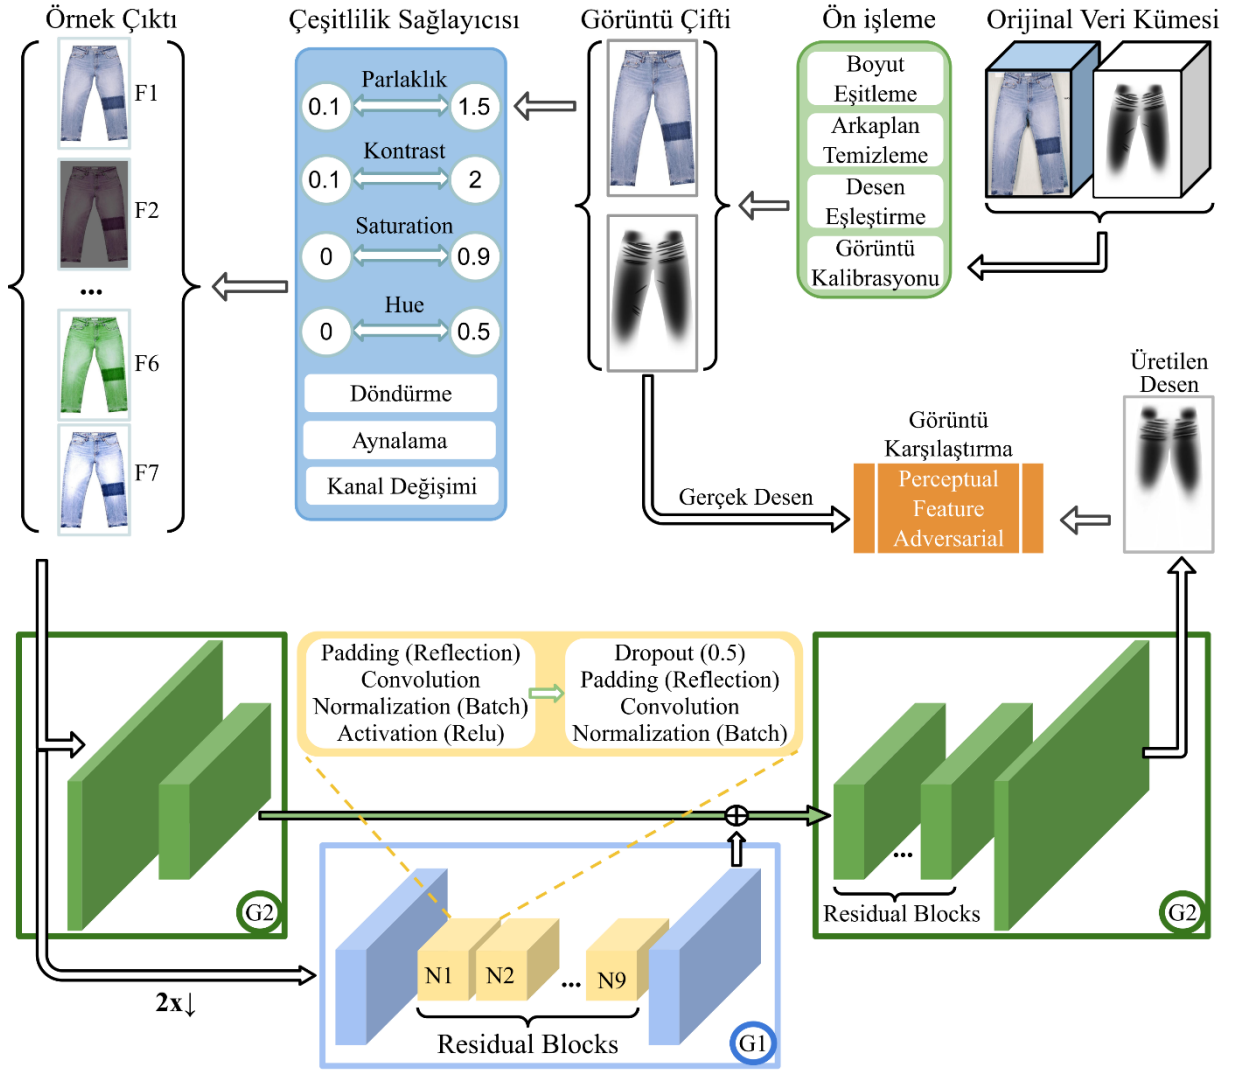
Ayırıcı ağın maliyeti tartışmalı kayıp üzerine kurulmuştur. Bu işlemde birler vektörü ile gerçek (x) görüntü arasındaki piksel farkının karesi alınır. Ardından sıfırlar vektörü ile sentezlenen görüntü (y) arasındaki piksel farkının karesi alınır. Bu iki işlem sonucunun toplamı ayırıcı ağın maliyetini vermektedir. İşlemin formülü Denklem 5'te gösterilmektedir.

$$\mathcal{L}_D = (1 - D(x))^2 + (0 - D(y))^2 \quad (5)$$

2.3. Önerilen Yöntem (Pix2PixHD++) ile Büyük Desen Üretimi

Çekişmeli üretici ağlar, görüntü manipülasyon ve dönüşüm işlemlerinde çok güçlü olmalarına rağmen iki problem alanından yüksek oranda olumsuz etkilenirler [5-16]. İlki bir ÇÜA mimarisinin çok iyi öğrenebilmesi için yüksek oranda standartlaştırılmış veri gerekir eğer veri miktarı az ise model aşırı öğrenmeye ya da bozuk veri üretimine sebep olur. İkincisi görüntü üzerindeki renk, parlaklık ve kontrast gibi efektlerden kaynaklanan değişimlerden ciddi derecede olumsuz etkilenir. Bu iki problemin belirli bir oranda indirgenmesi için Pix2PixHD mimarisi üzerine çeşitli eklentiler yapılmıştır. İlk aşamada hazırlanan orijinal veri kümesindeki her bir görüntü çifti, ön işleme aşamasından geçirilerek, denim kumaş ve büyük desen çiftlerinin desen eşleştirme, boyut eşitleme, arkaplan temizliği ve görüntü kalibrasyonu yapılmıştır. Böylece veri kümesinde standartlaştırma sağlanmıştır. İkinci aşamada modelin hem aşırı öğrenme problemini ortadan kaldırmak hem de görüntü değişim (parlaklık, kontrast, renk, pozlama, döndürme) efektlerine karşı direncini artırmak için çeşitlilik sağlayıcısı adında bir yazılımsal yöntem eklenmiştir. Bu yöntem, görüntü çiftinin büyük desen görseline karışmadan sadece denim kumaş üzerinde değişimler yaparak üretici ağa girdi olarak vermektedir. İlk önce parlaklık, kontrast (zıtlık), saturation (doygunluk) ve hue renk değerlerinden belirli aralıklarda rastgele bir değer uygulanıp ardından eğitim aşamasındaki iterasyonlarla birlikte döndürme, aynalama ve kanal değişimi yapılmaktadır. Her bir orijinal denim görüntüsü ile altı farklı değişimden geçirilmiş versiyonuyla tek bir büyük deseni eşleştirecek şekilde eğitim yapılmaktadır. Böylece model görüntüdeki dış ortam veya kamera çekimlerinden kaynaklanan efektlerden etkilenmeyecektir. Üçüncü aşamada ağın aşırı öğrenmesini engellenmesi için üretici ağın öznelikleri taşıdığı orijinal dokuz ayrı blok (residual blocks) ek olarak DropOut katmanı eklenmiştir. Son aşamada üretici ağın

ürettiği desen ile orijinal bıyık deseni üç ayrı maliyet fonksiyonuyla karşılaştırılıp elde edilen maliyet değeri üretici ve ayırıcı ağlara geri besleme olarak verilmektedir. Önerilen yöntemin ana şeması **Şekil 6**'da gösterilmektedir.



Şekil 6. Pix2PixHD++ mimarisinin ana şeması.

2.4. Denim2BıyıkHD: Yüksek Çözünürlüklü Denim-Bıyık Deseni Veri Kümesi

Denim-Bıyık deseni görüntülerinden oluşan Denim2Bıyık veri kümesi daha önceki çalışmalarda 976 görüntü çifti içerecek şekilde hazırlanmıştı [28,29]. Bu veri kümesinin belirli bir standartta olmadığı için görüntü üretiminde yeterli kalitede başarımlar sağlanamadı. Veri kümesininin üzerinde çeşitli düzenlemeler ile 950 görüntü çiftine indirgenerek belirli bir standartlaştırma seviyesine çıkartılmıştı [29]. Bu görüntülerin 256x256x3 ebatlarında olması ve belirli standartlarda çekimlenmemesinden dolayı yüksek çözünürlüklü görüntü üretiminde kullanılması uygun değildir. Yüksek çözünürlüklü bıyık desen üretiminde kullanılacak veri kümesi için Baykan Denim [27] firmasının İstanbuldaki üretim fabrikasından 589 denim kumaş görüntüsü elde edilmiştir. Bu görüntüler aynı koşullar (çözünürlük, ışık dağılımı, çekim ortamı, kamera, v.b) altında çekimlenmiştir. Görüntülerdeki bıyık desen görselleri firmanın Malatya lokasyonundaki üretim fabrikasında bir uzman personel tarafından Photoshop programı ile hazırlanmıştır. Nihai durumda 589 denim-bıyık görüntü çifti elde edilmiştir. Bu görsellerin ÇÜA mimarileri işlenebilmesi için Photoshop ve OpenCV programları ile görüntüler üzerinde çeşitli düzenlemeler (döndürme, arkaplan rengi, boyut, bölgesel eşleşme, renk ayarları, v.b) yapılmıştır. Veri kümesinin yeni formunda 512p (1024x512x3) ve 1024p (2048x1024x3) versiyonları mevcuttur. Veri kümesinden örnek birkaç denim kumaşı ve bıyık deseni çifti **Şekil 7**'de gösterilmektedir. Bu veri kümesinin (Denim2BıyıkHD) en büyük özelliği yüksek çözünürlükte standartlaştırılmış olarak hazırlanmasıdır.



Şekil 7. Denim2BıyıkHD veri kümesinden örnek görüntüler.

2.5. Görüntü Üretim Performansı Karşılaştırma Metrikleri

Bu bölümde denim kumaşından otomatik üretilen bıyık desen görüntülerinin gerçek desenlerle karşılaştırılmasında kullanılan görüntü karşılaştırma metrikleri anlatılmıştır.

2.5.1. SSIM

SSIM, yapısal benzerlik hesaplaması için standart sapma (σ) ve ortalama (μ) gibi verinin temel değerlerini kullanan istatistiksel bir benzerlik metriğidir. Bu karşılaştırmada maskeleyme, parlaklık ve kontrast gibi önemli sayısal özelliklerle birlikte görüntüdeki içeriksel değişiklikte hesaplamaya dahil edilir [30]. Gerçek (x) ve sentezlenen (y) görüntüsü için yapısal benzerlik formülasyonu Denklem 6 gibi ifade edilmektedir. Bu denklemdeki μ_x ve μ_y değerleri gerçek ve sentezlenmiş görüntünün piksel ortalamasını, σ_x^2 ve σ_y^2 varyansını, σ_{xy} kovaryansı belirtmektedir. Ek olarak $c_1 = (k_1L)^2$ ve $c_2 = (k_2L)^2$ değerleri sabittir ve piksel aralığı için L değeri 255 alınarak hesaplanır.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (6)$$

2.5.2. MSE

İki görüntü arasındaki benzerlik hesaplaması için piksel bazında karşılaştırma yapan temel metriklerden biridir [31]. Bu metriğe ait formülasyon Denklem 7 gibi ifade edilir. Bu denklemde gerçek ve sentezlenen görüntü arasındaki piksel farklarının kareleri alınarak toplanır. Ardından elde edilen sonuç piksel sayısına (n) bölünerek ortalaması alınır. İki görüntü arasındaki benzerliğin yüksek olması sonuç değerinin düşük olmasına bağlıdır.

$$L_2 = MSE(x, y) = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (7)$$

2.5.3. PSNR

Bir sinyaldeki olası maksimum gücü ve onun temsil ettiği doğruluğu olumsuz etkileyen güç (Örneğin: gürültü) arasındaki oranı hesaplamak için kullanılan logaritmik hesaplamalı bir metriktir [32]. Bu sinyal, gerçek görüntü ya da veri bloğudur ve olumsuz etkileyen etkende verideki bozulma veya sıkıştırılmadan kaynaklı hatadır. İki veri bloğu arasındaki bu oran farklılığı desibel olarak hesaplanır. Bu metriğin formülasyonu Denklem 8 gibi ifade edilmektedir. Denklemdeki gerçek ve sentezlenen görüntü arasındaki benzerlik için L_2 değeri hesaplanır. Ardından gerçek görüntüdeki maksimum piksel değeri (MAX_x^2) hesaplamaya dahil edilir. Sonucun yüksek olması sentezlenen görüntüdeki içeriğin ne kadar çeşitli ve kaliteli olduğunu gösterir.

$$PSNR(x, y) = 10 * \log_{10} \left(\frac{MAX_x^2}{L_2(x, y)} \right) \quad (8)$$

3. Deneysel Sonuçlar

Denim2BıyıkHD veri kümesinin eğitim işlemi RTX 2080 Titan ekran kartına sahip bir sunucuda gerçekleştirilmiştir. 200 iterasyon gerçekleşen eğitim işlemi 4352 cuda çekirdeği üzerinde yaklaşık olarak 40 saat sürmüştür. Eğitim işlemi part boyutu (batch size) 1 alınarak ve Adam optimizer kullanılarak yapılmıştır. Eğitim ve test işlemleri için Python programlama dili ve PyTorch kütüphanesi kullanılmıştır. Veri kümesi %90 eğitim ve %10 test olarak bölümlenmiştir. Küresel üretici ağlarında 9 aylık blok (residual) kullanılmıştır. Ayrıcı ağı 3 ölçekli olacak şekilde ayarlanmıştır. Ana seçeneklerde yükleme boyutu (load size) 1024, ince boyut (fine size) 512 ve etiket kanal sayısı (label channel size) 0 seçilmiştir. Pix2PixHD ve önerilen yöntem (Pix2PixHD++) modelleri eşit koşullar altında eğitilmiştir.

Üretilen görsellerin performans karşılaştırmasında; yapısal benzerlikte SSIM, piksellerdeki sinyal gücü tespitinde PSNR ve piksel farklılık maliyetinde MSE yöntemi kullanılmıştır. Mimarilerin eğitim ve test işlemlerindeki başarımlarını **Çizelge 1**'de gösterilmektedir.

Çizelge 1. Mimarilerin, Denim2BıyıkHD veri kümesinin eğitim ve test aşamasındaki performans sonuçları.

| Model Adı | Aşama | Metrik Adı (Benzerlik) | | |
|-------------------------------|--------|------------------------|--------------|---------------|
| | | SSIM ↑ | PSNR ↑ | MSE ↓ |
| Pix2PixHD | Eğitim | 0.91 | 21.15 | 440.26 |
| Pix2PixHD++ (Önerilen Yöntem) | Eğitim | 0.98 | 34.01 | 46.888 |
| Pix2PixHD | Test | 0.88 | 17.59 | 805.41 |
| Pix2PixHD++ (Önerilen Yöntem) | Test | 0.92 | 22.18 | 460.15 |

Eğitim aşamasında Pix2PixHD mimarisinin yüksek çözünürlüklü bıyık desen görsellerini %91 oranında başarıyla ürettiği gözlemlenirken, bu modelde yapılan değişikliklerle birlikte önerilen Pix2PixHD++ mimarisinin %98 oranında başarımlarını gösterdiği görülmektedir. Test aşamasında klasik Pix2PixHD modeli %88 başarımlarını gösterirken önerilen yöntemin %92 oranında yapısal olarak otomatik bıyık desen üretimi sağladığı görülmektedir. Ancak eğitim ile test aşamalarındaki çıktılar henüz aynı kalitede üretilmediği görülmektedir. Bu problem, Denim2BıyıkHD veri kümesindeki örnek sayısının yetersiz olmasından kaynaklanmaktadır. Veri kümesindeki örnek sayısı artırılırsa test aşamasındaki görüntü üretim kalitesi de artacaktır. Eğitim tamamlandıktan sonra önerilen yöntem (Pix2PixHD++) ile görsel test sonuçları elde edilmiştir. Denim2BıyıkHD veri kümesinin eğitim ve test kümelerindeki örneklerin bıyık deseni üretim sonuçları **Şekil 8-9**'da gösterilmektedir. İlki eğitim ikincisi test kümesindeki üretim sonucudur. Şekillerde sırasıyla ilk sütün: denim kumaşı, ikinci sütün: gerçek bıyık deseni, üçüncü sütün: üretim sonucunu göstermektedir.

Klasik Pix2PixHD mimarisi ile önerilen yöntemin (Pix2PixHD++) denim kumaşı üzerindeki parlaklık, kontrast ve renk gibi değişimlerden nasıl etkilendiğini gösteren test sonuçları **Şekil 10**'da gösterilmektedir. Bu şekilde test veri kümesinden alınan 2 örnek denim kumaşı çeşitlilik sağlayıcısından geçirilerek elde edilen 6 farklı görünümdeki imajlarıyla birlikte her iki ağa verilmektedir. Şekilde de görüldüğü gibi klasik model (Pix2PixHD) görüntü üzerindeki değişimlerden ciddi derecede etkilenirken önerilen (Pix2PixHD++) modelin değişimlerden neredeyse hiç etkilenmeyerek orijinal numunedeki görselle aynı çıktıyı vermektedir.



Şekil 8. Denim2BıyıkHD veri kümesinin eğitim setindeki üretim sonuçları (Denim kumaşı, Gerçek bıyık deseni, Pix2PixHD++ üretim sonucu).



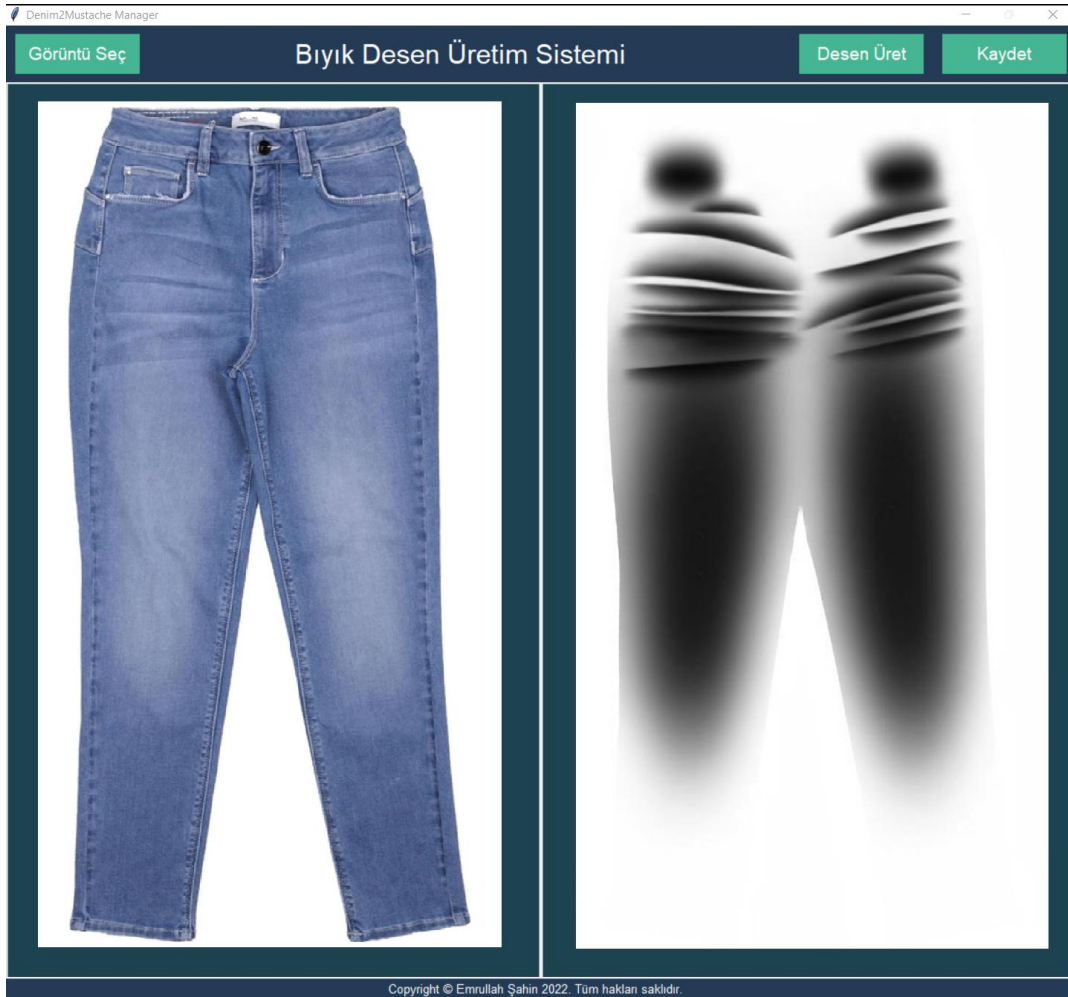
Şekil 9. Denim2BıyıkHD veri kümesinin test setindeki üretim sonuçları (Denim kumaşı, Gerçek bıyık deseni, Pix2PixHD++ üretim sonucu).

| Denim Kumaş | Gerçek Bıyık Deseni | Pix2PixHD | Pix2PixHD++ | Denim Kumaş | Gerçek Bıyık Deseni | Pix2PixHD | Pix2PixHD++ |
|---|---|---|---|---|--|---|---|
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |  |

Şekil 10. Pix2PixHD ve önerilen (Pix2PixHD++) mimarilerin, çeşitlilik sağlayıcısından elde edilen, 2 örneğe ait bıyık desen üretim sonuçları.

3.1. Bıyık Deseni Üretim Yazılımı

Bıyık desen üretimiyle ilgili tüm çalışmalar manuel üretim üzerinedir. Literatürde yapılan araştırmalar neticesinde herhangi bir otomatik bıyık desen üretim yazılımına rastlanmamıştır. Geliştirdiğimiz bu ürünle firmaya değiştirilebilir derin öğrenme çekirdeğine sahip bir sistem geliştirilmiştir. Bıyık deseni üretim sisteminin arayüzü kullanıcı dostu ve temel bir yapıya sahiptir. İlk adımda “Görüntü Seç” butonuna tıklayarak istediğimiz denim ürünü (pantolon, şort, etek) seçiyoruz. İkinci adımda “Desen Üret” butonuna tıkladığımızda, 2048x1024 gibi yüksek çözünürlükte bıyık desen görselinin sentezlenmesi yapılır. Son adımda “Kaydet” butonuna tıklayarak desen görselinin Jpg formatında kaydı sağlanır. Bu yazılımsal ürün masaüstü uygulaması olarak geliştirilmiştir. Derin öğrenme çekirdeği önerilen (Pix2PixHD++) mimarinin eğitilmiş model dosyalarını içermektedir. Ürünün desen üreten ana çekirdeği (ÇÜA modeli) zamanla daha iyi eğitilip değiştirilebilir. Bu değişiklik için herhangi bir yazılımsal değişiklik gerektirmez sadece yeni modelin çekirdeği programın kurulduğu klasörün altındaki “models” klasörünün içine aktarılması yeterlidir. En karmaşık motiflere sahip denim kumaşından bile yaklaşık 1 saniyede ve ortalama %92 doğrulukla bıyık desen görseli üretimi yapılır. Bıyık deseni üretim yazılımı **Şekil 11**'de gösterilmektedir.



Şekil 11. Otomatik Bıyık Deseni Üretim Yazılımı.

4. Sonuç ve Tartışma

Bu çalışmada, yüksek çözünürlükte görüntü üretimi yapan Pix2PixHD ve Pix2PixHD++ mimarisi ile denim kumaşından otomatik bıyık desen üretimi gerçekleştirilmiştir. Denim2Bıyık veri kümesinin yüksek çözünürlükteki versiyonu olan Denim2BıyıkHD veri kümesi hazırlanmıştır. Veri kümesinin yeni formu 589 adet yüksek çözünürlüklü standartlaştırılmış denim-bıyık desen çiftini içermektedir. Bu çalışma ile yüksek kalitede bıyık desen üretimi için önemli bir adım atılmıştır. Hem zamansal maliyet olarak 1 saniyenin altında üretim hızı sağlanmış hemde yüksek kalitede bıyık desen üretimi (yaklaşık %92 oranında) gerçekleştirilmiştir. Aynı zamanda denim kumaşından otomatik bıyık desen üretimi yapan yazılımsal bir program geliştirilmiştir. Yapılan çalışmalar neticesinde, denim-bıyık dönüşüm probleminin üretken ağ temelli mimariler kullanılarak başarılı bir şekilde çözülebildiği, önerilen özgün üretken ağ mimarisinin eşleştirme doğrulukları göz önüne alındığında ümit verici

çıktıların elde edildiği görülmektedir. İlerleyen çalışmalarda hem veri kümesinde hemde mimaride geliştirmeler sağlanırsa denim kumaşından otomatik büyük desen üretim probleminin tamamen çözüleceği öngörülmektedir. Bu tarz çalışmaların devam etmesiyle birlikte önümüzdeki yıllarda endüstriyel problemlerin çözümlerinde yapay öğrenme yaklaşımlarının artan bir ivmeyle kullanılacağı öngörülmektedir.

Teşekkür

Bu çalışma Baykan Denim A.Ş. ve İnönü Üniversitesi Bilimsel Araştırma Projeleri Birimi (BAP) tarafından “FKP-2021-2144” proje numarasıyla desteklenmektedir. Baykan Denim A.Ş. ve İnönü Üniversitesine bu destekleri için teşekkür ederiz.

Kaynakça

- [1] Zou, X., Wong, W. K., & Mo, D. (2018). Fashion Meets AI technology. In *International Conference on Artificial Intelligence on Textile and Apparel* (pp. 255-267). Springer, Cham.
- [2] Jucienė, M., Urbelis, V., Juchnevičienė, Ž., & Čepukonė, L. (2014). The Effect of Laser Technological Parameters on The Color and Structure of Denim Fabric. *Textile Research Journal*, 84(6), 662-670.
- [3] Zhong, T., Dhandapani, R., Liang, D., Wang, J., Wolcott, M. P., Van Fossen, D., & Liu, H. (2020). Nanocellulose from Recycled Indigo-dyed Denim Fabric and Its Application in Composite Films. *Carbohydrate Polymers*, 240, 116283.
- [4] Golden Laser. (2022). Jeans Laser Engraving Machine. Retrieved from: <https://www.goldenlaser.cc/jeans-laser-engraving-machine.html>, erişim tarihi: 10 Ağustos 2022.
- [5] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative Adversarial Nets. *Advances in neural information processing systems*, 27.
- [6] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [7] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2016). 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).
- [8] Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1125-1134).
- [9] Zhu, J. Y., Park, T., Isola, P., & Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. In *Proceedings of the IEEE international conference on computer vision* (pp. 2223-2232).
- [10] Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). Progressive growing of gans for improved quality, stability, and variation. *arXiv preprint arXiv:1710.10196*.
- [11] Karras, T., Laine, S., & Aila, T. (2018). A style-based generator architecture for generative adversarial networks. *arXiv preprint arXiv:1812.04948*.
- [12] Zhang, H., Goodfellow, I., Metaxas, D., & Odena, A. (2018). Self-attention generative adversarial networks. In *International conference on machine learning* (pp. 7354-7363). PMLR.
- [13] Brock, A., Donahue, J., & Simonyan, K. (2018). Large scale GAN training for high fidelity natural image synthesis. *arXiv preprint arXiv:1809.11096*.
- [14] Wang, T. C., Liu, M. Y., Zhu, J. Y., Tao, A., Kautz, J., & Catanzaro, B. (2018). High-resolution image synthesis and semantic manipulation with conditional gans. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8798-8807).
- [15] Park, T., Liu, M. Y., Wang, T. C., & Zhu, J. Y. (2019). Semantic image synthesis with spatially-adaptive normalization. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 2337-2346).
- [16] Li, Y., Singh, K. K., Ojha, U., & Lee, Y. J. (2020). Mixnmatch: Multifactor disentanglement and encoding for conditional image generation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 8039-8048).
- [17] Wang, X., Li, Y., Zhang, H., & Shan, Y. (2021). Towards Real-World Blind Face Restoration with Generative Facial Prior. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 9168-9178).
- [18] Karras, T., Aittala, M., Laine, S., Härkönen, E., Hellsten, J., Lehtinen, J., & Aila, T. (2021). Alias-free generative adversarial networks. *arXiv preprint arXiv:2106.12423*.
- [19] Suvorov, R., Logacheva, E., Mashikhin, A., Remizova, A., Ashukha, A., Silvestrov, A., ... & Lempitsky, V. (2021). Resolution-robust Large Mask Inpainting with Fourier Convolutions. *arXiv preprint arXiv:2109.07161*.
- [20] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

- [21] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- [22] Zheng, S., Lu, J., Zhao, H., Zhu, X., Luo, Z., Wang, Y., ... & Zhang, L. (2021). Rethinking semantic segmentation from a sequence-to-sequence perspective with transformers. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 6881-6890).
- [23] Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., ... & Zhou, Y. (2021). Transunet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.
- [24] Hatamizadeh, A., Tang, Y., Nath, V., Yang, D., Myronenko, A., Landman, B., ... & Xu, D. (2022). Unetr: Transformers for 3d medical image segmentation. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 574-584).
- [25] Wang, W., Chen, C., Ding, M., Yu, H., Zha, S., & Li, J. (2021, September). Transbts: Multimodal brain tumor segmentation using transformer. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 109-119). Springer, Cham.
- [26] Hatamizadeh, A., Nath, V., Tang, Y., Yang, D., Roth, H., & Xu, D. (2022). Swin unetr: Swin transformers for semantic segmentation of brain tumors in mri images. *arXiv preprint arXiv:2201.01266*.
- [27] Baykan Denim A.Ş. (2022). Baykan Denim A.Ş. firmasının resmi web site adresi. Retrieved from: <https://www.baykandenim.com/home-page/>, erişim tarihi: 11 Ağustos 2022.
- [28] Şahin, E., & Talu, M. F. (2022) Automatic Mustache Pattern Production on Denim Fabric with Generative Adversarial Networks. *Computer Science*, 7(1), 1-9.
- [29] Şahin, E., & Talu, M. F. (2021). Bıyık Deseni Üretiminde Çekişmeli Üretici Ağların Performans Karşılaştırması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 10(4), 1575-1589.
- [30] Nilsson, J., & Akenine-Möller, T. (2020). Understanding ssm. *arXiv preprint arXiv:2006.13846*.
- [31] Mihelich M., Dognin C., Shu Y., Blot M. (2020). A Characterization of Mean Squared Error for Estimator with Bagging. *ArXiv, abs/1908.02718*.
- [32] Fardo F A., Conforto V H., Oliveira F C., Rodrigues P. (2016). A Formal Evaluation of PSNR as Quality Measurement Parameter for Image Segmentation Algorithms. *ArXiv, abs/1605.07116*.