

# Regenerating Modern Interiors into Science Fiction Environments via Cycle-GAN

Esra Yağdır Çeliker<sup>1</sup>, Gizem Efendioğlu<sup>2</sup>, Özgün Balaban<sup>3</sup>

0000-0002-1817-3829<sup>1</sup>, 0000-0002-0586-6167<sup>2</sup>, 0000-0002-7270-2058<sup>3</sup>

<sup>1</sup>Istanbul Bilgi University, Faculty of Architecture, Department of Architecture, Istanbul, Turkey

<sup>2</sup>Özyeğin University, Faculty of Architecture and Design, Department of Architecture, Istanbul, Turkey

<sup>3</sup>Delft University of Technology, Faculty of Architecture and the Built Environment, Chair of Design Informatics. Delft. Netherlands

Deep learning is a machine learning method that uses artificial neural networks for complex tasks and problems that require the processing of large data sets. Deep learning has shown that it is possible to process the properties of the data that previously needed to be transferred to the computer by an expert person, only by a computer. Generative Adversarial Networks (GAN) algorithm, one of the subsystems of deep learning, takes advantage of the contention of two neural networks working opposite each other. While the Generator produces fake images, the Discriminator evaluates the images and generates the information that the image is fake or real. This contentious situation between two networks repeats until the Discriminator cannot distinguish the image is fake. For this reason, researchers prefer to use the GAN especially in image processing and image translation problems. With the image processing techniques offered by deep learning, it is possible to process complex spatial data and to reproduce spatial fictions through images. The study aims to investigate the new spatial potentials of interior spaces with different characteristics. In this context, modern interiors are reinterpreted as dystopic science fiction spaces by using the GAN algorithm, which is a suitable technique for image processing. In this study, we created two different data sets from modern interior photographs and science fiction movies. Thus, we tried to investigate how modern interiors can change morphologically when they become a part of science fiction movies.

**Received:** 24.08.2020

**Accepted:** 27.09.2020

**Corresponding Author:**

yagdir.celiker@bilgi.edu.tr

Çeliker, Y. E., Efendioğlu, G., Balaban, Ö. (2020). Regenerating Modern Interiors into Science Fiction Environments via Cycle-GAN, JCoDe: Journal of Computational Design, 1(3), 71-94.

**Keywords:** Cycle-GAN, Deep Learning, Machine Learning, Spatial Image Processing, Artificial Intelligence in Architecture.

# Cycle-GAN ile Modern İç Mekânların Bilim Kurgu Ortamları Olarak Yeniden Üretilmesi

Esra Yağdır Çeliker<sup>1</sup>, Gizem Efendioğlu<sup>2</sup>, Özgün Balaban<sup>3</sup>

0000-0002-1817-3829<sup>1</sup>, 0000-0002-0586-6167<sup>2</sup>, 0000-0002-7270-2058<sup>3</sup>

<sup>1</sup>İstanbul Bilgi Üniversitesi, Mimarlık Fakültesi, Mimarlık Bölümü İstanbul, Türkiye

<sup>2</sup>Özyeğin Üniversitesi, Mimarlık ve Tasarım Fakültesi, Mimarlık Bölümü, İstanbul, Türkiye

<sup>3</sup>Delft University of Technology, Faculty of Architecture and the Built Environment, Chair of Design Informatics, Delft, Netherlands

Derin öğrenme, karmaşık görevlerin ve büyük veri setlerinin işlenmesi gereken problemlerde, yapay sinir ağlarını kullanan bir makine öğrenmesi yöntemidir. Derin öğrenme ile daha önceden uzman bir insan tarafından bilgisayara aktarılması gereken veriye ait özelliklerin, salt bilgisayar tarafından işlenmesi mümkün hale gelmiştir. Derin öğrenmenin alt sistemlerinden biri olan Üretken Rakip Yapay Sinir Ağları (GAN) algoritması, birbirine zıt çalışan iki sinir ağının birbiri ile çekişmesinden faydalanmaktadır. Üretici ağ gerçek olmayan görseller üretirken, ayırt edici ağ, üretilen görselleri değerlendirmekte ve görselin sahte veya gerçek olduğu bilgisini üretmektedir. İki ağ arasındaki bu çekişmeli durum ayırt edici ağın gerçek ile sahteyi ayıramayacağı kadar kaliteli görseller üretilene kadar tekrarlanmaktadır. Bu nedenle GAN algoritması özellikle görüntü işleme ve görüntü çeviri problemlerinde tercih edilmektedir. Derin öğrenmenin sunduğu görüntü işleme teknikleri ile karmaşık mekânsal verilerin kurgulanması ve mekânsal kurguların görüntüler üzerinden tekrar üretimi mümkündür. Bu çalışmanın amacı, farklı özelliklere sahip iç mekânların bir bilim kurgu filminin parçası olma durumunu ve bu durumdan türeyen yeni mekânsal potansiyelleri araştırmaktır. Bu bağlamda görüntü işleme için uygun bir teknik olan GAN algoritması kullanılarak, modern iç mekânlar distopik bilim kurgu mekânları olarak yeniden yorumlanmıştır. Çalışmada modern iç mekân fotoğraflarından ve bilim kurgu filmlerinden olmak üzere iki farklı veri seti oluşturulmuştur. Böylece modern iç mekânların bilim kurgu filmlerinde yer alması durumunda söz konusu mekânların morfolojik olarak nasıl yorumlanabileceği araştırılmıştır.

**Anahtar Kelimeler:** Cycle-GAN, Derin Öğrenme, Makine Öğrenmesi, Mekânsal Görüntü İşleme, Mimarlıkta Yapay Zekâ.

**Teslim Tarihi:** 24.08.2020

**Kabul Tarihi:** 27.09.2020

**Sorumlu Yazar:**

yagdir.celiker@bilgi.edu.tr

Çeliker, Y. E., Efendioğlu, G., Balaban, Ö. (2020). Cycle-GAN ile Modern İç Mekânların Bilim Kurgu Ortamları Olarak Yeniden Üretilmesi, JCoDe: Journal of Computational Design, 1(3), 71-94.

## 1. GİRİŞ

Günümüzde bilgisayar biliminin alt çalışma alanlarından bir olan yapay zekâ (artificial intelligence) uygulamaları birçok bilimsel araştırma ve meslek pratiği uygulamalarında olduğu gibi mimari tasarım araştırmalarında ve uygulamalarında da gün geçtikçe aktif bir biçimde kullanılmaktadır. Simon'un (1972) tasarımı kötü tanımlanmış (ill-defined) bir problem olarak tanımlamasıyla, tasarım odaklı düşünme süreci, problemin tanımı ve elde edilmesi planlanan çıktılar arasında sürdürülecek kurallar dizisi olarak kurgulanabilmiş, algoritma tabanlı yaklaşım mimari tasarım süreçlerine entegre edilebilmiştir. Böylece hesaplamalı mimari tasarım yöntem ve uygulamaları güncel mimarlık teorisi ve pratiğinde etkin bir biçimde yer alarak insan tasarımcının işleyemeyeceği yoğunlukta, çeşitlilikte ve büyüklükteki veriler yapay zekâ araştırmalarının bir dalı olan makine öğrenmesi uygulamaları kullanılarak işlenebilir hale gelmiştir. Bilgisayar bilimindeki bu gelişmeler bir yandan mimari tasarımda biliş araştırmalarından beslenmiş, insanın bilgi işleme mekanizması makinalara yapay sinir ağları olarak aktarılabilmiştir. Böylece veri işleme süreci statik ve öngörülebilir çıktılar olarak işleyen makinalar yerine, özgün ve yeni bilgi üretebilen, başka bir deyişle öğrenebilen makinalar ile gerçekleştirilmeye başlanmıştır. Yapay zekâ bilgisayarlara zekice hareket edebilmeleri için yeterli çok yönlülüğün sağlanması olarak tanımlanırken (Nilsson, 1980), makine öğrenmesi (machine learning) matematiksel ve istatistiksel işlemler kullanılarak bilgisayarın çıkarımlar yapmasını ve deneyimler ile öğrenme yetisini kazanmasını sağlayan mekanizma olarak ifade edilmektedir (Şafak, 2017). Yapay zekâ uygulamalarındaki çok yönlülüğün sağlanmasıyla bilgisayarın tek başına problem çözebilecek bilgi işleme kapasitesine sahip olması amaçlanmış, böylece hızlı ve mantıksal çıkarımlar yapabilen makinalar ile veri işleme sürecinin gerçekleşmesi hedeflenmiştir. Söz konusu hedefler göz önüne alındığında problem çözümünde gerekli olan zihinsel yetkinlikler ile öğrenme ve strateji belirleme gibi tekniklerin bilgisayara kazandırılması yapay zekânın temel amaçları haline gelmiştir.

Yukarıda bahsedilen yapay zekâ ve makine öğrenmesi çalışmalarının kapsamı, mimari tasarım araştırmalarında yapma bilgisi (techne) ve gerçek/öz teorik bilgi (episteme) üretiminde de insan tasarımcıya destek olmakta ve özgün tasarım yaklaşımlarını ortaya çıkarma, büyük veriyi işleme olanağı sağlamaktadır. Özellikle tasarımda optimizasyon

süreçlerinin hızlandırılması, gömülü ilişkilerin açığa çıkarılması bağlamında yapay zekâ ve makine öğrenmesi uygulamaları insan tasarımcıya geçmişe kıyasla oldukça geniş bir yelpazede yaratıcı ve özgün üretim yapabilme olanağını sağlamaktadır. Makine öğrenmesi aynı zamanda görüntü işleme (image processing) uygulamalarında sıklıkla kullanılmakta ve mekânsal verinin insan tasarımcının elde edemeyeceği bir karmaşıklıkta işlenebilmesine olanak sağlamaktadır. Böylece mekânın görüntüler üzerinden tekrar yorumu ve değerlendirilmesi yapılabilirken, özgün mekânsal kurguların üretimi olanaklı hale gelmektedir. Bu bağlamda çalışma, güncel hesaplamalı tasarım araştırmalarında sıklıkla kullanılmaya başlanılan makine öğrenmesinin bir alt çalışma alanı olan derin öğrenme (deep learning) araçlarından biri olan Üretken Rakip Yapay Sinir Ağları (GAN) algoritmaları ile farklı morfolojik ve topolojik özelliklere sahip iç mekânların bir bilim kurgu filminin parçası olma durumunu ve bu durumdan türeyen yeni mekânsallaşma potansiyellerini araştırmaktadır. Söz konusu mekânsallaşma potansiyellerinin araştırılmasıyla verinin yaratıcı ve özgün tasarım çıktıları elde edilmesi süreçlerine kazandırılacak olası katkılar üzerinde tartışılması da gelecekte yapılacak araştırmalar için oldukça aydınlatıcı olacaktır. Çalışmanın ana araştırma sorusu “İç mekânların kendi bünyelerinde bulundurduğu gömülü (embedded) veriler Üretken Rakip Yapay Sinir Ağları kullanılarak yeni mekânsal formasyonlar doğurabilir mi?” olarak tanımlanabilir. Söz konusu “yeni mekân” makinenin iki farklı atmosfere ait mekân görüntülerini işleyerek özgün çıkarımlar yapması ve bu çıkarımların sonucunda iki farklı veri setinden yeni mekânsal bilgiler elde etmek olarak tanımlanabilir. Söz konusu çalışmada geçmişten günümüze kadar Royal Institute of British Architects (RIBA) dijital mimarlık kütüphanesinde (Url-2) bulunan, inşa edilmiş iç mekân tasarımlarından oluşmuş bir veri seti ve distopik mekânsal referanslara sahip olan dört farklı bilim kurgu filminin iç mekân fragmanlarından hazırlanmış veri setleri kullanılarak, modern iç mekânların bilim kurgu filmlerinin atmosferlerinin bir parçası olacak şekilde tekrar üretimleri yapılmıştır. Böylece modern iç mekân tasarımlarının bilim kurgu filmine entegre edilmesi durumunda söz konusu mekânların morfolojik olarak nasıl evrileceği araştırılmıştır. Araştırma sırasında Üretken Çelişmeli Yapay Sinir Ağı (GAN) algoritmalarından biri olan Cycle-GAN algoritması kullanılmış ve çalışma için sinema tarihinin kült bilim kurgu filmlerinden Blade Runner, Metropolis, 2001: A Space Odyssey ve Star Wars Serisi seçilmiştir.

## 2. LİTERATÜR ARAŞTIRMASI

Literatür araştırması yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları üzerine yapılan çalışmaların mimari tasarım çalışmaları ile olan ilişkilerine odaklanmadır. Böylece genetik algoritmaların mimari tasarım süreçlerine olan katkılarının belirlenmesi amaçlanmıştır.

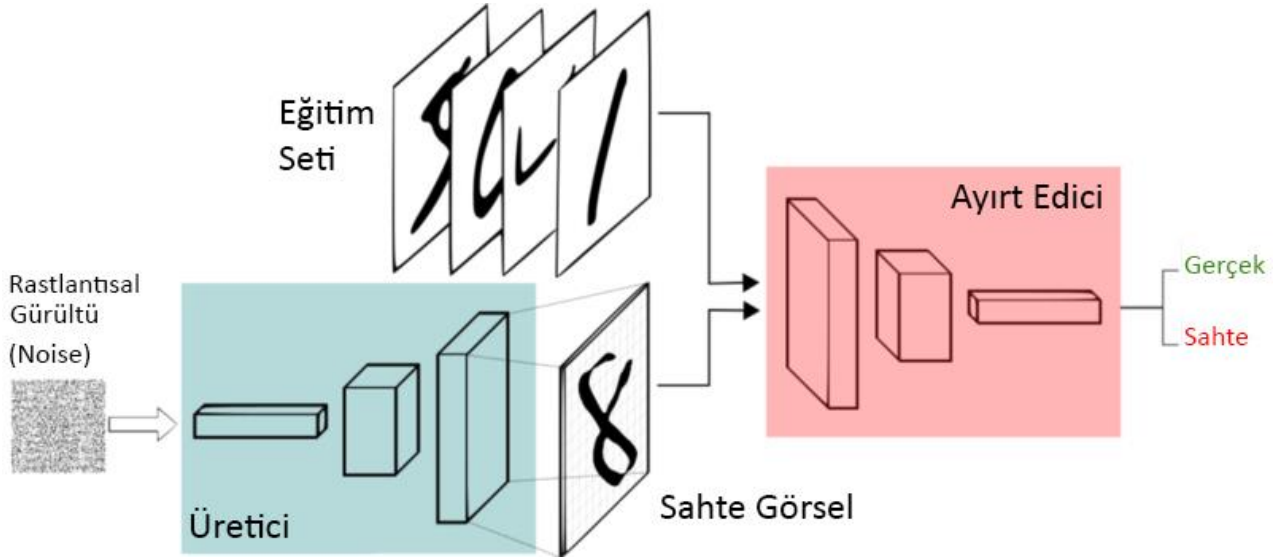
Yapay zekâ araştırmalarının önemli bir alt çalışma alanı olan genetik algoritmalar kullanılarak geliştirilmiş derin öğrenme, karmaşık görevlere yeni çözümler üretebilmek için sinir ağlarını (Neural Networks) kullanan bir makine öğrenmesi yöntemi olarak tanımlanabilir (Hitaj ve ark., 2017). Derin öğrenme ile veriye ait özelliklerin (features) bir insan tarafından öğretilmesinin zorunlu olmadığı, bilgisayarın da bu işlemi gerçekleştirebileceği bir sistemin var olabileceği görülmüştür. Böylece büyük verilerin kullanıldığı karmaşık problemlerin çözümünde bu yöntemden faydalanılmaktadır. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki **Şekil 1**'de görülmektedir.



**Şekil 1:** Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme arasındaki ilişki (Zbigniew ve ark., 2018).

Goodfellow ve ark. (2014), derin öğrenmedeki sinir ağları teorisini kullanarak iki farklı sinir ağının birbirine zıt şekilde çalıştığı Üretken Rakip Yapay Sinir Ağları (GAN, Generative Adversarial Networks) algoritmasını geliştirmiştir. Bu algoritma ile bilgisayar, eğitim seti (training set) istatistiklerini kullanarak yeni bir set oluşturmaktadır. Görüntü bölümlenme, soyutlama ve biçimlendirme gibi birçok görüntü işleme görevi, görüntüden görüntüye çeviri (image-to-image translation) problemi olarak tanımlanabilir (Isola ve ark., 2017). Bu nedenle görüntüden görüntüye çeviri problemlerinde, birbirine zıt iki farklı sinir ağı gibi çalışan GAN algoritması uygun yöntemi sağlamaktadır. GAN

algoritmasına üretici (Generator), baştaki verilerden rastgele bilgiler olarak gerçek olmayan görseller üretmeye çalışmaktadır (Goodfellow ve ark., 2014). Ayırt edici (Discriminator) ise sahte görselleri değerlendirerek bunların gerçek veya sahte olduğunun bilgisini üretmektedir. Bu işlem ayırt edici birimin (discriminator) gerçek ile sahteyi ayıramayacağı kadar kaliteli görseller üretilene kadar gerçekleştirilmektedir (Şekil 2).



GAN optimizasyonun matematiksel karşılığı ise aşağıda tanımlanan **Denklem 1** ile açıklanmıştır (Abdulkader ve ark., 2016).

**Şekil 2:** GAN optimizasyonu çalışma prensibi (Silva, 2018).

$$\min_{\theta_G} \max_{\theta_D} \sum_{i=1}^{n^+} \log f(x_i; \theta_D) + \sum_{j=1}^{n^-} \log (1-f(g(z_j; \theta_G); \theta_D)) \quad (1)$$

$x_i$  baştaki veriden alınan gerçek görselleri temsil ederken,  $z_j$  rastgele üretilen görselleri tanımlamaktadır.  $f(x_i; \theta_D)$ , karşılaştığı görsellere göre farklı etiketler üreten ayırt edici sinir ağı olarak kabul edilirse,  $g(z_j; \theta_G)$  rastgele verilerden görüntü üreten üretici sinir ağını tanımlamaktadır. Çalışma esnasında ayırt edici sinir ağının performansını en üst düzeye çıkarabilmek için  $\theta_D$  gradyanı hesaplanmaktadır. Böylece  $f(x_i; \theta_D)$ , orijinal görsel ile üretilen görsel arasındaki farkı değerlendirerek görselin gerçek veya sahte olduğunu değerlendirebilmektedir. Devamında  $\theta_G$  gradyanı hesaplanarak, orijinal görsele en yakın sahte görselin üretilmesini sağlamaktadır (Hitaj ve ark., 2017).

GAN algoritmasının görsel verilerin üretiminde sağladığı verimlilik, algoritmanın görsel odaklı birçok farklı çalışmada tercih edilmesini sağlamıştır. Zebra ve at (Zhu ve ark, 2017) veya kedi, köpek gibi hayvan görsellerinin dönüşümleri ile çizimlerden gerçek aksesuarlara veya kıyafetlere dönüşümler (Huang ve ark., 2018), belirli bir alanın yaz ve kış mevsimine göre dönüşümleri (Zhu ve ark, 2017), fotoğraflardan ressamların stillerine göre tablo dönüşümleri (Lee ve ark, 2018), fotoğraflarda insanların cinsiyetlerini değiştirme veya duygu durumlarına göre yüz ifadelerinin değişimi (Choi ve ark., 2018), el yazısı ile sayı görsellerinin üretimi (Goodfellow, 2014) gibi görüntüden görüntüye çeviri problemlerinde GAN algoritması sıklıkla kullanılmaktadır.



Şekil 3: Büyük kedi, ev kedisi ve köpek görselleri ile oluşturulmuş GAN algoritmasının uygulandığı bir çalışma (Huang ve ark., 2017).

## 2.1 Mimari Tasarımda Üretken Rakip Yapay Sinir Ağları (GAN)'ın Kullanımı

Literatürde mimari tasarım alanında büyük veri kullanılarak özgün ve bütüncül bir mimari üretimin ilk örneği İspanyol Mimar Vignola tarafından 16.yy'da gerçekleştirilmiştir (De Haan akt., As ve diğ., 2018). Vignola bir manastır tasarımı yarışmasından çıkan proje önerilerini kullanarak "yeni" bir manastır tasarımı geliştirmiş ve bu yaklaşım, büyük veriyi kullanarak kolektif mimari üretimin ilk örneklerinden biri olmuştur (As ve diğ., 2018). Söz konusu çalışma, yarışma katılımcılarının


hakları açısından bazı tartışmaların önünü açmasına rağmen açık kaynak kullanımının da öncüsü olarak tanımlanabilir.

1960'lı yıllara gelinmesiyle yapay zekâ araştırmaları hız kazanmış ve makine öğrenmesi, derin öğrenme, genetik algoritmalar geliştirilmeye başlanmış ve mimari tasarım araştırmalarında kullanımı yıllar içinde artış göstermiştir. Hopfield (1982) makine öğrenmesini genetik algoritmalar gibi çeşitli kural dizileri kullanan üretken hesaplamalı tasarım yaklaşımı bütünü olarak tanımlamıştır. Genetik algoritmalar biyolojik evrim operasyonları olarak tanımlanabilecek mutasyon, doğal seçim ve gen aktarımı prensiplerine dayanan, özellikle yüksek çözünürlüklü görüntü işleme ve optimizasyon problemlerinde sıklıkla kullanılan bir algoritma çeşidi olarak tanımlanabilir (Eiben, 1994).

Genetik algoritmalar ilk olarak 1960 yılında John Holland tarafından Darwin'in Evrim Teorisi baz alınarak geliştirilmiş, ardından Holland'ın öğrencisi David E. Goldberg 1989 yılında genetik algoritmaların kullanım alanlarını genişleten çalışmada bulunmuştur (Mitchell, 1997). John Frazer (1995), Reptile Structure adını verdiği çalışmada evrimsel algoritmaları kullanarak mimari strüktürler geliştirmeye çalışmıştır. John Gero, 1996 yılında evrimsel sistemler ve sinir ağlarını kapsayan çalışmasını paylaşmıştır.


Yapay zekâ çalışmalarının gelişimi ile mimarlıkta makine öğrenmesinin kullanımı öncelikli olarak tasarım üretimi, biçim tanımlama, tasarım alanının keşfi ve sınıflandırması alanlarına odaklanmıştır (Tamke ve ark., 2018). Chaillou (2019), tez çalışması kapsamında GAN ile mimari tasarım üretimine katkıda bulunmayı amaçlamıştır. Tezindeki çalışmalar plan organizasyonu ve stil aktarımına odaklanmıştır. Modern planlar ile barok planlar arasındaki farklılıklara değinen Chaillou, modern planlardan barok üslupta plan tiplerinin üretildiği bir GAN algoritması geliştirmiştir (**Şekil 4**).





**Şekil 4:** GAN ile Modern Plandan Barok Plana Dönüşüm (Chaillou, 2019).

Chaillou mimari plan organizasyonunda, boş parsel üzerinde yapı sınırının oluşturulması, yapı sınırından duvarların ve pencere boşluklarının planlanması, devamında kat planının mobilyalar ile donatılmasını makine öğrenmesi ile geliştirmeyi başarmıştır (**Şekil 5**).



**Şekil 5:** GAN ile plan organizasyonu planlaması (Chaillou, 2019).


Araştırmacı, **Şekil 5**'te görülen parsel üzerinde yapı izinin tanımlanmasında Boston'da bulunan yapıların vaziyet planlarından oluşturdukları büyük bir veri setini öğrenme seti olarak kullanmıştır. Bu vaziyet planlarını, ticari, konut ve endüstriyel plan tipleri olarak etiketlemiş ve 700'den fazla plan tipiyle veri setini oluşturmuştur. Planları tek tek bölümlerine ayırarak renk kodlarıyla işaretlemiştir. Mobilya yerleşimlerinde, önceki aşamada kullanılan renk kodlarına göre o mekânın kullanım amacı belirlenmekte ve o alanda kullanılacak mobilyalar plana yerleştirilmektedir. Örneğin, renk kodunun mavi olduğu alanlar yatak odası olarak belirlenmekte ve böylece bu alanlara mobilya olarak yatak yerleştirildiği görülmektedir.

Literatür araştırması bölümünde özetlenen çalışmalarda görüldüğü üzere, mimari tasarımda yapay zekâ uygulamaları farklı amaçlara hizmet edebilecek şekilde kurgulanabilen, esnek, istenildiğinde tasarım kısıtlarına göre evrilebilen bir yapıya sahip bir bilgi işleme aracı olarak

tanımlanabilir. Bu bağlamda özellikle GAN gibi genetik algoritmaların var olan veriyi mimari tasarım kriterlere göre işleyebilmesi ve bu işlemi mantıksal çıkarımlar eşliğinde yapabiliyor olması sayesinde insan tasarımcının öngöremediği potansiyel çözümleri sağlayabildiği ve nihai tasarım çıktılarını çok daha nitelikli hale getirebileceği öngörülebilir.

### 3. YÖNTEM VE ARAÇLAR

Çalışma genellikle iki farklı veri setini birbirine dönüştürmek için kullanılan Cycle-GAN algoritması kullanılarak Gözetimsiz Öğrenme (Unsupervised Learning) yöntemi ile farklı tipoloji ve morfolojilere sahip modern iç mekân görüntülerinin işlenmesini hedeflemektedir. Gözetimsiz Öğrenme, veri setindeki özelliklerin algoritmaya önceden tanımlanmadığı, görüntüdeki herhangi bir bileşenin etiketlenerek derin öğrenme sürecine dahil edilmediği makine öğrenmesi yöntemidir (Duda ve ark. 2001). Böylece etiketlenmemiş/tanımlanmamış veriler arasındaki ilişkilerin algoritmadaki nöronlar tarafından kurulması beklenir. Cycle-GAN ise, temel olarak görüntülerden oluşan veri setinin karakteristik özelliklerini yakalamayı ve bu özelliklerin diğer görüntü veri setine nasıl çevrilebileceğini bulmayı amaçlar (Zhu ve diğerleri, 2018). Bu bağlamda çalışmanın ilk adımı olarak Royal Institute of British Architects (RIBA)'nın açık veri kaynağı olarak kullanıcılara sunduğu dijital mimarlık kütüphanesinden (Url-2) elde edilen modern iç mekân görüntülerinden bir veri seti oluşturulmuş, seçilen dört adet bilim kurgu filmi için söz konusu modern iç mekânlar Cycle-GAN algoritması kullanılarak yeniden üretilmiştir. Cycle-GAN algoritmasının temel yapısı ve çalışma prensibi Şekil 6'da özetlenmiştir.



Şekil 6'de görüldüğü gibi Cycle-GAN algoritması modern iç mekânların bulunduğu X alanına (domain X) tanımlanmış veri seti ve her bir bilimkurgu filminden oluşan birbirinden bağımsız Y alanına (domain Y)

Şekil 6: Cycle-GAN algoritmasının yapısı (Zhu et al.,2018).

tanımlanmış veri setlerine uygulanmak üzere G ve F olarak adlandırılan iki adet eşleşme fonksiyonu (mapping function) içermektedir. Bu iki eşleşme fonksiyonunun X ve Y olarak adlandırılmış veri setleri ile olan ilişkisi aşağıdaki bağıntılar ile tanımlanmıştır (**Denklem 2** ve **Denklem 3**).

$$G:X \rightarrow Y \quad (2)$$

$$F:Y \rightarrow X \quad (3)$$

Çalışmadan kullanılan Cycle-GAN algoritmasında **Denklem 2** ve **Denklem 3** olarak tanımlanan eşleşme fonksiyonlarının yanı sıra, **Şekil 6**'da görülen DX ve DY olarak tanımlanmış olan rakip ayırt ediciler (adversarial discriminators) da X ve Y alanları ile ilişki kurmaktadır (Zhu et al.,2018). Böylece ayırt ediciler, eşleme fonksiyonlarının işlemleri sırasında görüntülerin gerçek veya sahte/makine tarafından yaratılmış olup olmadığını tanımlama işlevini üstlenmektedir (**Şekil 2**). Ayırt edicilerin dahil olduğu ana fonksiyon (**Şekil 2**) aynı zamanda tersine çalışarak birbirinden ayırt edilemeyen çıktılarını saptamaya da olanak vermektedir (Zhu ve diğerleri, 2018).

**Denklem 4** ve **Denklem 5**'de ise eşleşme fonksiyonlarındaki döngüsel tutarlılık kayıplarının (cycle-consistency loss) saptanması hedeflenmektedir (Zhu ve diğerleri, 2018). Söz konusu döngüsel tutarlılık kayıplarının 0'a yaklaşması algoritmanın maksimum verimle verileri işleme anlamına gelmektedir.

$$x \rightarrow G(x) \rightarrow F(G(x)) \approx x \quad (4)$$

$$y \rightarrow F(y) \rightarrow G(F(y)) \approx y \quad (5)$$


Çalışmanın ana aracı olarak Google ColabPro kod yazım ortamı kullanılmış ve algoritmanın çalıştırılması süresince Google'ın sunduğu Grafik İşleme Ünitesi (GPU) hizmetinden yararlanılmıştır. X alanına karşılık gelen modern iç mekânların .jpeg formatında elde edilen imajları kullanılırken, Y alanı için oluşturulacak veri setlerinin oluşturulmasında "Kawping" isimli çevrimiçi video bölümler aracı kullanılarak öncelikle seçilen bilimkurgu film videoları istenilen fragmanlara ayrılmıştır. Film fragmanların seçimindeki en öncül kriter, çalışmada kullanılacak bilim kurgu filmi fragmanlarının iç mekân görüntüleri içermesidir. Böylece Cycle-GAN algoritmasının çıktılarındaki döngüsel tutarlılık kayıplarının minimize edilmesi amaçlanmıştır. Video fragmanlarının hazırlanmasının ardından söz konusu .avi uzantılı dosyalar VLC Player kullanılarak .jpeg formatına dönüştürülmüştür. Sırasıyla Blade Runner, Metropolis, 2001: A Space Odyssey ve Star Wars Serisi olmak üzere 4 film için ayrı ayrı olarak .jpeg formatında hazırlanan

Y alanına ait veri setlerine ait imajlar aynı boyuta getirilmek üzere Adobe Bridge aracıyla işlenerek 128x128x3 ve 256x256x3 piksel olarak tekrar boyutlandırılmıştır. Ardından iki farklı boyut olarak hazırlanmış, X ve Y alanlarına ait veri setleri kullanılarak Cycle-GAN algoritması çalıştırılmıştır. Veri setlerinin hazırlanması aşamasında çalışmaların büyük çoğunluğunda Pareto prensibi (80-20 ilkesi) kullanılmaktadır (Url-1). Bu ilkedan yola çıkarak her bir veri setinin yaklaşık olarak %20'si test, %80'i algoritmanın eğitilmesi (training) için ayrılmıştır.

#### 4. MODERN İÇ MEKÂNLARIN CYCLE-GAN İLE TEKRAR ÜRETİLMESİ

Çalışmada Cycle-GAN algoritması kullanılarak RIBA'nın açık kaynak olarak paylaştığı modern iç mekân görüntülerinin (Url-2), sinema tarihinin kült bilim kurgu filmlerine ait iç mekânları için tekrar üretimi yapılmıştır. Modern iç mekân görüntüleri X alanı olarak algoritmaya tanımlanmıştır (Şekil 7).

**Şekil 7:** RIBA'nın modern iç mekân görüntülerinden oluşturulmuş veri setinden örnekler (Url-2).



X alanı için hazırlanmış olan veri setinde 795 adet görüntü algoritmanın eğitilmesi, 192 görüntü ise test için kullanılmıştır. Şekil 7'de görüldüğü üzere RIBA dijital kütüphanesinden elde edilmiş modern iç mekân görüntüleri farklı tipoloji ve morfolojilere ait iç mekânların

fotoğraflarından oluşmaktadır (Url-2). Mekânların tipolojik ve morfolojik farklılıklarının yanı sıra, mekânların fotoğraflanma açıları da belirgin farklar bulunmaktadır.

Y alanına ait veri setleri ise bilim kurgu sinemasının kült filmlerinden Blade Runner, Metropolis, 2001: A Space Odyssey, Star Wars Serisi kullanılarak üretilmiştir. Her film için hazırlanmış olan test ve eğitim veri setlerinde bulunan veri sayıları **Tablo 1**'de görülmektedir.

**Tablo 1:** Y alanı (domain) için hazırlanmış test ve eğitim verileri

| Veri Setleri       | Blade Runner | 2001: A Space Odyssey | Metropolis | Star Wars Serisi |
|--------------------|--------------|-----------------------|------------|------------------|
| Eğitim veri sayısı | 624          | 1221                  | 1249       | 450              |
| Test veri sayısı   | 156          | 404                   | 325        | 125              |

Çalışmada Blade Runner ve Star Wars serisi için ortalama 500 görüntü eğitim için kullanılırken, yaklaşık 120-150 kadar görüntü ise algoritmanın testi için kullanılmıştır. Bununla birlikte 2001: A Space Odyssey ve Metropolis filmleri için daha fazla sayıda veri, eğitim ve test için ayrılmıştır. Söz konusu veri sayısı değişimi ile algoritmanın çalıştırılmasıyla birlikte veri seti hacminin algoritmanın çıktı niteliğine olan etkisinin belirlenmesi de amaçlanmıştır. **Şekil 8**'de Y alanına ait veri seti örneklerinde görüldüğü üzere, bilimkurgu filmlerinden elde edilmiş olan iç mekân görüntüleri X alanında olduğu gibi farklı morfoloji ve tipolojide iç mekânların görüntülerini içermektedir. Buna ek olarak filmlerde iç mekân görüntülerinde sadece mekân değil kullanıcılar da görüntülerde bulunabilmektedir. Ayrıca, görüntülerdeki aydınlık düzeyleri de birbirinden oldukça farklılık göstermesi mekânsal algı da değişimler yaratmaktadır.


Blade Runner Veri Seti



Metropolis Veri Seti



2001: A Space Odyssey Veri Seti



StarWars Serisi Veri Seti




Tüm veri setlerindeki görüntüler 128x128x3 ve 256x256x3 piksel olarak iki farklı boyutta hazırlanmış, hedeflenen sonuçları elde etmek adına algoritmanın ana fonksiyonları farklı iterasyon sayılarına karşılık gelen dönem (epoch) sayıları ile çalıştırılmıştır. Öncelikle kontrol grubu çalışması olarak tanımlanabilecek bir ön çalışma yapılmış, ana çalışma için optimum görüntü boyutu ve dönem sayısı belirlenmiştir. Ardından ana çalışmada aynı dönem sayısı ve görüntü boyutu ile algoritma her bir film için tekrar çalıştırılarak, sonuçlar değerlendirilmiştir.

**Şekil 8:** Y alanı (domain) için hazırlanmış test ve eğitim verilerinden örnekler

#### 4.1 Kontrol Grubu Çalışması

Kontrol grubu çalışmasında Metropolis filminden üretilmiş olan veri seti kullanılarak Cycle-GAN algoritması 1000 ve 10000 dönem sayılarında çalıştırılmış, 128x128x3 piksel boyutundaki görüntülerden elde edilmiş olan sonuçlar incelenmiştir (Şekil 9).



**Şekil 9:** Metropolis 128x128x3 piksel, yukarıdan aşağıya 1000 ve 10.000 dönem için çıktılar.

**Şekil 9**'da görüldüğü üzere, 128x128x3 piksel boyutundaki verilerin işlenmesinde dönem sayısının artırılması çıktılarının niteliğinde belirgin düzeyde azalmaya neden olmuştur. Her iki deneme için dögüsel tutarlılık kaybının hesaplanmasında **Denklem 4** ve **5**'deki bağıntılara ek

olarak Ortalama Mutlak Hata Fonksiyonu (OMH)'den yararlanılmıştır (Denklemler 6).

$$OMH = \frac{1}{n} \sum_{j=1}^n |x_j - y_j| \quad (6)$$


Denklemler 6'te  $x_j$  üretilen (sahte) imajların vektörünü,  $y_j$  ise gerçek imajların vektörünü temsil ederken;  $n$  ise veri setindeki toplam veri sayısına karşılık gelmektedir (Qi ve diğ., 2020). Yukarıda belirtilen hata fonksiyonu kullanılarak, algoritmanın dögüsel tutarlılık kayıpları belirlenmiştir (Tablo 2).

| Dönem sayısı | Dögüsel tutarlılık kaybı $D_x$ | Dögüsel tutarlılık kaybı $D_y$ | Toplam Dögüsel Tutarlılık Kaybı |
|--------------|--------------------------------|--------------------------------|---------------------------------|
| 1000         | 0.0093                         | 0.4739                         | 2.0535                          |
| 10.000       | 0.0047                         | 0.1843                         | 2.5300                          |

Tablo 2: Metropolis filmi için dögüsel tutarlılık kayıpları

Tablo 2'de görüldüğü üzere, dönem sayısını artması toplam dögüsel tutarlılık kaybını arttırmaktadır. Ancak, X ve Y alanlarının ayırt edicileri ayrı ayrı olarak değerlendirildiğinde, dönem sayısının yükselmesiyle ayırt edicilerin dögüsel tutarlılık değerlerini kayıplarını azaltmıştır. Çalışmada X alanına ait verilerden Y alanına benzer verilerin elde edilmesinde odaklanıldığından, araştırmada  $D_y$  ayırt edicisinin tutarlılık kayıpları ve toplam tutarlılık kayıplarına göz önüne alınmış ve ileriki değerlendirmeler bu parametrelere göre yapılmıştır. Söz konusu iki denemenin de dögüsel tutarlılık kayıplarının görüldüğü grafiklere bakıldığında ise;  $D_y$  için 1000 dönem ile yapılan denemede en yüksek tutarlılığın 600-800 dönem aralığında, 10.000 dönemlik deneme için ise 4000-6000 aralığında elde edildiği görülmektedir (Şekil 10).

Şekil 10: Soldan sağa sırasıyla 1000 dönem ve 10.000 dönem için dögüsel tutarlılık kayıpları.



Söz konusu sonuçların elde edilmesinden sonra görüntü boyutlarının değişiminin tutarlılık kayıplarına etkisini belirlemek ve çıktı niteliğinin



değişimini görebilmek adına, 1000 dönem sayısı ve 256x256x3 piksel boyutundaki Metropolis veri setiyle algoritma tekrar çalıştırılmıştır. **Şekil 11**'de, verilerin piksel değerlerinin büyümesiyle görüntüdeki gürültülülüğün (noise) 128x128x3 piksel boyutundaki veri seti sonuçlarına göre oldukça azaldığı görülmektedir. Ayrıca 128x128x3 piksel ile elde edilmeyen renk çeşitliliği, 256x256x3 piksel ile elde edilmiştir. Mekânların morfolojik olarak değişimi gözlemlenmezken, mekândaki aydınlık seviyesi değişerek, gerçek görüntülerde daha açık renk tonlarına sahip yüzeyler, üretilmiş görüntülerde en koyu yüzeyler haline gelmiştir.

**Şekil 11:** Metropolis 256x256x3 piksel, 1000 dönem sayısı



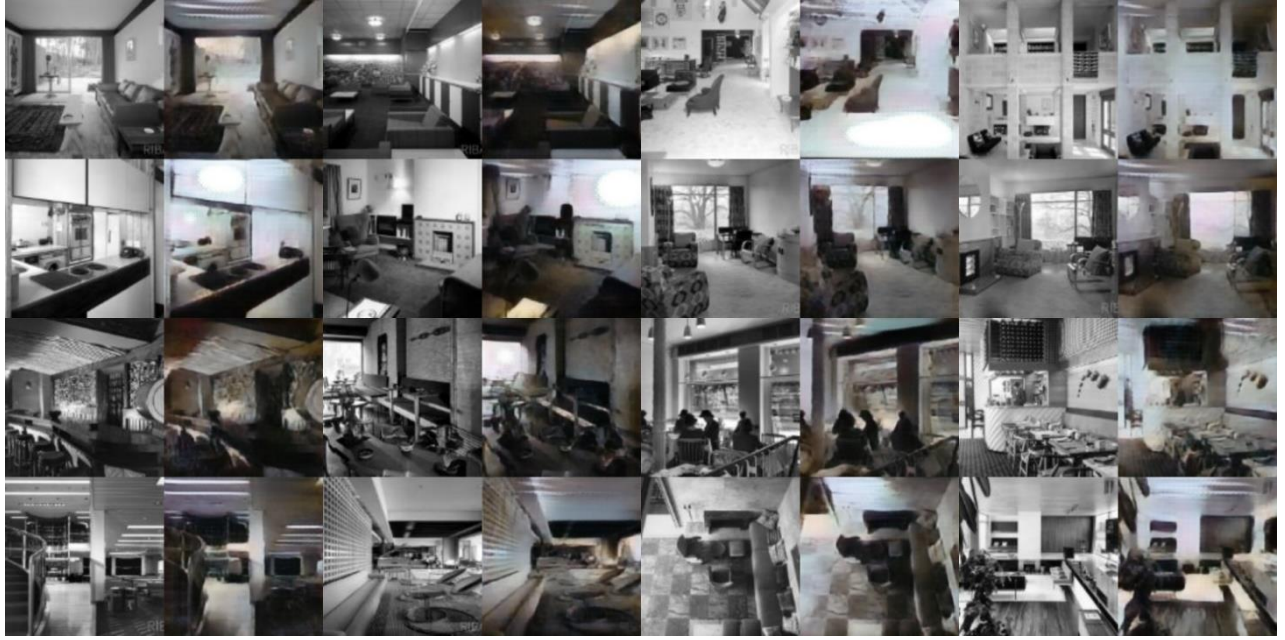
**Şekil 11**'deki çıktılar analiz edildiğinde ise, toplam dögüsel tutarlılık kaybı 1000 dönem sayısı için 3.1797 olarak saptanırken;  $D_Y$  için 0.3504,  $D_X$  için 0.0504 olarak belirlenmiştir. Söz konusu değerler 128x128x3 piksel ve 1000 dönem ile karşılaştırıldığında, dögüsel tutarlılık kaybı açısından düşük çözünürlüklü görüntülerin daha tutarlı sonuçlar verdiği görülmektedir. Kontrol grubu analizleri sonucunda, 128x128x3 piksel boyutu ve 6000 dönem sayısı ile çalışmanın ilerletilmesine karar verilmiştir.

#### 4.2 Bilim Kurgu Ortamları için Modern İç Mekân Üretimi


Çalışmanın ana bölümünde Blade Runner, Metropolis, 2001: A Space Odyssey ve Star Wars Serisi filmleri görüntüleri ile hazırlanmış olan

128x128x3 boyutundaki veriler kullanılarak Cycle-GAN algoritması 6000 dönem sayısı ile çalıştırılmıştır (Şekil 12).





X Y X Y X Y X Y



**Şekil 12:** Yukarıdan aşağıya; Blade Runner, Metropolis, 2001: A Space Odyssey, Star Wars Serisi. 128x128x3 piksel, 6000 dönem sayısı.

**Şekil 12'**de görüldüğü üzere, X alanına ait veri setindeki modern iç mekân görüntüleri, sırasıyla Blade Runner, Metropolis, 2001: Space Odyssey ve Star Wars serisine ait verilerin bulunduğu Y alanına CycleGAN algoritması kullanılarak dönüştürülmüştür. 6000 dönem sayısı ve 128x128x3 piksel boyundaki görüntüler ile elde edilmiş sonuçların dögüsel tutarlılık kayıpları da **Tablo 3'**te görülmektedir.

| Bilim Kurgu Filmleri | Döngüsel tutarlılık kaybı $D_x$ | Döngüsel tutarlılık kaybı $D_y$ | Toplam Döngüsel Tutarlılık Kaybı |
|----------------------|---------------------------------|---------------------------------|----------------------------------|
| Blade Runner         | 0.0037                          | 0.0397                          | 2.8882                           |
| Metropolis           | 0.0455                          | 0.0476                          | 2.9085                           |
| 2001: Space Odyssey  | 0.0840                          | 0.1085                          | 3.1845                           |
| StarWars             | 0.0267                          | 0.2658                          | 2.2267                           |

**Tablo 3:** 128x128x3 piksel, 6000 dönem sayısı için döngüsel tutarlılık kayıpları

Döngüsel tutarlılık kayıpları incelendiğinde, en yüksek değer 3.1845 ile 2001: A Space Odyssey Filminde görülürken, en düşük değer ise 2.2267 ile Star Wars Serisi için belirlenmiştir. Bölüm 4.1'deki ön çalışmalardaki değerler bağlamında Metropolis için toplam kayıplar karşılaştırıldığında, 6000 dönem sayısı ile elde edilen kayıp değerinin 1000 ve 10.000 dönem sayısında elde edilen kayıp değerlerinden daha fazla olduğu görülmektedir.

## 5. SONUÇ

Yapılan çalışma Cycle-GAN algoritmasıyla gözetimsiz derin öğrenme araştırmaları yaparak modern iç mekân görüntülerinden bilim kurgu ortamlarına ait yeni mekânlar üretmeyi amaçlamakta ve üretilen mekânların tipolojik ve morfolojik özelliklerinde gerçekleşen değişimlerin analizini kapsamaktadır. Mimari analizlerin sağlıklı olarak yapılabilmesi amacıyla, araştırmada Metropolis filmi verileri kullanılarak kontrol grubu çalışması yapılmış, ana çalışma için gereken optimum görüntü boyutu ve dönem sayısının belirlenmesi hedeflenmiştir. Böylece Cycle-GAN algoritmasından optimum düzeyde verim alınması planlanmıştır. Kontrol grubu deneyi sonuçlarına göre 128x128x3 piksel boyutuna sahip görüntülerin döngüsel tutarlılık değerlerinin, 256x256x3 piksel boyutuna göre daha az olduğu belirlenmiştir. Bu bağlamda, algoritmanın verimi ve piksel boyutu arasında bu çalışma çerçevesinde ters orantı gözlemlenmiştir. Bu durum, gözetimsiz derin öğrenme yönteminin kullanılması ve görüntülerde bulunan mimari bileşenlerin birbirinden oldukça farklı olması nedeniyle gerçekleşebileceği yorumu yapılabilir. Ayrıca, en yüksek verimin 4000-6000 dönem sayısı aralığında alındığı ön kontrol çalışmasında belirlenmesine ve ana çalışmanın da bu bilgiye dayanarak 6000 dönem sayısı ile yapılmasına rağmen, toplam kayıp değerleri özellikle

Metropolis örneği için öngörülen değer üzerindedir. Bu sonucun da algoritmanın gözetimsiz olarak eğitilmesi nedeniyle olabileceği öngörülmektedir. Bu bağlamda ileriki çalışmalarda farklı morfoloji ve tipolojideki mekânlara ait mimari bileşenlerin etiketlenerek gözetimli derin öğrenme ile eğitilmesi, sonuç ürünlerdeki mimari bileşenlerin biçimsel olarak da değişmesini sağlamak için uygun bir yöntem olarak değerlendirilebilir. Ancak, bu çalışmada, biçimsel olarak değişimden ziyade mekânın ait olduğu atmosfer ile olan ilişkisi açısından oldukça belirgin mimari değişim ve dönüşümler elde edilmiştir. Bu bağlamda çalışma, özellikle kavramsal tasarım süreçleri, mimari tasarımda biliş ve mimarlık kuramı çalışmaları için oldukça ufuk açıcı perspektifler sağlamaktadır. Araştırmanın ilgili çalışma alanlarına katkısını özetlemek adına, sonuç ürünlerin mekânsal potansiyellerinin değişimi ve dönüşümü, seçilmiş olan her bir film için sırasıyla incelenmiş ve yorumlanmıştır.

Çalışmanın ana ürünü olan iç mekân görüntüleri (**Şekil 12**), mimari mekân üretimi bağlamında analiz edildiğinde, görüntülerde dramatik seviyede tipolojik ve morfolojik değişimler gözlemlenmediği, ancak mekânların aydınlık seviyesi, ışık rengi ve oluşan gölgeler bağlamında oldukça belirgin dönüşümlerin olduğu görülmektedir.

Blade Runner ve Metropolis veri setleriyle yapılan çalışmalarda mekânların sahip olduğu renklerin birbirine oldukça benzer olduğu görülmekteyken, bu yakınlığın Star Wars Serisi ile 2001: A Space Odyssey arasında da bulunduğu söylenebilir. Ayrıca, Metropolis çıktılarında açık tonlardaki yüzeylerin daha koyu, koyu tonlara sahip yüzeylerin ise daha açık renk yüzeyler olarak yer değiştirmiş olduğu görülmektedir. Bu bağlamda Metropolis veri seti Cycle-GAN'a ışık kaynaklarının yer değiştirdiği bir iç mekân yaratma olanağı sağlamıştır. Böylece görüntülerdeki mimari bileşenlerin iç-dış ilişkisi, ön ve arkada olma durumu değişmiş ve mekân, gözlemciye Blade Runner çıktılarına göre çok daha farklı varyasyonlarda mekânsal deneyimler sunabilmiştir. Örneğin, orijinal görüntüde zeminde bulunan daha aydınlık bir bölüm gözlemciye tavanda bulunabilecek bir ışıklık öğesinin varlığını sorgulatabilir. Bu bağlamda, Metropolis, iç mekânı saran yapı kabuğunun morfolojik değişimleri ile ilgili olasılıkları da arttıran, tasarımcıya mekânın var olduğu atmosfer ile ilgili soru sordurtan mimari ürünlerin ortaya çıkmasını sağlamıştır.

2001: A Space Odyssey ise özellikle iç mekânda, orijinal görüntülerde olmayan yapay ışıklandırma öğelerinin arttığı çıktılar sunmuştur. Ayrıca algoritma ağaç, pencereden görünen gökyüzü, desenli yüzeyler gibi daha karmaşık yapıları pürüzsüzleştirerek, daha sade ve yalın iç mekânlar üretilmesini sağlamıştır. Bu bağlamda filmin genel atmosferine hâkim olan steril mekân algısı, yeniden üretilmiş modern iç mekânlarında etkin bir biçimde hissedilmektedir.

Star Wars Serisi çıktılarına bakıldığında ise; orijinal iç mekân görüntülerinde var olan gölge tonlarının oldukça koyulaştığı ve aydınlık bölgelerdeki ışık kaynağı renklerinin farklı tonlara sahip neon efektlere dönüştüğü, başka bir deyişle mekân görüntüsünün saturasyon (doyma, rengin saflık derecesi) değerlerinde dramatik değişimler gerçekleştiği görülmektedir.

Yukarıdaki analizler bağlamında, mekânların kendilerini çevreleyen ortama ait olma durumu, söz konusu çalışmada ışık, gölge, yüzey dokusu ve renk üzerinden analiz edilmiş ve gözetimsiz derin öğrenme ile gerçekleştirilen üretimlerin bu noktada oldukça yararlı olduğu görülmüştür. Çalışmanın ileriki adımlarında ise mekânlarda bulunan mobilyaların ve/veya yapı elemanlarının biçimsel değişimlerine odaklanılarak, araştırmanın uluslararası literatüre katkı sağlaması hedeflenmektedir.

## Referanslar

Abdulkader A., Lakshmiratan A., and Zhang J. (2016, Jun 1). *Introducing DeepText: Facebook's Text Understanding Engine* [Blog]. Facebook Engineering. Erişim adresi: <https://tinyurl.com/jj359dv>, erişim tarihi 26.08.2020.

As, I., Pal, S., & Basu, P. (2018). Artificial Intelligence in Architecture: Generating Conceptual Design Via Deep Learning. *International Journal of Architectural Computing* 16(4), 306–327.

Borysiuk, Z. & Konieczny, M. & Kręcis, K. & Pakosz, P. (2018). Application of sEMG and Posturography as Tools in the Analysis of Biosignals of Aging Process of Subjects in the Post-production Age. In Hunek, W., P. & Paszkiel, S. (Eds), *Proceedings of the 3<sup>rd</sup> International Scientific Conference on Brain-Computer Interfaces, BCI 2018* (pp. 23-29). Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-75025-5>

Chailou, S. (2019). *AI & Architecture Towards A New Approach* [Thesis Project]. Harvard University Graduate School of Design. Erişim Adresi: <https://towardsdatascience.com/ai-architecture-f9d78c6958e0>, erişim tarihi: 26.08.2020.

Choi, Y., Choi, M., Kim, M., Ha, J. W., Kim, S., & Choo, J. (2018). Stargan: Unified Generative Adversarial Networks for Multi-Domain Image-To-Image Translation. In *Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition* (pp. 8789-8797).

Duda, R. O., Hart, P. E. & Stork, D. G. (2001). *Pattern Classification* (2<sup>nd</sup> ed.) (pp. 16-17). New York: John Wiley & Sons.

Eiben A.E., Raué P.E., Ruttkay Z. (1994). Genetic algorithms with multi-parent recombination. In Davidor Y., Schwefel HP., Männer R. (Eds), *Parallel Problem Solving from Nature — PPSN III.*. Berlin: Springer. [https://doi.org/10.1007/3-540-58484-6\\_252](https://doi.org/10.1007/3-540-58484-6_252)

Frazer, J. (1995). *An Evolutionary Architecture* (pp. 71-85). London: Architectural Association.

Gero, J. S. (1996). Artificial Intelligence in Computer-Aided Design: Progress and Prognosis. *Computer Aided Design* 27(3), 153-154. Great Britain: Elsevier.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., & Bengio, Y. (2014). Generative Adversarial Nets. In *Advances in Neural Information Processing Systems*, 2672-2680.

Hitaj, B., Ateniese, G., & Perez-Cruz, F. (2017). Deep Models Under The GAN: Information Leakage From Collaborative Deep Learning. In *Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security* (pp. 603-618).

Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. In *Proceedings of The National Academy Of Sciences* 79(8), 2554-2558.

Huang, X., Liu, M. Y., Belongie, S., & Kautz, J. (2018). Multimodal Unsupervised Image-To-Image Translation. In Ferrari, V., Hebert, M., Sminchisescu, C., Weiss, Y. (Eds), *Proceedings of the European Conference on Computer Vision (ECCV)*, 172-189. Cham: Springer. <https://doi.org/10.1007/978-3-030-01246-5>.

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).

Mitchell, T. M. (1997). *Machine Learning* (pp. 269-270). Singapore: McGraw-Hill Science/ Engineering/ Math.

Nilsson, N. T. (1980). *Machine Learning Principles of Artificial Intelligence* (pp. 1-3). California: Morgan Kaufmann Publishers.

Qi, J. & Du, J. & Siniscalchi, M. & Ma, X. & Lee, C. (2020). On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression. In *IEEE Signal Processing Letters* 27 (pp. 1485-1498). doi: 10.1109/LSP.2020.3016837

Silva, T. (2018, January 7). *An intuitive Introduction to Generative Adversarial Networks (Gans)* [Blog]. FreeCodeCamp. Erişim Adresi: <https://www.freecodecamp.org/news/an-intuitive-introduction-to-generative-adversarial-networks-gans-7a2264a81394/>, erişim adresi: 26.08.2020.

Simon, Herbert A. (1973). The Structure of Ill-Defined Problems. *Artificial Intelligence* 4 (3-4), 181-201. [https://doi.org/10.1016/0004-3702\(73\)90011-8](https://doi.org/10.1016/0004-3702(73)90011-8).

Tamke, M., Nicholas, P., & Zwierzycki, M. (2018). Machine Learning for Architectural Design: Practices and Infrastructure. *International Journal of Architectural Computing*, 16(2), 123-143.

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 (ICCV)* (pp. 2223-2232).

Url-1 <<https://towardsdatascience.com/finally-why-we-use-an-80-20-split-for-training-and-test-data-plus-an-alternative-method-oh-yes-edc77e96295d>>, erişim tarihi 26.08.2020.

Url-2 <<https://www.architecture.com/imagelibrary/ribapix.html?keywords=modern%20interiors>>, erişim tarihi 26.08.2020.