

Year : 2023 | Volume : 7 | Issue : 1



International Journal of Multidisciplinary Studies and Innovative Technologies

Year :2023

Volume : 7

Issue : 1

Editor-in-Chief

Assoc. Prof. Dr. Turgut ÖZSEVEN

Assistant Editor

Asst. Prof. Dr. Ebubekir YAŞAR

Issue Editorial Board

Prof. Dr. Leila Akhvlediani
BAU International University, Georgia

Prof. Dr. Zakaria Boumerzoug
Université Mohamed Khider De Biskra

Assoc. Prof. Dr. Irada Dadashova
Baku State University, Azerbaijan

Assoc. Prof. Dr. Muharrem Düğenci
Karabuk University, Turkey

Dr. Shahbaz Memon
*Julich Supercomputing Centre,
Germany*

International Journal of Multidisciplinary Studies and Innovative Technologies is online, open access, double blind peer-reviewed, international research journal. Language of the journal is English and Turkish. Authors should only submit original work, which has not been previously published and is not currently considered for publication elsewhere.

An expert editor is assigned to a submitted manuscript. The editor appoints reviewers to evaluate the manuscript. As a result of the evaluation of the manuscript by reviewers, the editor decides about the acceptance, modification or rejection of the manuscript.

International Journal of Multidisciplinary Studies and Innovative Technologies

Year: 2023, Volume: 7, Issue: 1

CONTENTS

1. Gürgen Ağacı Talaşı Dolgulu Epoksi Matrişli Kompozit Yapıların Mekanik Özelliklerinin İncelenmesi	1-5
<i>İlyas KARTAL, Zerrin ÖZCAN</i>	
2. Generating Personalized Abstract Art Paintings by using People's Life Energy Distribution	6-14
<i>Furkan AYAS, Feriştah DALKILIÇ</i>	
3. Hava Lidar ve fotoğraflardan kentsel alanların digital ikizinin oluşturulması ve karşılaştırılması	15-19
<i>Cihan ALTUNTAŞ</i>	
4. Modeling Naval Mine Warfare with Machine Learning Algorithms.....	20-31
<i>Hakan AKYOL, Ragıp ZİLCİ, Caner TABAN</i>	
5. Üretken Yapay Zekâ.....	32-40
<i>Melisa GÖZET, Ulaş FİLİZ, Asım Egemen YILMAZ</i>	

Gürgen Ağacı Talaşı Dolgulu Epoksi Matrisli Kompozit Yapıların Mekanik Özelliklerinin İncelenmesi

İlyas Kartal^{1*}, Zerrin Özcan²

¹*Marmara Üniversitesi, Teknoloji Fakültesi, Mealurji ve Malzeme Mühendisliği Bölümü, İstanbul, Türkiye (ilyaskartal@marmara.edu.tr)
(ORCID: 0000-0001-9677-477X)

² MEB, Başakşehir Şehit Muhammed Eymen Demirci İlkokulu, İstanbul- TÜRKİYE (zerrinnozcan@gmail.com) (ORCID: 0009-0004-2184-3186)

Türkçe Özeti – Doğal elyaf dolgulu polimer kompozitlere olan ilgi, yüksek performansları, önemli işleme avantajları, düşük maliyetleri ve düşük bağıl yoğunlukları nedeniyle hızla artıyor. Bu çalışmada gürgen talaşı dolgulu epoksi matrisli kompozitlerin mekanik özellikleri incelenmiştir. Matris malzemesi olarak ısı ile sertleşen epoksi reçinesi tercih edilmiştir. Dolgu olarak yerel mobilya üreticilerinden doğal atık olarak ortaya çıkan gürgen ağacı talaşı kullanılmıştır. Talaş, eleklerden elenerek 0-150 mikron boyut aralığında hazırlanmış olup reçineye ağırlıkça %5-10-15-20 oranlarında ilave edilmiştir. %20 talaş ilavesi ile reçine doyuma ulaşlığı için numune hazırlanması sonlandırılmıştır. Epoksinin çok iyi yapışma özelliği sebebiyle kalıp olarak Teflon malzemesi tercih edilmiştir. Hazırlanan karışım tamamen sertleşmesi için 180°C'de 3 saat kür işlemi uygulanmıştır. Numunelerin çekme, sertlik, darbe gibi mekanik özellikleri incelenmiştir. Kırık yüzeylerin incelenmesi SEM görüntülerile yapılmıştır. Çalışma sonunda ağırlıkça %15 gürgen talaşının epoksi matrisli kompozitlerde mekanik özelliklere olumlu tesis ettiği, talaş katkı oranının ideal olduğu tespit edilmiştir. Numune yapısında homojen bir şekilde karışım olduğu SEM görüntülerinden de anlaşılmıştır.

Anahtar Kelimeler – Epoksi reçinesi, Gürgen ağacı talaşı, Doğal dolgu, Mekanik özellikler, Epoksi matrisli kompozit.

Atıf: Kartal, İ., Özcan, Z. (2023). Gürgen Ağacı Talaşı Dolgulu Epoksi Matrisli Kompozit Yapıların Mekanik Özelliklerinin İncelenmesi. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 1-5.

Investigation of Mechanical Properties of Hornbeam Wood Sawdust Filled Epoxy Matrix Composite Structures

Extended Abstract

The interest in natural-fiber reinforced polymer composites is growing rapidly owing to their great performance, significant processing advantages, low cost and low relative density. In this study, the mechanical properties of hornbeam sawdust filled epoxy matrix composites were investigated. Thermosetting epoxy resin is preferred as matrix material. As a filler, hornbeam sawdust from local furniture manufacturers as natural waste was used. Sawdust was prepared in the size range of 0-150 microns by sieves and added to the resin at the rate of 5-10-15-20% by weight. Sample preparation was terminated as the resin reached saturation with the addition of 20% sawdust. Teflon material was preferred as the mold because of the very good adhesion property of epoxy. The prepared mixture was cured at 180 °C for 3 hours to completely harden. Mechanical properties of the samples such as tensile, hardness and impact were investigated. Examination of the broken surfaces was made with SEM images. At the end of the study, it was determined that the addition of 15% by weight hornbeam sawdust had a positive effect on the mechanical properties of epoxy matrix composites, and the sawdust additive ratio was ideal. It was also understood from the SEM images that there was a homogeneous mixture in the sample structure.

Keywords – Epoxy resin, Hornbeam wood sawdust, natural filler, mechanical properties, epoxy matrix composite

Citation: Kartal, İ., Özcan, Z. (2023). Investigation of Mechanical Properties of Hornbeam Wood Sawdust Filled Epoxy Matrix Composite Structures. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 1-5.

I. GİRİŞ

Kompozit malzemeler genel olarak matris bileşeni ile katkı/dolgu malzemeleri içeren bileşenlerden oluşur. Polimer

esaslı kompozitlerde katkı malzemesi olarak cam elyaf ve karbon elyaf yoğun olarak kullanılır. Dolgu malzemesi olarak hem sentetik hem de doğal dolgu malzemeleri mevcuttur.

Dolgu malzemeleri maliyeti önemli ölçüde düşürmesi ile birlikte bir kısmı mekanik özelliklere katkı da sağladığı bilinmektedir. Sentetik dolgular çoğunlukla seramik esası olup endüstride kullanımını yaygındır. Ancak sentetik dolgulu kompozitler için atık bertarafı ve geri dönüşüm küresel bir sorundur. Artan çevresel duyarlılık nedeniyle, düzenli depolama bertarafı dünya çapında daha fazla tercih edilmemesi söz konusudur [1-3].

Doğal kaynakların korunması ve geri dönüşümle ilgili endişeler, yenilenebilir ham maddelere odaklanması sebebi olmuştur. Son yıllarda çevreye uyumlu doğal dolgular seramik esası dolguların yerini almış olup yoğun olarak tercih edilmektedir. Özellikle bitki liflerine dayalı yeni tip kompozitler geliştirilmiştir. Doğal elyaf/dolgu takviyeli kompozitler, iyi bir mekanik performans ve çevre dostu olma özelliği sunar. Son yıllarda doğal dolgu ve lifler kullanımı ile ilgili birçok çalışma yapılmıştır [4-9].

Yeni nesil doğal dolgulu çevreci malzemeler sentetik plastiklere alternatif olarak pek çok alanda kullanılmaktadır. Yeşil kompozitler olarak da adlandırılan bu malzemelerden üretilmiş ürünler yoğun olarak, otomotiv, mobilya, inşaat ve ambalaj sektöründe kullanılmaktadır. Lif ve dolgu malzemeleri olarak selüloz, fındıkkabuğu, bambu lifi, buğday sığı, odun talaşı, kenaf, ceviz kabuğu gibi malzemeler tercih edilmektedir [5-6, 8].

Doğal liflerden oluşan yenilenebilir kaynaklara dayalı kompozitler ekonomik ve ekolojik olarak kabul edilebilir. Doğal dolgulardan biri de odun talaşıdır. Odun talaşı hafiflik, mikro tane boyutu, yerel kaynaklardan kolayca bulunabilmesi ve doğal atık gibi avantajlara sahip olması nedeniyle polimerik kompozitlerde kullanımları elverişlidir [10-11]. Odun malzemesi aynı zamanda bir kompozit olup bir lignin matrisi tarafından bir arada tutulan selüloz, hemiselülozlar ve ligninden oluşan üç boyutlu bir bileşiktir. Odun lifleri çok iyi mekanik özellikler göstermekle beraber hidrofobik polimerlerle yapışmalarını zayıflatın nispi düşük bozunma sıcaklıklarına sahiptir [12-13].

Doğal elyaf takviyeli kompozitlerin ana uygulaması, doğal elyaf kompozitlere dayalı çeşitli bileşenler geliştiren otomotiv endüstrisi alanındadır. Avrupa'da bitki lifi kompozitleri esas olarak otomotiv endüstrisi tarafından kullanılmaktadır. Biyofiber takviyesi harmanlanmış termoplastiklerde veya reçineli termoset uygulamaları olarak artık kapı kaplamaları/panelleri, paket rafları ve bagaj kaplamaları gibi uygulamalar oldukça yaygındır. Biyofiber takviyeli kompozitlere sahip otomotiv bileşenlerinin, artan model penetrasyonu ile istikrarlı bir şekilde artması beklenebilir. Günümüzde biyofiber kompozitlerin bir otomobilin dış bileşenlerinde kullanılması sıkılıkla tercih edilmektedir. DaimlerChrysler'in binek otomobiller için dış zemin altı korumada yenilikçi abaka elyaf uygulaması, keten elyaf takviyeli kompozitlerden diğer dış parçalar (ön tampon, otobüsün zemin altı döşemesi), Ford Mondeo'nun kapı panelleri kenaf ile güçlendirilmiş polipropilen kompozitlerden üretilmesi, Mercedes S sınıfı için 27 bileşenin biyofiberle güçlendirilmiş kompozitlerden üretilmesi gibi otomotiv endüstrisinde uygulamalar mevcuttur [14-16].

Yüksek performanslı gelişmiş kompozitlerde en sık kullanılan ışıyla sertleşen reçineler fenolik, epoksiler ve polyester reçinelerdir. Bu reçineler hem mükemmel solvent hem de yüksek sıcaklık direnci sergiler. Kalıplama ile şekillendirme yöntemi, fiber ister uzun ister kısa olsun, bu kompozitleri yapmak için en yaygın kabul gören yöntemdir.

Bu çalışmada matris malzemesi olarak yaygın kullanımı sebebiyle ısı ile sertleşebilen epoksi reçinesi tercih edilmiştir. Epoksiler iyi yapışma, mekanik özellikler, düşük nem emme, kimyasal direnç, az çekme ve işlenme kolaylığı özelliklerine sahiptir. Bu mükemmel özellikler, epoksi ailesini birçok kompozit için en iyi matris malzemelerinden biri yapmıştır [17-20].

Gürgen ağacı Türkiye'nin birçok bölgesinde yaygın bir şekilde bulunmakta olup başta mobilya sektörü olmak üzere sağlam ahşap kullanılması gereken ürünlerde kullanılan sert ve dayanıklı bir ağaçtır. Mobilya sektöründe ve ahşap ihtiyacı olan sektörlerde tercih edilen ağaçların başında gelir. Kerestesi çok tercih edilen bir ağaç türüdür. Sağlam yapısı ve dayanıklılığı sebebiyle oyuncak sektöründen gemi sektörüne kadar birçok alanda ahşap ihtiyacını karşılar [21-22].

Bu çalışmada ise ısı ile sertleşen epoksilerde atık gürgen talaşı dolgu olarak kullanılması incelenecektir. Böylece bir kompozit uygulamasıyla atık talaşın kullanımını ile çevresel etkilerinin azaltılması, kompozit üretim maliyetinin düşürülmesi, sentetik dolguların kullanımının önüne geçilerek atık depolama miktarının ve gaz emisyonunun azaltılması, doğal kaynakların korunması sağlanacaktır.

II. MALZEME VE METOD

A. Malzemeler

Kompozit numuneler için matris malzemesi olarak kompozit uygulamalarında yoğun olarak tercih edilen epoksi reçinesi, Epikot 828 (Shell Chemical, yoğunluğu 1,16 kg/litre) seçilmiştir. Epikot 828, bisfenol A reçinesi ve epiklorohidridinden üretilen orta viskoziteli sıvı epoksi reçinesidir. Seyreltici içermez, kürlenmiş durumda iyi pigment ıslatma ve dolgu maddesi çökelmesine karşı iyi direnç ve yüksek düzeyde mekanik ve kimyasal direnç özellikleri sağlar. Epoksi reçinesi sertleştiricisi olarak Epicure (Shell Chemical), hızlandırıcı olarak benzil dimetil amin (BMDA-Aldrich) kullanılmıştır. Doğal dolgu malzemesi olarak yerel mobilya üreticilerinden temin edilen atık gürgen ağaç talaşları kullanılmıştır. Talaşlar 150 mikron boyutundaki eleklerden geçirilerek 0-150 mikron boyutlarına getirilmiştir.

B. Numune Hazırlama

Epoksi reçinesine 0-150 mikron boyut aralığındaki gürgen ağaç talaşı yaklaşık %5-10-15-20 oranlarında ilave edilmiştir. %20 dolgulu numunelerde doyuma ulaşığı için başka numune hazırlanmamıştır.

Epoksi reçinesi için kullanılan sertleştirici oranı 1:1 dir yani epoksi reçinesinin ağırlığınca aynı miktarda sertleştirici kullanılmıştır. Epikot 828 ve Epicure karışımında oluşan hava kabarcıklarının giderilmesi için 50 °C sıcaklığındaki etüv firmanızda yaklaşık 20 dakika bekletilmiştir. Ayrıca yaklaşık %1 oranında benzil dimetil amin (BDMA) hızlandırıcı olarak ilave edilmiştir. Teflon kalıba dökülen karışım tamamen sertleşmesi için 180 °C 3 saat kür işlemi uygulanmıştır.

Epoksi reçinesinin yapışma özelliği çok iyi olması sebebiyle numunelerin kalıptan kolayca ayrılması için açık Teflon kalıp tercih edilmiştir.

C. Mekanik Testler

Numunelere çekme testi ISO 527 standardına göre Zwick marka Z010 universal tipi çekme test cihazında çekme hızı dakikada 5 mm olacak şekilde uygulanmıştır. Çentiksiz test numunelerinin darbe dayanımı, Zwick marka B5113.30 darbe test cihazı üzerindeki 5,4 J'lük Izod çekici kullanılmıştır. Sertlik testi ölçümleri Zwick markalı Shore D test cihazında yapılmıştır. SEM incelemesi için numuneler 10 Å kalınlığındaki altın/paladyum合金 laşımı ile kaplanması yapıldı. SEM testi Marmara Üniversitesi Teknoloji Fakültesi Laboratuvarında yer alan Polaron SC markalı cihazı ile gerçekleştirildi.

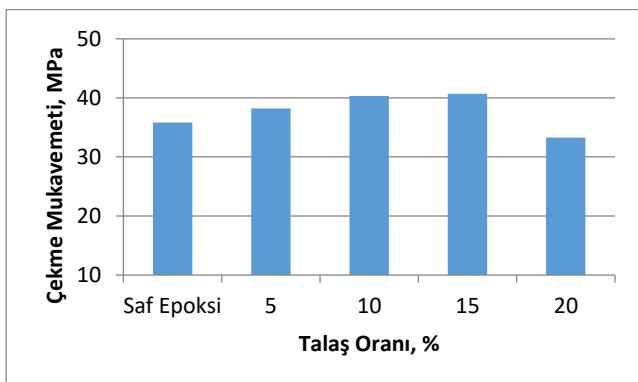
III.BULGULAR VE TARTIŞMA

Kompozit numunelere çekme deneyi, Izod darbe deneyi ve sertlik ölçümleri yapılmıştır. Numunelere ait çekme mukavemeti ve % birim şekil değiştirme değerleri tablo 1'de verilmiştir.

Tablo 1. Numunelerin çekme mukavemeti ve % birim şekil değiştirme değerleri

Numuneler	Çekme Mukavemeti (MPa)	Birim Değiştirme (%)
Saf Epoksi	35,8	2,2
%5	38,2	2,3
%10	40,3	2,1
%15	40,7	1,8
%20	33,3	1,6

Epoksi-gürgen ağacı talaşı karışımı numunelerde ağırlıkça % talaş oranının artmasıyla karışımın çekme mukavemetinde kısmi bir artış sağladığını şekil 1'deki grafikten de görmek mümkündür.

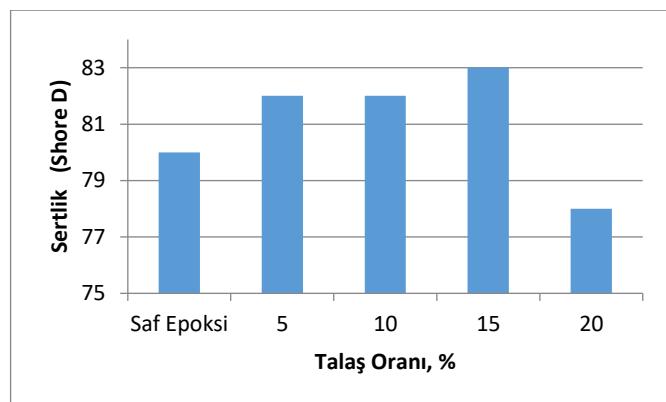


Saf epoksi numunesi, düşük bir gerilme mukavemeti sergilemiştir. Ancak talaşın takviye edici etkisinden dolayı kompozitlerin çekme dayanımı değerleri %15 talaş oranı ile en yüksek değere ulaşmış olup saf epoksinin çekme mukavemetini yaklaşık olarak %14 oranında artırmıştır. %15 sonrası talaş ilavesiyle numunenin çekme mukavemetinde azalma gözlemlendi.

Bunun nedeni, kompoziti sıkıca bağlayan epoksi reçine yüzdesinin azalması olabilir. Diğer olası neden, polimer matris ile dolgu içeriği arasındaki zayıf ara yüzey bağıının kompozitin çekme dayanımını düşürmesi olabilir. Talaş miktarının artmasıyla topaklanma eğilimi veya talaş parçacıkları ile

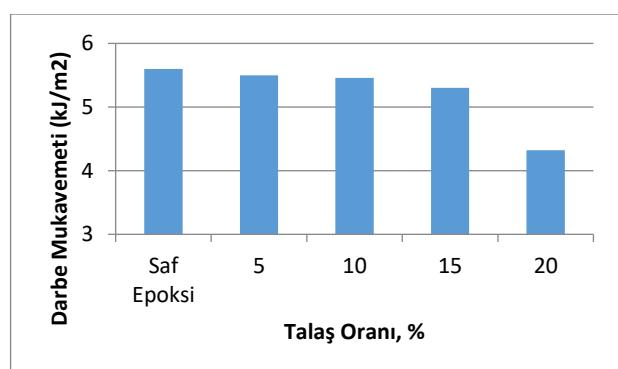
epoksi reçine matrisi arasındaki yetersiz hidrojen bağıının çekme dayanımının azalmasına neden olduğunu çalışmalarla ifade edilmiştir [13, 20, 23-24].

Numunelerin Shore D sertlik değeri şekil 2'de verilmiştir. Çekme mukavemetinde olduğu gibi ağırlıkça bir miktar artış göstermiş, %15 talaş miktarı sonrası ise bir parça azalma görülmüştür.



Şekil 2. Numunelerin Shore D sertlik değerinin talaş oranına bağlı olarak değişimi

Şekil 3'te Izod darbe dayanımının artan talaş orıyla değişimi incelendiğinde talaş oranı artması ile kompozitin darbe direncinde bir miktar artış gözlemlenmiştir. Talaş ilavesiyle epoksinin darbe mukavemeti talaş doyum oranına ulaştığı %20 dolgulu numunede saf epoksinin de altında bir derece düşmüştür. Literatürde yapılan çalışmalarda termoset reçinelere ilave edilen talaş boyutu azaldıkça mekanik özellikleri artırdığı ifade edilmiştir [6]. Bu çalışmada da dolgu boyutu 150 mikron ve altı olmasının gerek çekme mukavemetine gerekse darbe mukavemetine olumlu tesis ettiği düşünülmektedir.

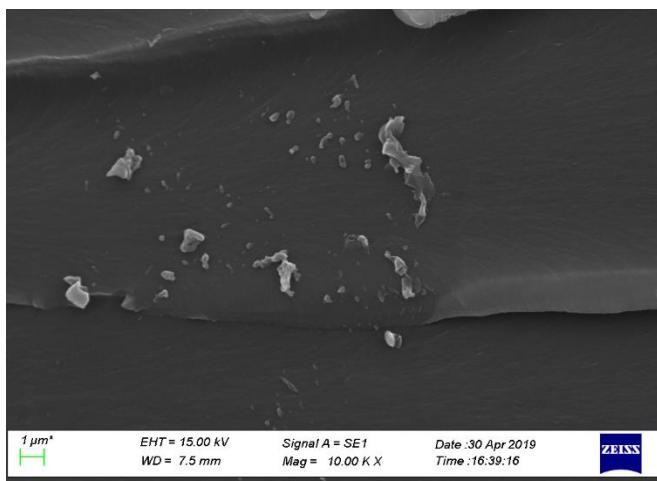


Şekil 3. Numunelerin darbe mukavemetinin talaş oranına bağlı olarak değişimi

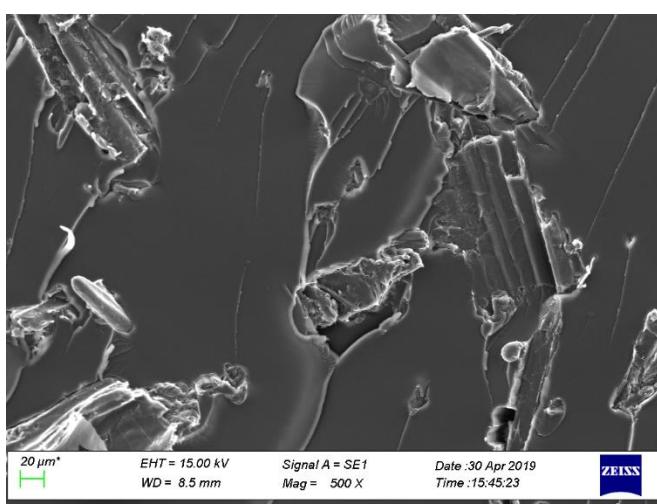
Şekil 4'te numunelerin SEM görüntülerini verilmiştir. Şekil 4a'da saf epoksinin kırık yüzeyinde gevrek kırılma olduğu görülmektedir. Diğer SEM görüntüsü şekil 4b %15 gürgen talaş içermektedir. Talaşın epoksi reçineye iyi bir şekilde yaptığı açıklıktır. Görüntülerden de anlaşılabileceği gibi 10 mikron boyutunda talaş olduğu gibi 150 mikron boyutunda da talaş olduğu görülmektedir. %20 dolgu içeren numunelerde talaş parçacıkları ağırlıkça oranı arttıkça topaklanma gözlemlendi. Bu da kompozitlerin mekanik özelliklerine müdahale

edebilecek kabarcık ve gözenek oluşmasına sebep olduğu düşünülmektedir.

Ağırıkça %15 talaş dolgulu epokside iyi yapışma olduğu, ağırıkça talaş miktarının artmasıyla selülozik yüzeylerin tamamını tamamen kaplamak için yeterli miktarda epoksi reçinesi olmamış olabilecegi düşünülebilir. Böylece bu görüntülerden, ağırıkça %15 talaş içeren kompozitlerin, neden ağırıkça %20 talaş içeren kompozitlerden daha iyi mekanik özellikler gösterdiği anlaşılabilir. Bu çalışmadaki benzer gözlemler farklı çalışmalarında da gözlendiği belirtilmiştir [23-25].



a.



b.

Şekil 4. Saf epoksi (a) ve %15 gürgen talaş dolgulu (b) numunelerin kırık yüzeylerine ait SEM görüntüler

IV. SONUÇLAR

Bu çalışmada gürgen talaşı, ısı ile sertleşen epoksi esaslı kompozit malzemede dolgu olarak kullanımı incelendi. Epoksi içinde gürgen talaş dolgusu arttıkça mekanik özelliklerde az da olsa bir iyileşme gözlemlendi. Çekme testi verilerine göre %15 oranındaki talaş dolgusunun diğer tüm numunelere göre daha iyi bir mukavemet gösterdiği gözlemlendi. Sertlik değerinde de kısmi bir artış olmuştur. Darbe deneyi değerleri,

yapıldığı 150 mikron ve altı boyutlarındaki talaş dolgusu sebebiyle bir parça artış göstermiştir. Tüm numunelerin verileri incelendiğinde %15 talaş dolgulu numunelerde talaş oranının ideal olduğu, yapıda homojen bir şekilde karışmış olduğu SEM görüntülerinden anlaşılmıştır. Talaş boyutunun küçük olması mekanik özellikleri olumlu etkilemiştir.

Bu çalışma sonunda %15 gürgen talaş dolgusu ilavesinin, ısı ile sertleşen epoksi kullanım miktarının azaltacağı, bunun da maliyeti düşürecegi, mekanik özelliklere de olumlu katkı sağlayacağı tespit edilmiştir. Bununla beraber sentetik dolguların yerine doğal dolgunun kullanılmasıyla çevresel sorunların çözümüne katkıda bulunacağı da açıkları. Dolayısı ile ısı ile sertleşen epoksi matrişli kompozit malzeme uygulamalarında gürgen talaşının dolgu olarak kullanılmasının yerinde bir karar olabileceği sonucuna varılmıştır.

ACKNOWLEDGMENT

The heading of the Acknowledgment section and the References section must not be numbered.

Authors' Contributions

The authors' contributions to the paper are equal.

Statement of Conflicts of Interest

There is no conflict of interest between the authors.

Statement of Research and Publication Ethics

The authors declare that this study complies with Research and Publication Ethics

KAYNAKÇA

- [1] Lubin G, (1982), Handbook of Composites, New York, Van Nostrand.,
- [2] Bismarck A, Mishra S, Lampke T, (2005) Natural Fibers, Biopolymers and Bio-composites, edited by A K Mohanty, M Misra, L T Drzal, Boca Raton, FL, CRC Press, 37.
- [3] Sabu, T., Kuruvilla J.; Kumar, M., Goda, K., Sreekala M. S. (2012). Introduction to Polymer Composites, Polymer Composites, Volume 1, First Edition, Wiley-VCH Verlag GmbH & Co 209.
- [4] Kartal İ, (2020) "Effect of hornbeam sawdust size on the mechanical properties of polyethylene composites" Emerging Materials Research Volume 9 Issue 3, 979-984
- [5] Kartal, İ., Nayci, G. and Demirer, H. (2019). "Investigation of the Mechanical Properties of Chestnut/Hornbeam Sawdust Filled Vinyl Ester Composites". European Journal of Science and Technology, (16), 723-728.
- [6] Kartal İ., Nayci G., Demirer H., (2020) The effect of chestnut wood flour size on the mechanical properties of vinyl ester composites, Emerging Materials Research, 9(3), 960-965,
- [7] Şengör İ., Cesur S., Kartal İ., Oktar F. N., Ekren N., İnan A. T., Gündüz O., (2018) "Fabrication and Characterization of Hazelnut Shell Powder with Reinforced Polymer Composite Nanofibers", ICNMA: 2018 20th International Conference on Nanostructured Materials and Applications, Zurich, Switzerland, 13 – 14 September
- [8] Kartal İ., Gülsah Nayci G., and Demirer H, (2019) "Investigation of Mechanical Properties of Glass and Bamboo Fiber Reinforced Vinylester Composites" Multidisciplinary Studies and Innovative Technologies, Volume 3, Number: 1, 34 - 37
- [9] Demirer H., Kartal İ., Yıldırım A., Büyükkaya K., (2018) "The Utilisability of Ground Hazelnut Shell as Filler in Polypropylene Composites", Acta Phys. Pol. A 134, 254-256
- [10] Kamdem, D. P., Jiang, H., Cui, W., Freed, J., and Matuana, L. M. (2004). "Properties of wood plastic composites made of recycled HDPE and wood flour from CCA-treated wood removed from service," Composite Part A: Applied Science and Manufacturing 35(3), 347-355. DOI: 10.1016/j.compositesa.2003.09.013
- [11] Deka, B. K., Baishya, P., and Maj, T. K. (2014). "Synergistic effect of SiO₂, ZnO and nanoclay on mechanical and thermal properties of wood

- polymer nanocomposite," *Journal of Thermoplastic Composite Materials* 27(4), 464-480. DOI: 10.1177/0892705712452739
- [12] Ashori, A. (2008). "Wood-plastic composites as promising green-composites for automotive industries," *Bioresource Technol.* 99, 4661-4667.
- [13] Marcovich, N.-E., Reboreda, M.-M., and Aranguren, M.-I. (1996). "Composites from sawdust and unsaturated polyester," *J. Appl. Polym. Sci.* 61(1), 119-124.
- [14] Daimler Chrysler awarded for banana fiber use in Mercedes A Class, <http://www.netcomposites.com/news>. Nowember 2005
- [15] Hintermann M, 'Automotive exterior parts from natural fibers', RIKO-2005, Hannover, Germany, November 2005.
- [16] Buttlar H B, 'Natural fiber reinforced construction materials for SMC applications', RIKO-2005, Hannover, Germany, November 2005.
- [17] Kartal İ, (2019) "Investigation of Wear Properties of Toughened Epoxy Resin using Silane Terminated Urethane", Vol. 135, *Acta Physica Polonica A* No. 5, 1100-1101
- [18] Kartal İ, Boztoprak Y., Bilici M. K., Çakır M., "Investigation of Wear Properties of Epoxy-Polyester Mixtures", 13th International Metallurgy and Materials Congress, Istanbul, Turkey, 9 - 12 November 2006
- [19] Bilyeu, B., Brostow, W., and Menard, K. P. (1999). "Epoxy thermosets and their applications. I: Chemical structures and applications," *Journal of Materials Education* 21(5&6), 281-286.
- [20] Khan, M., Abas, M., Noor, S., Salah, B., Saleen, W., and Khan, R. (2021). "Experimental and statistical analysis of sawmill wood waste composite properties for practical applications," *Polymers* 13 (4038), 1-19.
- [21] <https://bitkievreni.com/gurgen-agacinin-tarihi-ve-kulturel-onemi/>
Nisan 2023
- [22] Uğur Eskier, <https://www.makaleler.com/gurgen-agacinin-ozellikleri-nelerdir>, Nisan 2023
- [23] Lette, M. J., Elhadji Babacar, L. Y., Ndiaye, D., Takasaki, A., and Okabe, T. (2018). "Evaluation of sawdust and rice husks as fillers for phenolics resin based wood polymer composites," *Journal of Composite Materials* 8(3), 124-137 DOI: 10.4236/ojcm.2018.83010
- [24] Huda, M. S., Drzal, L. T., Misra, M., and Mohanty, A. K. (2006). "Wood-fiber-reinforced poly(lactic acid) composites: Evaluation of the physicomechanical and morphological properties," *J. Appl. Polym. Sci.* 102, 4856-4869.
- [25] Kumara, R., Kumarb, K., Sahooc, P., and Bhowmika, S. (2014). "Study of mechanical properties of wood dust reinforced epoxy composite," *Procedia Materials Science* 6, 551-556.

Generating Personalized Abstract Art Paintings by using People's Life Energy Distribution

Furkan Ayas^{1*} and Feriştah Dalkılıç²

¹*The Graduate School of Natural and Applied Sciences, Dokuz Eylül University, Izmir, Turkey (furkan.ayas@ceng.deu.edu.tr) (ORCID: 00009-0004-9666-6006)

²Department of Computer Engineering, Dokuz Eylül University, Izmir, Turkey (feristah@cs.deu.edu.tr) (ORCID: 0000-0001-7528-5109)

Abstract – Data visualization, which is essentially the visual expression of data through mathematical calculations, is a highly effective method for transferring and understanding data. The right data visualization, selected or developed with data and people in mind, has an important role in improving the quality of conveying the relationships, meanings, information, structures and hidden properties of data to individuals from different fields of expertise and enables them to work together.

Data visualization has been a subject that has evolved and progressed in different ways throughout history and has finally reached today's computer technology and conditions. The improved facilities of today's computer such as high computing power has brought data visualization methods to a new horizon. Also the changing definition of the data has expanded the boundaries of the data visualization. Today, data is obtained from many different sources such as; IoT, Embedded systems, Social data, Business data and Real-Life data. This study is also inspired by the Real-Life, and a visualization system was developed based on real-life botanical trees and using humans as data.

Throughout history, computer science and other branches of science have used art as a subject in various studies. This study reunites science and art and proposes a way of expressing the human through art. Thus, an artistic visualization system was developed that uses the activities of people's lives as data and generates artistic visuals inspired by abstract art paintings. Through this study, a sub-art style was created with a visualization system that manages to produce artistic visuals by adhering to mathematical foundations.

Keywords – Data Visualization, Creative Algorithms, Computational Creativity, Neural Style Transferring, Abstract Art.

Citation: Ayas, F., Dalkılıç, F. (2023). Generating Personalized Abstract Art Paintings by using People's Life Energy Distribution. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 6-14.

I. INTRODUCTION

Art is a form of self-expression and a way of relating to the environment and the world, which is produced by artists in fields such as painting, sculpture, music and literature, using their creativity, inspiration and imagination to convey, experience and inspire others with various emotions, ideas and experiences. Art is a multifaceted concept that can take many different forms and serve many different purposes, revealing different perspectives and interpretations in people. **Visual Art** refers to art forms such as painting, sculpture and photography, which by their nature can be understood and perceived with the sense of sight instead of other emotions. As one of the forms of art, it can evoke different feelings and convey thoughts and inspiration. Throughout history, visual arts have been one of the most powerful ways for society and people to express themselves. **Abstract Art** does not attempt to create an accurate depiction of visual reality [1], instead abstract artists draw inspiration for feelings and ideas from visual references in the world and create non-representational or non-objective compositions using the language of shape, form, color, sign and line [2], which allows the artist to project anything they want through their work [3]. Arshile Gorky said

“Abstraction allows man to see with his mind what he cannot see physically with his eyes.” Because abstract art is not a recognizable subject, it is open to viewers to interpret the work according to their own experiences, feelings, perspectives and methods. **Visual Abstract Art** is a genre used by artists as a way to explore complex ideas or emotions that are often difficult to express in more representational forms, allowing them to communicate them in a clear and accessible way to a wide audience.

Algorithms can be used to create Art that reflects the developer's/artist's perspective as well as solve complex math problems. A creator can use the computer to create artifacts like a painter using his/her brush on the canvas. While in some of these applications, the computer is only responsible for calculating certain "creative" results that the developers want to achieve. In other applications, computers act/work like a partner of the developer and affect the journey of the creator. It reflects the computer's characteristics over the result, shifting the results that were designed and planned by the creator. This is regarded as Art created by an Artist (Developer) cooperated by a computer and examined under the subject Computational Creativity. Computational creativity may or may not involve Artificial Intelligence (AI). Image Generation/Image Synthesizing is the study of generating or

synthesizing images using different techniques including AI, Machine Learning, Creative Algorithms or/and Computational Creativity. Machine Learning based Neural Style Transferring (NST) methods are used to apply the style of an image to the content of another image. Some types of NSTs use Convolutional Neural Network (CNN) and Generative Adversarial Networks (GAN) in the background.

Researchers, Artists and Developers have already worked on Data Visualization and Generative Art. There are studies that use real-life data and regard humans as a source of real-life data. Some of these studies use data to mathematically visualize with more pragmatic approaches, while others use it for more artistic purposes. In this study, a new method of artistic data visualization based on mathematical foundations is proposed, adhering to the abstract art genre. The aim was to create personalized artworks that bring art and people together, reflecting the differences of people with different interests and artistic tastes on digital canvas. Also the system purposed to reveal the diversity in people's lives using art and to transform the energy distribution in people's lives into abstract pictures using Creative Computing and NST methods. In the first step, a 4-stage questionnaire was applied to obtain data from the identified participants. A survey application was developed in Python and QT to collect participants' personal information, their 5 favorite colors, their 3 favorite paintings among the 200 paintings (10 popular paintings by 20 popular painters) and the energy distribution tree of their lives. This real-life data was processed to create different types of tree images inspired by botanical real-life trees. These images were combined to create content images, and finally, the styles and textures of the user-selected style images were transferred to the content images using NST to create the result images.

The paper is structured as follows; In Section II a comprehensive review of literature is performed to demonstrate similar studies. Section III explains the user data, the artistic data, the tools and the libraries used in the study. Section IV introduces the components of the proposed method including collecting data over people, generating content images, using NST to create result images and evaluating the results of the user. Section V presents the experimental results and finally conclusion and future works are drawn in Section VI.

II. RELATED WORKS

Although Art and Science are considered as two different concepts and fields today, they were originally rooted in the same word and their meanings were very similar. In the Middle Ages, logical subjects such as geometry, astronomy and logic, which today are classified under science, were taught under the liberal arts in the first universities, because the word Art originally meant Logic [4]. One of the interests of Science has always been to produce Art. Although one of the two basic views on data visualization evaluates data visualization more pragmatic such as usability and simplicity, the other argues that using visual aesthetics will convey data better by activating human emotions [5]. Based on this view, Science and Art came together once more and the idea of Artistic Visualization of Data was born. Today, the use of art and data visualization together has gone beyond only transferring data, but also enabling people to identify and relate to data and strengthen their experiences [6-8].

Data visualization has an important role in improving the quality of transferring relationships, meanings, knowledge, structures and hidden features of data to individuals. Visualizing data that is only available in text form enables it to be understood by people who do not have expertise in the field. Moreover, it enables experts from different fields to perceive data in the same way and makes it possible to work together [9].

Today, data visualization is an undeniable necessity to improve the quality of understanding, transfer and use of data [10-14]. While companies benefit from the data visualization services of the leading companies in the market for their internal and external works, processes and projects, researchers and developers scan the data visualization literature to find the most suitable solutions for their data, aim and the group they will interact with [9]. Finding the appropriate service and/or method is vital for data visualization. To determine the well-fitting data visualization method; the characteristics of the data, application and the needs of the target audience should be examined and taken into account [9]. Only the right method can improve the user experience as it strengthens and facilitates the user's understanding of the essence, structure and relationships of the transmitted data [9, 13, 15, 16]. Beyond that, there are studies showing the positive effects of personal data visualization on user experience [17]. These studies show that the user experiments are different even among sub-methods of the same visualization method [12]. Due to the abundance of data visualization methods available, it is increasingly difficult to create new visualization techniques. However, developers still have the opportunity to leverage existing visualization methods to design customized methods aligned with their specific goals [10, 16]. Some researchers are working on the artistic visualization of data in order to go beyond the traditional data visualization [6, 17]. The belief is that artistic visualization of data will strengthen human perception since humans are beings with emotions beyond pure logic [5, 6, 17]. The artistic visualization of data enables individuals to establish a personal connection and identification with the data [5, 6, 17].

Today, data can be obtained from different sources including IoT, Embedded Systems, Medical and Real Life [6, 7, 15, 18]. The natural data visualized in previous studies can be exemplified by information about the landing and take-off of airplanes at an airport in the last 10 years, the height of the waves in a sea during the year, the seasonal wind information in a continent, the interactions of a person with the people around. Such transitions can occur both from nature to science and from science to nature [15]. In our study, the percentages of the daily activities of the people are used as a natural data for artistic visualization.

Botanical visualization of a tree structure is a data visualization method based on the representation of hierarchical data similar to real-life trees [15, 19, 20]. In particular, visualizing complex, large and dense hierarchical data with a structure that people are familiar with from real life makes the understanding and perception of data easier [15]. As an example of the field of genetics, the number of species and the hierarchies between them are high and complex. To make it easier for genetic researchers to access, understand and use the data, an application has been developed to represent this tree-based data [19].

The artistic data visualizations generated by science have now gone beyond data visualization and have evolved into computer-generated art [6]. While it was controversial in the past that the computer could be smart beyond making art, today they exhibit striking examples of creativity [8]. On the other hand, it is possible for the computer to produce aesthetic and artistic results and produce art by partnering with a developer/artist. These applications can be produced with Creative Computing and Artificial intelligence [8, 21, 22]. The terms "Generative Art," "Computational Art," and "Cybernetic Art" are occasionally used interchangeably, while at other times they carry distinct connotations. At this juncture, the interpretation of these concepts is somewhat contingent upon the perspective of the artist or developer involved [21]. Today, the results of some creative studies in this field are subjected to the Turing Test and the results that are believed to be made by humans can be considered more valuable [8]. In addition, the outputs of these applications produced as visual or others may have commercial potential [23]. According to Guernica, the creators do this in the hope that their creations will engage people's minds on an emotional or cognitive level. In computational creativity research, the shared objective is to develop systems that can challenge humans through artistic and scientific means [8].

In addition to Creative Computing, AI can also be supported to produce Art with the Computer. NST applications can be used with or without CNN and GAN in the background [22, 24]. These systems involve working on a group of images to produce similar images and transferring the texture and styles of images onto other images. In this study, NST techniques were applied to create artistic textures by transferring users' preferred artistic styles to content images generated through Creative Computing.

III. MATERIALS

Due to the focus on human and art subjects within this study, the collected data from participants and artists is of paramount significance within the system. Four primary categories constitute human data, namely *Personal Information*, *Color Selections*, *Painting Selections*, and the *Live Energy Distribution Tree*. Personal information encompasses the general identifying information of the person, such as name, surname, and age. Color selections consist of 5 hexadecimal colors specified by the user. Painting selections involve 3 images selected by the user from our library of 200 images. The Live Energy Distribution Tree represents a hierarchy of the activities that the person engages in daily, divided into percentages. All user data is stored in JSON data file format. A partial sample data file of a person is shown in Figure 1.

Various tools, libraries, and auxiliary files were used during the study to process the user file and create artistic visualizations. At the beginning of the study, a GUI (General User Interface) application was developed to receive data from users and manage the system. Initially, QT was used to develop a cross-platform GUI application, but then a switch was made to Python on PyCharm CE. Also the Visual Studio Code was used for data and file processing. The free version of Google Colab was used for NSPT.ipynb [25, 26], which was used for neural style transfer. Graphic for MacOS was also utilized to develop designs before engaging in creative coding.

```
{
  "User_Art_Style": [
    { "FirstName": "Vincent", "LastName": "van-Gogh",
      "Painting": "The-Starry-Night",
      "Style": "Post-Impressionism", "Genre": "Cloudscape" },
    { "FirstName": "Vincent", "LastName": "van-Gogh",
      "Painting": "Cafe-Terrace-at-Night",
      "Style": "Post-Impressionism", "Genre": "Cityscape" },
    { "FirstName": "Pablo", "LastName": "Picasso",
      "Painting": "Le-Reve",
      "Style": "Cubism", "Genre": "Portrait" }],
  "User_Colors": ["9a194d", "000075", "ffa1cd",
    "ffd919", "800000"],

  "User_Information": {
    "Age": "26", "Email": "@", "Gender": "Male",
    "FirstName": "Furkan", "Profession": "Engineer"
    "LastName": "Ayas", "Nationality": "Turkish"},

  "Person_Energy_Distribution": [
    {"Description": "RP", "Level": "0",
      "Name": "Root", "Percentage": "100"},
    {"Description": "Optional", "Level": "00",
      "Name": "Work", "Percentage": "40"}, ... ]
}
```

Figure 1. A Partial Data of Candidate in JSON format

As part of the study's libraries, Json was used to write and read data. Matplotlib was used for some mathematical calculations. Visualizations were based on drawing and coloring, and the features of the Turtle Library were used for this purpose. Networkx, Squarify, NumPy (Numerical Python), and PIL (Pillow) were also used for graph creation, image display, and image saving. After comparing the results of different color extraction methods in terms of consistency and visual similarity, ColorThief was chosen to extract the dominant colors of the images.

The *Artists_and_Paintings_Data* File contains a comprehensive collection of information related to the 20 artists included in our research study. This file includes the first names, surnames, artistic styles, and the years during which the artists were actively engaged in their artistic pursuits. Moreover, it contains detailed records of their paintings, including the titles, genres, and corresponding links to WikiArt. The *Genres_and_Style_Data* File holds the definitions of the genres and styles of the images, along with the hierarchical information between them. The *Colors_Names_Data*, color naming library was created specifically for the study. Since users may not understand the hexadecimal representation of colors, colors were represented with names corresponding to their codes in places where the user was active, such as the evaluation document. The *Color_Information_Data* file consists of characteristic descriptions of 12 colors. After the extraction of the 3 dominant colors from the user's result image, a short color-based characteristic analysis is performed using this data.

IV. METHODS

The proposed system consists of 4 main methods including *Data Collection*, *Content Image Generation*, *Output Image Generation* and *User Result Evaluation* as illustrated in Figure 2. The detailed explanation of all the parts is given in the following subsections.

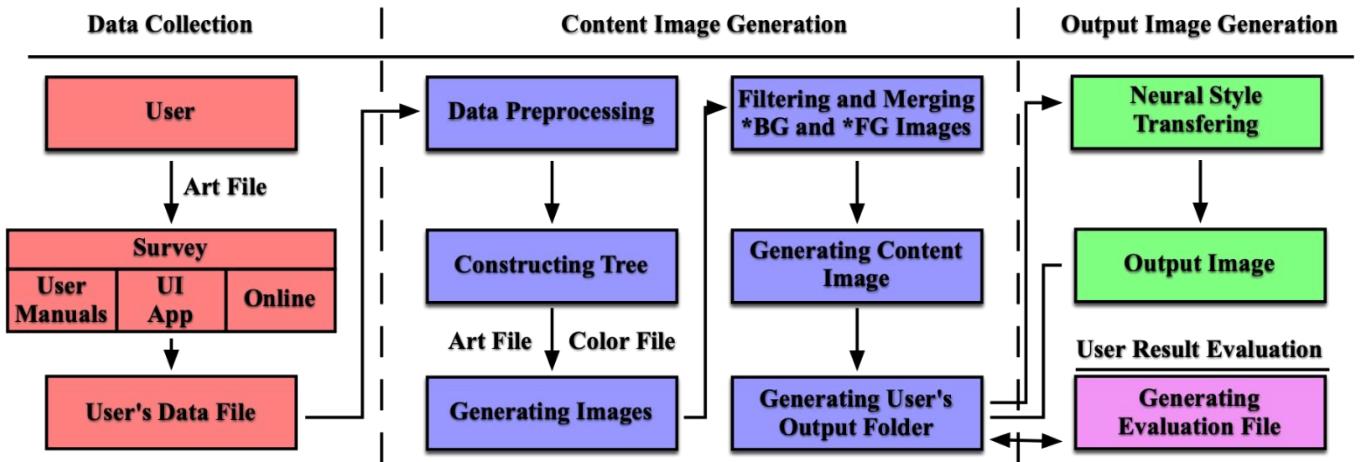


Figure 2. General Overview of Proposed System

A. Data Collection

Data is collected through different types of surveys to ensure compatibility and flexibility with our users. The first survey method is the GUI survey application (shown in Figure 3); it is a standard survey application where the blanks are filled in and selections are made by the user. The second method is the e-mail survey method; if candidates are unable to fill in all the blanks and/or want to think more or make changes to their answers, they are directed to online manuals. Even in face-to-face GUI surveys, the system is preferably explained with the manuals.

The third method is the online survey method; in cases where people are interested in the study but do not have time to complete the survey, they are sent our self-explanatory online survey, and their answers are submitted following simple steps. The data is then pulled from the cloud results table. The online manuals and paintings library are always accessible to users. Even in face-to-face GUI surveys, the system is preferably explained with the manuals.

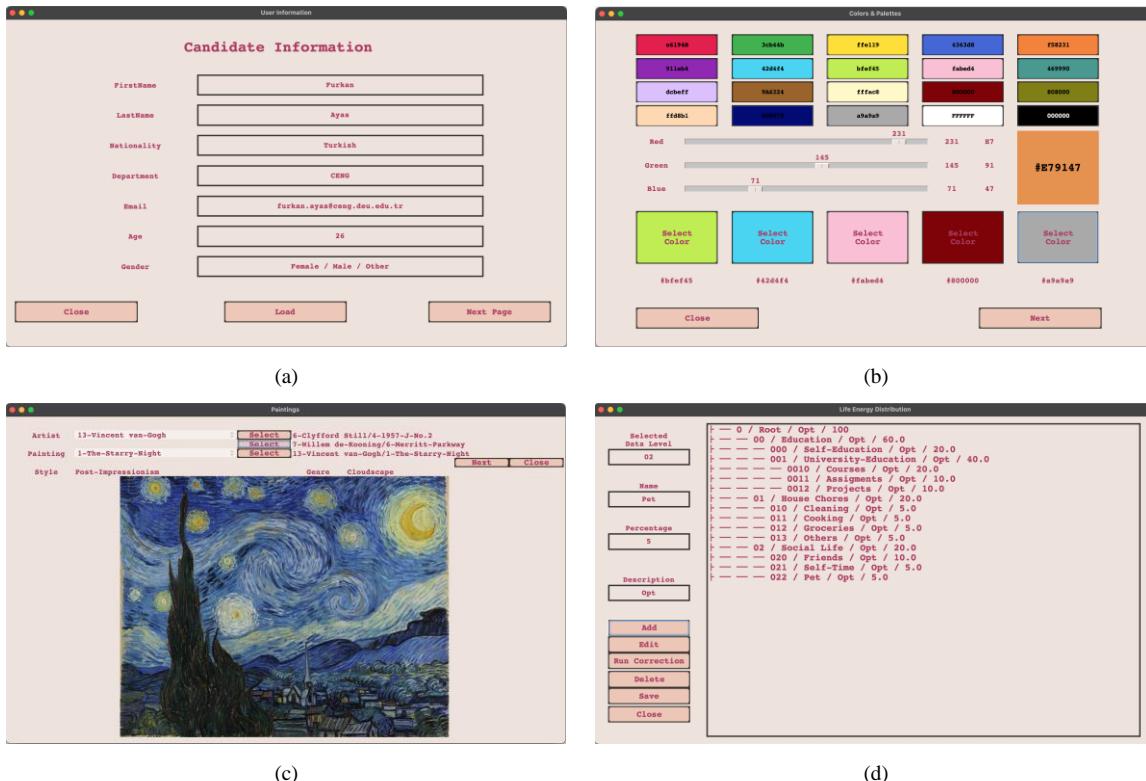


Figure 3. (a) Personal Information UI, (b) Color Palette UI, (c) Painting Selections UI, (d) Index-Based Life Energy Tree Input UI

B. Content Image Generation

People are prone to make mistakes when dividing their life's activities into percentages. Therefore, a pre-processing system was developed that eliminates potential errors in the data. After this data preprocessing step, the system constructs an n-

ary tree from the naturally hierarchical data. Then, new visualization attributes are assigned to each node to create visual trees according to the default tree values determined by the experiments. After the assignments, the data is ready to

produce botanical-based tree visualizations. At this point, the Artistic Visualization system developed using Creative Algorithms is starting to produce different visuals.

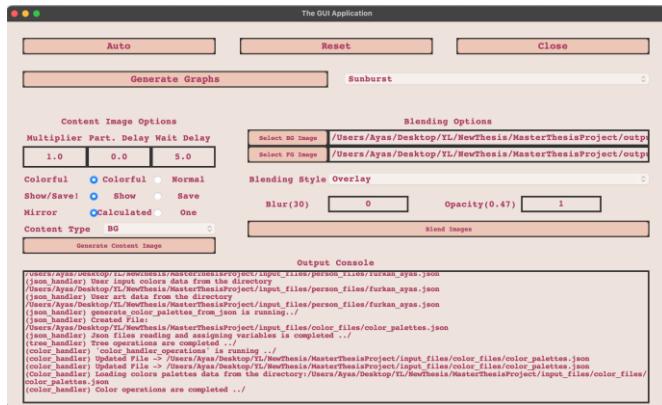


Figure 4. Content Image Generation UI of the Proposed System

The Life Energy Distribution Tree Visualization system (shown in Figure 4) is able to make visualizations in various ways based on the Content Type option, and all these ways are rooted in the Botanical Real-Life Tree inspired base visualization's structure. *TREE* is the main method, *FG* (Foreground) projects the all activities, *FG-TREE* (TREE over Foreground) shows how the FG occurs from the Tree, *BG* (Background) projects the all branch activities, *BG-TREE* (TREE over Background) shows how the BG occurs from the Tree, *BG-FG* (Foreground over Background) is the direct merge of BG and FG in order. *BG-FG-TREE* is the direct merge of the BG, FG and TREE. *DOTS*, *DOTS-LINES*, *LINE*, *RADIAN*, *SINE* are other methods not focused on at this stage of the study.

The other options of the content image generation system are *Mirror*, *Colorful*, *Multiplier*, *Partial Delay* and *Wait Delay*. The mirror creates circular reflections according to the maximum depth of the tree -inspired by the petals of the flowers-. When the mirror option is active, the same activities are reflected in the reflections with the same colors, but the colorful option allows the same activities to be reflected in the reflections with different colors. The multiplier is multiplied by all predefined length dimensions, making them longer and shorter. This also provides a zoom effect and makes the output image easier to inspect. The Partial delay creates a pause between all activities, so that the user and the developer can follow the system and the stages of image generation. The wait delay freezes the resulting image when the developer wants not to save the result or only to show it to the user.

All the variables of the Tree are assigned while constructing the tree. Some values are set defaults. Level and the some Inner Variables directly taken from candidate such as *Name*, *Description* and *Percentage* but all the other ones are calculated over this data such as *Length*, *Angle*, *Regional Angle*, *Direction*, *Width*, *Path*, *Position*, *Child Number*, *Branch Angle* and *Central Angle*.

For the next steps of our study, the focus was narrowed down to only two of these images, despite the system's ability to visualize the data in various forms; *BG* (Background) and *FG* (Foreground). These 2 images are filtered with *Overlay*, *Opacity* value 0.47 out of 1 and combined with 30% *Blur*. The *Blur* value ensures that the regional transitions in the Result Image are smoother, so that the resulting image is more natural

and people are less likely to realize that it is computer generated.

During all of these content image generation processes, colors are also used frequently. There are 7 palettes in total and each one consists of 5 colors. The first palette consists of the user's favorite colors. It's created by the user selecting the desired colors. The second, third and fourth palettes are the 5 dominant colors of each of the selected paintings. The fifth, sixth and seventh palettes are calculated from our palette library based on the first palette -the user's palette-. So each user has a total of 35 colors for coloring and the system uses them in a prioritized circular order.

C. Output Image Generation

In Figure 5, as depicted, the content image is created into the user's output folder (as illustrated in Figure 2). This folder is then imported into NSPT.ipynb [25, 26], a widely used, well-known, well-developed, open-source neural style transfer system. It is run on Google Colab. At this stage of the study, a specialized NST has not been developed as the focus is on transferring people to art using Computational Creativity under Creative Art. However, as one of the future works, a more specialized NST system would be desired to be developed.

Nevertheless, tests have been conducted on the system options to make this NST implementation more customized to our needs. All 20 options have been tested with different values and combinations, and the results have been analyzed to make each option suitable for each iteration. Although the system comprises 20 options, some of them are not informative, so only the effective ones will be described to produce our results.

Since the system uses 8 iterations with sub iterations, an *ipython* script has been developed to manage the system, set NSPT options, and integrate this system with the cloud part of our system. GPU has been chosen as the processing unit of option since it is known to be a better power source than CPU in Visual ML computing systems. The *init* option is set to random for the first iteration because noise is used as the starting point instead of an image. For the other iterations, instead of using noise, the generated output of the previous iteration is used as the input image. The *content_weights* option affects how much weight should be given to the term style reconstruction. Precise testing has been performed with values of 1, 5, 10, 20, and 50, and it has been found that 5 is the best for the system.

Since the user colors and other palettes were processed in the previous content image generation phase, in this step, the *original_colors* are set to preserve them. The other option is to extract and reflect the colors of the input style images. For the *pooling* option, *avg* is preferred over *max* due to limited resources and better RAM optimization. Other options of the system have also been optimized to achieve better results as suggested by the developers for the *avg* option.

The *style_blend_weights* are also kept equal, as the default option, since there is no prioritization between style images (the users' painting selections). The *style_scale* option defines the extraction of features from style images, and after testing values of 0.5, 1.0, 1.5, and 2.0, the value of 0.7 has been set for our system. The *cudnn backend* option has also been chosen to reduce memory usage based on our examinations.

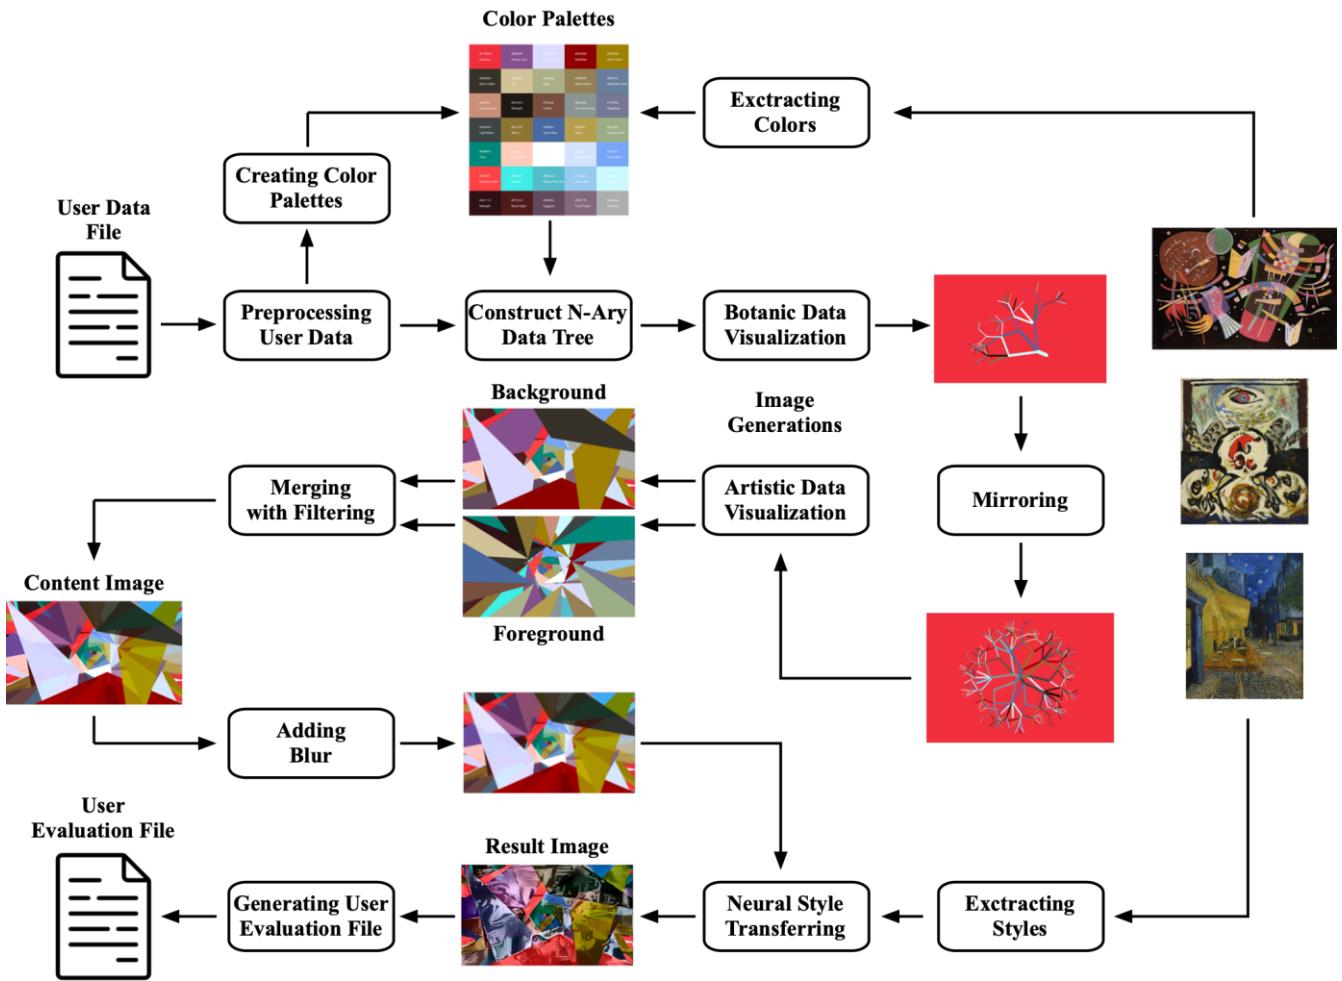


Figure 5. Artistic Data Visualization System Flow

Table 1. Options by Iterations

IT: ITERATION, SID: STYLE_IMG_DIR, CID: CONTENT_IMG_DIR, MF: MODEL FILE, OI: OUTPUT_IM

	IT1	IT2	IT3	IT4	IT5	IT6	IT7	IT8
style_weight	100K	100K	100K	100K	100K	100K	100K	10K
num_iterations	1000	1000	1000	1000	1000	200	200	10
image_size	512	768	1024	1400	1400	1800	3600	7200
model_file	MF1	MF1	MF1	MF1	MF1	MF2	MF2	MF3
optimizer	lbfgs	lbfgs	lbfgs	lbfgs	lbfgs	lbfgs	adam	adam
tv_weight	0.000 01	0	0.000 01	0	0	0	0	0

The options that are changed from iteration to iteration are shown in Table 1. The style restructuring term is weighted by the *style_weight*, and the values in the table were set after testing the values 500, 5K, 20K, 1M, and 10M. The number of iterations is determined by *num_iterations*. Testing was

conducted from 500 to 10000 in a range of 500 steps. The horizontal image size of the output image in pixels is denoted by *image_size*. Higher values are used to generate high-resolution outputs, and even higher values are used to generate outputs that are more suitable for canvas printing. The Path to the .caffemodel file for the VGG Caffe model is specified by *model_file*. The default is the original VGG-19 model, and the defaults were kept for the 8 iterations. The optimization algorithms to be used, lbfgs or adam, are selected using the optimizer option. The *learning_rate* option was set to 1 from the values 1, 4, 10, and 20 that were tested, as the system is using the ADAM optimizer for IT7 and IT8. The total-variation editing weight, which helps to smooth the image, is represented by *tv_weight*, and the default values for this option were also kept.

D. User Data & Result Evaluation

As the study is based on People and Art, the people surveyed found the study very interesting and took the time to help. They also expressed a desire to see the resulting artistic visualizations. Therefore, an evaluation file generation system was developed, both to link the results to an academic standard and to thank the users by sending them their results.

At the final step of the system, it reads all the input and output files of the previous steps and generates an evaluation file. This step is based on the final status of the *output_folder*. Which contains; All the *Content Images*, *User Data*, *User*

Color Palettes, User Tree Graphs and Result Image. The evaluation file contains; User Personal Information, Tree Data Evaluations, User Color Palettes, User Style Images and the explanations of their Genres and Styles, Result Image Color Extracted Character Analysis, User Data as table, Tree Graphs (Tree Graph, TreeMap, SunBurst, Icicle, Kamada-Kawai Graph), Generated Content Images (TREE, FG, BG and combinations of these three and BLENDED) and the Result Image. Figure 6 shows 2 examples of Content Images that are not used to create the result image but help explain the system. Figure 6 (a) shows how activities of a person are visualized through botanical based visualization and Figure 6 (b) shows how mirroring works. In the evaluation file, they are used to describe and transfer the process and method to individuals.



(a)



(b)

Figure 6. (a) An Example Content Image, Multiplier 2, Mirror is False (Colorful is automatically False) (b) An Example Content Image, Multiplier 2, Mirror is True, Colorful is False

V. EXPERIMENTAL STUDIES

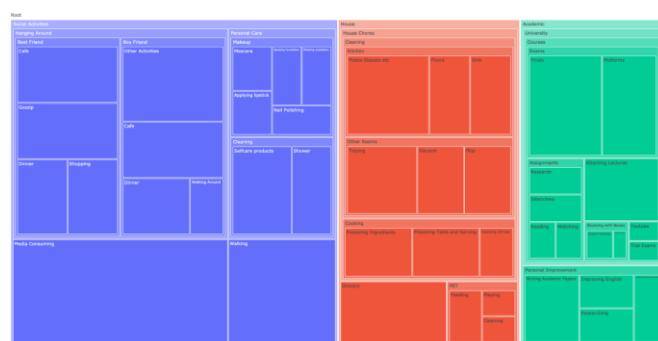


Figure 7. TreeMap Visualization of a Sample User Data

The test subject is a senior electrical and electronics engineering student, and her life energy distribution data is represented as TreeMap in Figure 7. Her life is divided into three main activities, *Academic*, *House* and *Social*. Even though most students have similar divisions, they represent

their life in very different ways. This diversity is something to be observed in the study. Their description and representation of their life in their way has an important effect on creating Art of their lives. It allows the data to be personalized. This subject's data visualization is also shown in Figure 5 in our method with all the steps.

The difference between our method and the TreeMap method is understandably quite large. In total, there are more than 300 tree visualization methods and TreeMap is considered to be one of the most space efficient. TreeMap was introduced as a solution to the problem of standard Tree Graphs, which require a lot of space, especially as you go to the leaf nodes, but even in this document, TreeMap is insufficient to represent relatively small data. Functional digital TreeMaps can use space more efficiently by moving inwards with a clicking. TreeMaps are suitable for all kinds of hierarchical data. On the other hand, our system can be displayed in the same way in a document like this one, or on canvases meters high. Although our system is based on hierarchical tree data, it is an artistic representation developed specifically to visualize humans. It needs the user's color and painting information.

Based on this comparison of the same data, it can be said that the right visualization for the right data is essential in data visualization, as all visualization research indicates.



Figure 8. Key Visualizations Generated During the Processes

Figure 8 shows the basic visualization steps of two different users' data. (a) the users' color palettes, (b) the generated

botanical-based visual trees using the users' preprocessed data and the generated color palettes, (c) the content images obtained after mirroring (b) and creating BG and FG images from it and then combining them with filtering, (d) the user's painting selections, (e) the result images after the neural style transfer. This figure shows how the system generates a botanical-tree inspired representation of the data and then builds a content image on it using palettes, and then uses the selected paintings at NST step for the create the result visualizations.

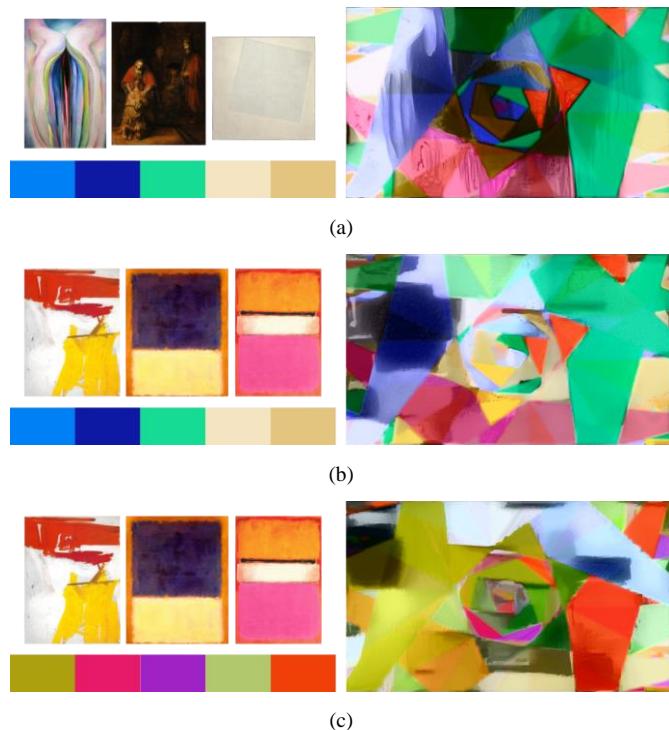


Figure 9. Comparison of Outputs

Figure 9 shows how the output image varies according to the effects of the user's color selections and painting selections. The 3 images on the left show the painting selections, the 5 colors on the left show the color selections and the image on the right shows the user's output image. (a) and (b) has the exact same color selections but the painting selections are different. (b) and (c) have same painting selections but different color selections. The user's color palette is the highest priority among the 7 palettes -the next three palettes come from the 5 dominant colors of the selected paintings and the other 3 palettes are calculated from the user's palette-. The effect of the palettes can be easily observed in this Figure while creating the content image. The effect of the selected images used in neural style transfer on texture transfer is also observable in the same Figure.

VI. CONCLUSION

The right visualization method suitable for the data and the target audience, or even a new method based on existing methods, is essential to effectively convey the data in data visualization. In this study, an artistic visualization system has been developed to represent people's daily life activity & energy distribution data. To achieve a Creative Computing study, the data was processed with special Creative Algorithms and Neural Style Transfer.

In the study, not only mathematical data but also people's favorite colors and artistic perspectives were used to reflect the

human being in a unique way. The results of the system are also open to interpretation, just like the people themselves. At the end of the study, it was observed that the proposed system produced consistent results and thus created a specific art style. This observation can be interpreted as the creation of a new sub-art style during the study.

For future work, it is aimed that the system have developed during the study, will be supported with licensed images and offered as an online service, so that individuals and institutions can produce and use artistic result images that reflect themselves or the people concerned. Activities will be categorized into selectable categories as a support system and further additions will be possible.

VII. RECOMMENDATIONS

The artistic outputs produced by the system are expected to be used in future phases to interpret, group of people in a non-mathematical way, through the observation of art. The users should be divided into groups such as students and professionals, and it should be observed what similarities and differences the data of students from different majors have in the resulting images, or what commonalities the members working in the same team have.

With a system of predefined activities based on the selection to be made in the background, it is expected to observe the similarities and differences between the results of people with similar lives in terms of activities. Thus, the interpretation of the observed results and the evaluation of the new results that are being generated will allow our study to be used for the interpretation and evaluation of people and groups.

Authors' Contributions

The authors' contributions to the paper are equal. The study and article were conducted by Furkan Ayas and supervised by Feriştah Dalkılıç.

Statement of Conflicts of Interest

There is no conflict of interest between the authors. Furkan Ayas is the creator, owner and implementer of the idea and Feriştah Dalkılıç is the academic advisor of the article processes.

Statement of Research and Publication Ethics

The authors declare that this study complies with Research and Publication Ethics. This project has no commercial interest, as we use paintings by 20 well-known artists as style images.

VIII. REFERENCES

1. S. Kumari, "What is meant by abstract painting?," The Statesman, <https://www.thestatesman.com/features/meant-abstract-painting-1503052291.html> (accessed May 17, 2023)
2. Rudolph Arnheim, Visual Thinking, University of California Press, 1969, ISBN 0-520-01871-0
3. D. Nimmer, "What is abstract art (and why should I care)?," Artists Network, <https://www.artistsnetwork.com/art-inspiration/what-is-abstract-art/> (accessed May 17, 2023)
4. D. E. Knuth, "Computer programming as an art," Commun. ACM, vol. 17, no. 12, pp. 667–673, Dec. 1974, doi: 10.1145/361604.361612.
5. Q. Li, "Data visualization as creative art practice," Visual Communication, vol. 17, no. 3, pp. 299–312, Aug. 2018, doi: 10.1177/1470357218768202.

6. F. B. Viégas and M. Wattenberg, "Artistic Data Visualization: Beyond Visual Analytics," in Online Communities and Social Computing, D. Schuler, Ed., in Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2007, pp. 182–191. doi: 10.1007/978-3-540-73257-0_21.
7. S. Alvaro, "Art and Data: the aesthetic emergence of knowledge." in Proceedings of the 5th Computer Art Congress, 2016, Paris, France, pp. 108-125.
8. S. Colton, R. Mántaras, and O. Stock, "Computational Creativity: Coming of Age," *AI Magazine*, vol. 30, pp. 11–14, Sep. 2009, doi: 10.1609/aimag.v30i3.2257.
9. M. Islam and S. Jin, "An Overview of Data Visualization," 2019 International Conference on Information Science and Communications Technologies (ICISCT), Tashkent, Uzbekistan, 2019, pp. 1-7, doi: 10.1109/ICISCT47635.2019.9012031.
10. H. -J. Schulz, "Treevis.net: A Tree Visualization Reference," in IEEE Computer Graphics and Applications, vol. 31, no. 6, pp. 11-15, Nov.-Dec. 2011, doi: 10.1109/MCG.2011.103
11. G. A. Pavlopoulos, T. G. Soldatos, A. Barbosa-Silva, and R. Schneider, "A reference guide for tree analysis and visualization," *BioData Mining*, vol. 3, no. 1, p. 1, Feb. 2010, doi: 10.1186/1756-0381-3-1.
12. L. K. Long, L. C. Hui, G. Y. Fook, and W. M. N. Wan Zainon, "A Study on the Effectiveness of Tree-Maps as Tree Visualization Techniques," *Procedia Computer Science*, vol. 124, pp. 108–115, Jan. 2017, doi: 10.1016/j.procs.2017.12.136.
13. A. Kobsa, "User Experiments with Tree Visualization Systems," IEEE Symposium on Information Visualization, Austin, TX, USA, 2004, pp. 9-16, doi: 10.1109/INFVIS.2004.70.
14. K. Onak and A. Sidiropoulos, "Circular partitions with applications to visualization and embeddings," in Proceedings of the twenty-fourth annual symposium on Computational geometry, in SCG '08. New York, NY, USA: Association for Computing Machinery, Jun. 2008, pp. 28–37. doi: 10.1145/1377676.1377683.
15. E. Kleiberg, H. van de Wetering and J. J. van Wijk, "Botanical visualization of huge hierarchies," IEEE Symposium on Information Visualization, 2001. INFOVIS 2001., San Diego, CA, USA, 2001, pp. 87-94, doi: 10.1109/INFVIS.2001.963285.
16. C. O. Wilke, Fundamentals of Data Visualization a Primer on Making Informative and Compelling Figures. Beijing: O'Reilly, 2019.
17. J. Spence, E. Schachter, A. Saleem, and B. Jia, "Increasing Data-Knowledge Through Artistic Representation," in HCI International 2021 - Posters, C. Stephanidis, M. Antona, and S. Ntoea, Eds., in Communications in Computer and Information Science, vol. 1419. Cham: Springer International Publishing, 2021, pp. 609–624. doi: 10.1007/978-3-030-78635-9_78.
18. L. Devroye and P. Kruszewski, "The botanical beauty of random binary trees," in Graph Drawing, F. J. Brandenburg, Ed., in Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 1996, pp. 166–177. doi: 10.1007/BFb0021801.
19. D. M. de Vienne, "Lifemap: Exploring the Entire Tree of Life," *PLOS Biology*, vol. 14, no. 12, p. e2001624, Dec. 2016, doi: 10.1371/journal.pbio.2001624.
20. A. Sallaberry, Y.-C. Fu, H.-C. Ho, and K.-L. Ma, "ContactTrees: A Technique for Studying Personal Network Data." arXiv, Oct. 31, 2014. doi: 10.48550/arXiv.1411.0052.
21. S. Laurentiz, "Conformed Thought and the Art of Algorithms," in Proceedings of the 9th International Conference on Digital and Interactive Arts, in ARTECH 2019. New York, NY, USA: Association for Computing Machinery, Feb. 2020, pp. 1–8. doi: 10.1145/3359852.3359871.
22. C.-C. Lin, C.-B. Hsu, J.-C. Lee, C.-H. Chen, T.-M. Tu, and H.-C. Huang, "A Variety of Choice Methods for Image-Based Artistic Rendering," *Applied Sciences*, vol. 12, p. 6710, Jul. 2022, doi: 10.3390/app12136710.
23. W. Duch, "Computational Creativity," in The 2006 IEEE International Joint Conference on Neural Network Proceedings, Jul. 2006, pp. 435–442. doi: 10.1109/IJCNN.2006.246714.
24. Q. Cai, M. Ma, C. Wang, and H. Li, "Image neural style transfer: A review," *Computers and Electrical Engineering*, vol. 108, p. 108723, May 2023, doi: 10.1016/j.compeleceng.2023.108723.
25. L. A. Gatys, A. S. Ecker, and M. Bethge, "A Neural Algorithm of Artistic Style." arXiv, Sep. 02, 2015. doi: 10.48550/arXiv.1508.06576.
26. Egan, B. (2018). neural-style-pt (Version 1.0.0) [Computer software]. <https://github.com/ProGamerGov/neural-style-pt>

Hava Lidar ve fotoğraflardan kentsel alanların digital ikizinin oluşturulması ve karşılaştırılması

Cihan Altuntaş^{1*}

¹*Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita, Konya, Türkiye (caltuntas@ktun.edu.tr) (ORCID: 0000-0002-5754-2068)

Özet – Arazi topografiyası ve ilişkili detayların nokta bulutu şeklinde sayısallaştırılarak bilgisayar ortamına aktarılması çok sayıda uygulamada vazgeçilmez hale gelmiştir. Araziye ilişkin her türlü planlama, akıllı şehir uygulamaları ve diğer hizmetler için bu sayısal verilerden yararlanılır. Hava Lidar ve fotogrametri geniş alanların kısa sürede sayısallaştırılması için yaygın ölçme teknikleridir. Hava lidar sisteminde belirli bir açı artışı ile yönlendirilen lazer ışınları ile tarama yapılarak nokta bulutu ölçülür. Fotogrametrik nokta bulutu yöntemi teknik bilgi gerektirmez ve düşük maliyetlidir. Konumsal verilerin entegrasyonu için elde edilen nokta bulutu ölçülerinin jeodezik koordinat sistemine dönüştürülmesi gereklidir. Bu çalışmada Lidar ve fotogrametrik yöntem ile kentsel alanların 3B modellemesi yapılmıştır. Nokta bulutu verileri uçuş esnasındaki konum bilgileri ile jeodezik koordinat sistemine dönüştürülmüştür.

Anahtar Kelimeler – Lidar, fotogrametri, nokta bulutu, jeodezik koordinat, kentsel alan modelleme

Atıf: Altuntaş, C. (2023). Hava Lidar ve fotoğraflardan kentsel alanların digital ikizinin oluşturulması ve karşılaştırılması. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 15-19.

Digital twin generation and comparison from aerial Lidar and images in urban area

Extended Abstract

Research Problem/Questions – For the integration of spatial data, the obtained point cloud measurements need to be registered to the geodetic coordinate system. In this study, 3D modeling of urban areas was made with Lidar and photogrammetric method.

Short Literature Review – Lidar measurements are in the form of a point cloud that represents the measuring surface with its actual dimensions. Integration of measurements into the common geodetic coordinate system is done either using the ground control points (GCP) or with flight data at the time of measurement [1]. Using a ground control points improves accuracy, but has a high workload cost. Geodetic coordinating with direct flight data provides adequately accurate geodetic coordinating for many applications [2].

Methodology – To be able to use the lidar point cloud for mapping, it must be registered to a geodetic coordinate system. The registration to the geodetic coordinate system is done by three methods: GCP, flight data and data processing. Coordinating is easily done with GNSS data during flight. It uses direct georeferencing, global navigation satellite systems (GNSS) and inertial measurement unit (IMU). The GNSS records the position (XYZ coordinates) and the IMU records the rotation, tilt, yaw angles around the axis at the time of recording. These parameters are combined and each measured Lidar point is converted directly into the georeference system. The lidar point cloud is precisely georeferenced with minimal processing. Direct georeferencing is currently the most widely used method for LiDAR point cloud data. Geodetic coordinates of the photogrammetric point cloud are easily done using the camera projection center coordinates recorded by GPS during flight. This process is a fast and efficient method for geodetic coordinating of the photogrammetric point cloud.

Results and Conclusions – Different types of land cover can affect point accuracy. However, there was no significant difference between Lidar and photogrammetric point cloud in this study.

Keywords – Lidar, photogrammetry, point cloud, geodetic coordinate, urban area modelling

Citation: Altuntaş, C. (2023). Digital twin generation and comparison from aerial Lidar and image in urban area. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 15-19.

I. GİRİŞ

Araziye ilişkili her türlü görüntüleme ve planlamada nokta bulutu ölçme tekniklerinden yararlanılır. Hava Lidar ve fotogrametri yöntemleri ile kentsel alanların haritalanması ve modellenmesi kısa sürede yüksek doğrulukla yapılabilir.

Lidar ölçüler, ölçme yüzeyini gerçek boyutları ile temsil eden nokta bulutu şeklindedir. Ölçülerin yaygın jeodezik koordinat sistemine entegrasyonu ya kontrol noktası kullanılarak ya da ölçme anındaki uçuş verileri ile yapılır [1]. Kontrol noktası kullanmak doğruluğu artırır ancak iş yükü maliyeti yüksektir. Doğrudan uçuş verileri ile jeodezik koordinatlandırma pek çok uygulama için yeterli doğrulukta jeodezik koordinatlandırma sağlar [2].

Lidar nokta bulutunun segmentasyonu ile kentsel alandaki değişim belirlenebilir [3]. Kentsel alandaki bitki türleri ve yapısı Lidar ölçmelerinden tespit edilebilir [4]. Bitki türleri tespitinde lidar ve fotogrametri birlikte de kullanılmıştır [5]. Ek olarak Lidar tarafından sağlanan 3B geometrik veriler kentsel yeşil altyapıyı korumaya da yardımcı oldmaktadır [6]. Lidar yansıtma değerinden yüzeyin material özelliği hakkında bilgi edinilebilir. Örneğin yüzeyin kuru ve ıslak olması durumunda yansıtma değerlerinin farklı olacaktır. Bu durum yüzeylerin ayırt edilmesini sağlar [7].

Fotogrametrik görüntülerden oluşturulan nokta bulutu verisinin ölçeklendirilmesi ve jeodezik koordinatlandırma uçuş esnasındaki kamera konumları ile doğrudan gerçekleştirilebilir. Diğer yandan Lidar nokta bulutu koordinatları ile de ölçeklendirme ve koordinatlandırma yapılabilir. Bu çalışmada kentsel alan modellemesinde Lidar ve fotogrametrik (SfM) nokta bulutu yöntemleri araştırılmıştır. Elde edilen nokta bulutlarının jeodezik koordinat sistemine dönüşümü yapılarak farklı arazi örtüsü türleri için karşılaştırma yapılmıştır.

II. MATERIAL VE METHOD

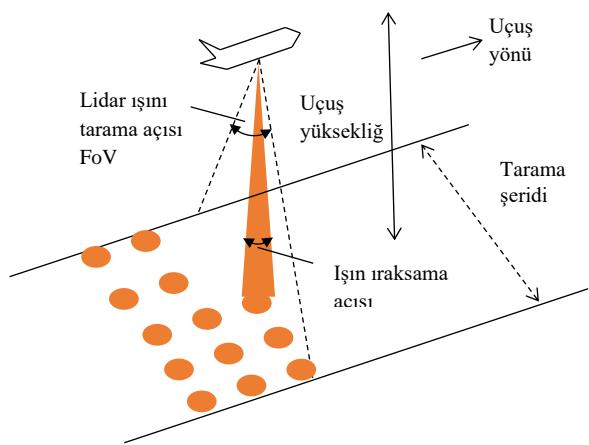
A. Hava Lidar

Lidar ölçmelerinde temel prensip ölçülen noktanın mesafesi ile ölçü işini doğrultusunun belirlenmesi ve dönen işinin taşıdığı bilginin digital kodlara dönüştürülerek kaydedilmesidir. Ölçüler alet merkezli lokal bir koordinat sisteminde ifade edilir. İşin kaynağının ölçme noktasına olan mesafesi işinin uçuş süresi ile hesaplanır. Mesafe, bilinen ışık hızı ve uçuş süresi kullanılarak doğrudan ya da dolaylı olarak hesaplanır. İşin doğrultusu, tanımlı referans sisteminin yatay ve düşey düzlemleri ile yapılan açılarla ifade edilir. 3B nokta koordinatlarının elde edildiği bu sistem 3B Lidar olarak ifade edilir.

Ölçme yüzeyinin renk ve materyal yapısı dönen işinin yansıtma şiddetini etkiler. Yansıtma oranı yüksek yüzeyler daha uzak mesafelerden ölçülebilir. Tarama noktalarının 3B konum doğruluğu büyük oranda iraksama açısı, dönen işinin şiddeti ve aletin açı ölçme hassasiyeti ile ilişkilidir.

Lidar nokta bulutunu haritalamada kullanabilmek için jeodezik koordinat sistemine dönüştürülmesi gerekir. Jeodezik koordinat sistemine dönüşümü YKN, uçuş verileri ve veri işleme olmak üzere üç yöntem ile yapılır. YKN uçuş alanında düz yüzeyler üzerine tesis edilir ve koordinatları yersel yöntemlerle ölçülür. Maliyetli ve zaman alıcı bir yöntemdir. Uçuş esnasındaki GNSS verileri ile koordinatlandırma kolayca yapılır. Doğrudan coğrafi referanslama, küresel navigasyon uydu sistemleri (GNSS) ve atalet ölçüm birimi (IMU) kullanır. GNSS, konumu (XYZ

koordinatları) kaydeder ve IMU, kayıt anında eksen etrafında dönme, eğim, sapma açlarını kaydeder. Bu parametreler birleştirilir ve ölçülen her Lidar noktası doğrudan coğrafi referans sistemine dönüştürülür. Lidar noktası bulutu en az işlem ile hassas bir şekilde coğrafi referanslandırılır. Doğrudan coğrafi referanslama, LiDAR noktası bulutu verileri için günümüzde en yaygın kullanılan yöntemdir. Veri işlemeye dayalı yöntem ölçülen nokta bulutunun daha önceden jeodezik koordinatlandırılmış noktası bulutu koordinat sistemine dönüşümü şeklinde uygulanır.



Sekil 1. Hava 3D Lidar tarama

B. Fotogrametrik Nokta Bulutu

SfM aynı örtü alanına ait farklı açılardan çekilmiş parlaklık, ölçek ve dönüklükleri farklı görüntülerin otomatik eşleştirilmesi ile kamera ve eşlenik nokta koordinatlarının tanımlı bir koordinat sisteminde ifade edilmesini içerir. Bu işlemler için kamera kalibrasyonu gerekmeyez. Kamera kalibrasyon parametreleri ve nokta koordinatları iteratif olarak hesaplanır.

SfM algoritması ile fotogrametrik nokta bulutu dört adımda oluşturulur. İlk adımda, görüntü özellik noktaları bulunur. İkinci adımda, özellik noktaları karakteristik değişmez özelliklerle tanımlanır. Tanımlayıcı, özellik noktalarını 128 boyutlu uzayda temsil eder. Üçüncü adımda tüm görüntüler arasındaki benzer özellik noktaları eşleştirilir ve dördüncü adımda işin demetleri dengelemesi ile görüntülerin görelî konumları tahmin edilir. Eşleştirme sonuçları genellikle seyrek nokta bulutudur ve bunlar daha sonra ek eşleşmelerle yoğun nokta bulutuna dönüştürülür. Ticari fotogrametri yazılımları, kullanıcıların eşleşen özellik noktalarının sayısını kısıtlamasına olanak tanır. Bu sayede çoklu görüntü eşleştirme, bilgisayar kapasitesini zorlamaz. Eşleşen tüm özellik noktaları için 3B uzamsal koordinatlar, lokal referans koordinat sistemine göre elde edilir [8]. Nokta bulutunun ölçeklendirilmesi gerçek obje üzerindekine benzer ölçü yapmayı sağlar. Ölçeklendirme ve coğrafi referanslanmanın kontrol noktasına dayalı olarak yapılması zaman ve maliyet alıcı bir işlemidir. Bunun yerine doğrudan uçuş anında GPS ile kaydedilen kamera çekim merkezi koordinatları kullanılarak jeodezik koordinatlandırma yapılır. Bu işlem fotogrametrik nokta bulutunun jeodezik koordinatlandırılması için hızlı ve etkili bir yöntemdir.

C. Verilerin Elde Edilmesi

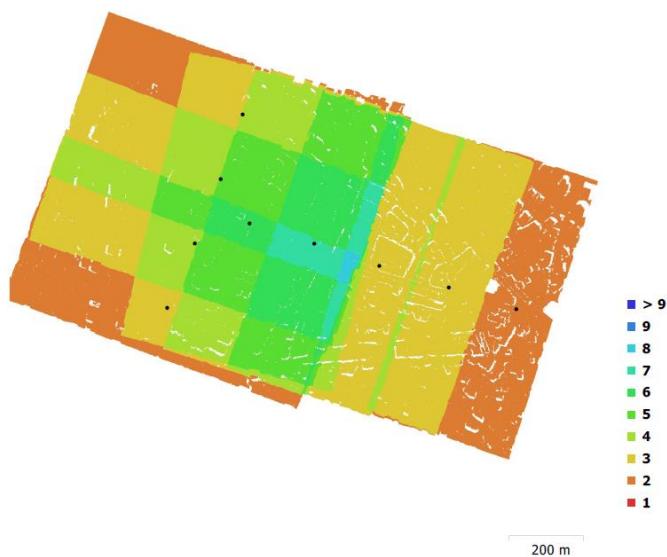
Çalışma alanı Konya ili, Kulu İlçe merkezinde 1.11km^2 lik bir alandır ve denizden yüksekliği ortalama 1000m dir (Şekil 2). Lidar tarama ortalama 841m yükseklikten 2-3 nokta/ m^2 yoğunluk ile yapılmıştır. Lidar ölçüsü yapılrken aynı anda fotogrametrik değerlendirme için hava fotoğrafları da çekilmiştir. Fotoğraf çekimi anında kamera çekim merkezinin GPS koordinatları da kaydedilmiştir. Fotoğraflar 24 bit derinliğinde ve 10625-14204 pixel çözünürlüğündedir. Ölçme alanına ait dokuz fotoğraf kaydedilmiştir.



Şekil 2. Çalışma alanı

III. ARAŞTIRMA SONUÇLARI

Fotoğraflardan nokta bulutu Agisoft yazılımı ile üretilmiştir. Nokta bulutu "medium" özelliği ile oluşturulmuştur. Fotoğraflardan oluşturulan nokta bulutu verisinin ölçeklendirilmesi kamera çekim merkezlerinin GPS koordinatları koordinatları ile yapılmıştır. Elde edilen nokta bulutu Lidar nokta bulutu ile karşılaştırılarak farklı yüzey örtülü alanlar için doğruluk değerlendirme yapılmıştır.

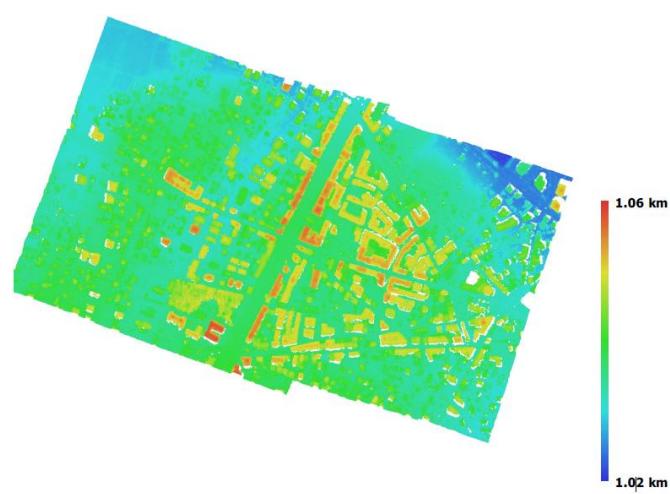


Şekil 3. Kamera konumları ve bindirmeli alanlar.

Fotogrametrik nokta bulutu dokuz fotoğrafın ortak görüntüü alanından üretilmiştir. Kamera çekim merkezleri ve fotoğraflar arası bindirmeli alanlar Şekil 3 de verilmiştir. Seyrek nokta bulutu 13831 nokta içermektedir. Bağlantı noktalarının ortalama projeksiyon sayısı 2.65 tir. Bağlantı noktalarının resim düzlemine geri projeksiyonunda ortalama hata ise 1.74 pixel dir. İşin demetleri denelemeden sonra kamera çekim merkezlerindeki ortalama hatalar Tablo 1 de ve hata elipsi büyülükleri Şekil 4 de verilmiştir. "Medium" seçeneği ile üretilen yoğun nokta bulutu 6273511 nokta içermektedir. Yoğun nokta bulutundan elde edilen sayısal yükseklik modeli bina yükseklikleri de dikkate alındığında çalışma alanında ortalama 50m kot değişimini göstermektedir (Şekil 5). Farklı örtü tiplerine sahip arazilerde Lidar ve fotogrametrik nokta bulutlarının doğrulukları etkilenebilir. Bunu tespit etmek için Lidar ve fotogrametrik nokta bulutları karşılaştırılmıştır (Şekil 6).



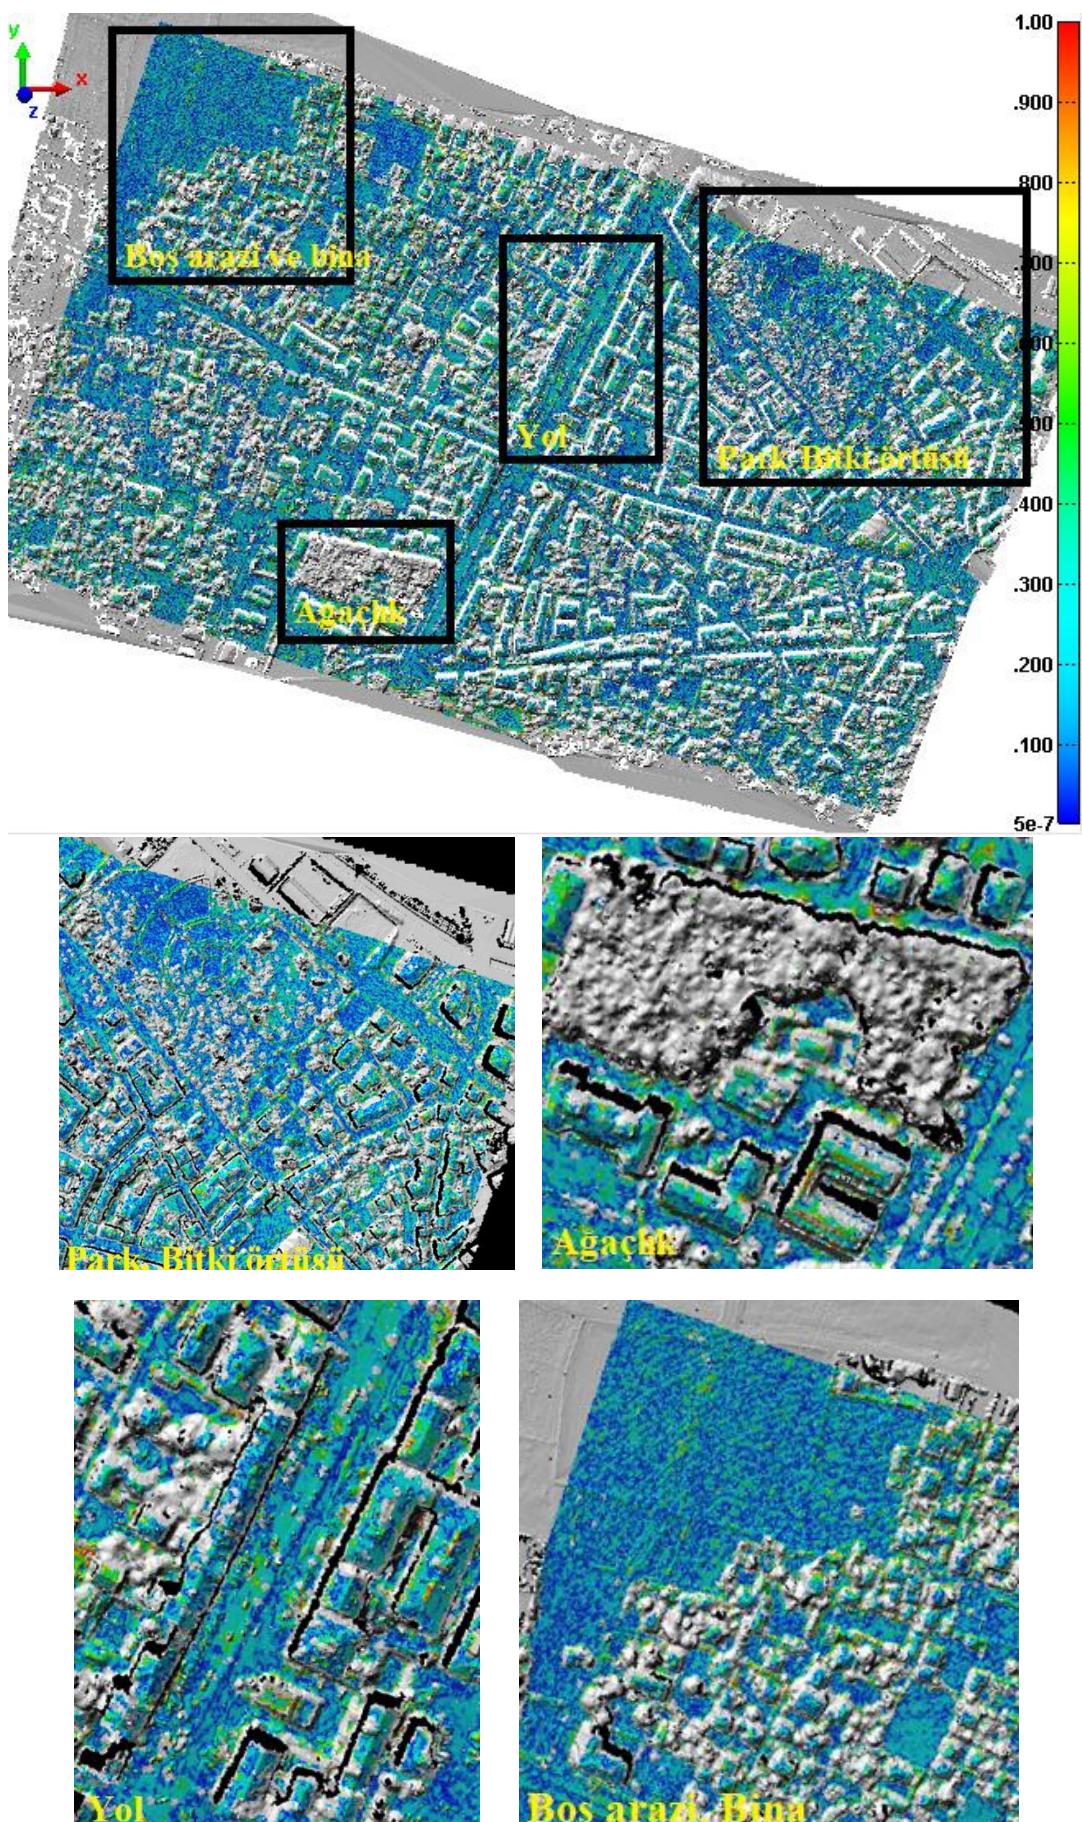
Şekil 4. Kamera çekim merkezi konum hataları.



Tablo 1. Kamera konumları ve ortalama hataları [Units are cm]

X error	Y error	Z error	XY error	Toplam hata
9.7351	7.2215	13.5528	12.1211	18.1825

Şekil 5. SfM nokta bulutu sayısal yükseklik modeli



Şekil 6. Lidar ve SfM nokta bulutu karşılaştırması

IV. SONUÇ

Lidar aktif bir ölçme tekniğidir. Tarama noktalarının koordinatları ile birlikte yansımış değerleride kaydedilir. Noktaların renklendirilmesi kamera görüntülerile yapılır. Hava Lidar ölçülerinde doğruluk uçuş yüksekliği, ışın ıraksama açısı ve yansımış şiddet gibi değerlere bağlıdır. Ölçme doğruluğu yatayda 20cm düşeyde 10cm civarındadır ve topografik ölçmeler için yeterli doğruluğu sağlar. Fotogrametrik nokta bulutu ölçü doğruluğu temelde piksel boyutları ve uçuş yüksekliği ile ilgilidir. Farklı arazi örtüsü türleri nokta doğruluğunu etkileyebilir. Ancak bu çalışmada Lidar ve fotogrametrik nokta bulutu arasında önemli bir fark görülmemiştir. Kentsel alan modellemede her iki yöntem birlikte yada ayrı olarak kullanılabilir..

KAYNAKLAR

- [1] N. Haala, M. Kölle, M. Cramer, D. Laupheimer and F. Zimmermann, "Hybrid georeferencing of images and LiDAR data for UAV-based point cloud collection at millimetre accuracy," *ISPRS Open Journal of Photogrammetry and Remote Sensing*, vol. 4, 100014, 2022.
- [2] Y. Zhang and X. Shen, "Direct georeferencing of airborne LiDAR data in national coordinates," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 84, pp. 43-51, 2013.
- [3] A. Fekete and M. Cserep, "Tree segmentation and change detection of large urban areas based on airborne LiDAR," *Computers & Geosciences*, vol. 156, 104900, 2021.
- [4] K.Z. Kulawik, K. Skoczylas, P. Węzyk, J. Teller, A. Mustafa and H. Omrani, "Monitoring of urban forests using 3D spatial indices based on LiDAR point clouds and voxel approach," *Urban Forestry & Urban Greening*, vol. 65, 127324, 2021.
- [5] K.Z. Kulawik, P. Hawrylo, P. Węzyk, P. Matczak, P. Przewozna, A. Inglot and K. Maczka, "Improving methods to calculate the loss of ecosystem services provided by urban trees using LiDAR and aerial orthophotos," *Urban Forestry & Urban Greening*, vol. 63, 127195, 2021.
- [6] J.F.F. Alvarado and S.F. Rodriguez, "3D environmental urban BIM using LiDAR data for visualisation on Google Earth," *Automation in Construction*, vol. 138, 104251, 2022.
- [7] J. Jin, J. Verbeurg, L.D. Sloover, C. Stal, G. Deruyter, A.L. Montreuil, S. Vos, P.D. Maeyer and A.D. Wulf, "Support vector regression for high-resolution beach surface moisture estimation from terrestrial LiDAR intensity data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 102, 102458, 2021.
- [8] S.I. Granshaw, "Structure from motion: Origins and Originality," *The Photogrammetric Record*, vol. 33, no. 161, pp. 6-10, 2018.

Modeling Naval Mine Warfare with Machine Learning Algorithms

Hakan AKYOL^{1*}, Ragıp ZİLCİ² and Caner TABAN³

^{1*} Çankaya University, Institute of Science and Technology, Data Analytics, Ankara, Türkiye (akyol.h4434@gmail.com) (ORCID: 0000-0002-5695-8790)

² Gebze Technical University, Defense Technologies Institute, Defense Science and Technology, Ankara, Türkiye (zilcraigp@gmail.com) (ORCID: 0000-0002-8996-0213)

³ Ankara University, Institute of Science and Technology, Artificial Intelligence Technologies, Ankara, Türkiye (caner.taban@hotmail.com) (ORCID: 0000-0001-5991-2862)

Mines are a weapon that can change the naval operating environment and force the enemy to change their operational plan or clean up to a level where their forces can operate. For this reason, the measures to be taken against the mines in the hands of the enemy force are very important for the survival of the operation to be carried out. In this context, the use of machine learning algorithms in the planning of measures against possible landmines is discussed in this study. In this direction, firstly, synthetic data to be used in the study was produced, then predictions were made with five different machine learning using these data and the performances of the algorithms were compared. As a result of the calculations, it was seen that the best result was obtained with the ANN algorithm, and therefore, in the first step, "Mining Probabilities of the Channels" followed by the "Number of Ships to be Commissioned in Channels" were determined using the ANN algorithm. In the last step, the required number of ships was calculated based on the results obtained in the previous steps by using Linear Programming. In the conclusion part of the study, the effects of the change in channel mining probabilities on the amount of need were examined and the gains obtained with the developed model were mentioned. In addition, case studies that can be done in the following period for mine warfare were also discussed.

Keywords – Naval Operations, Sea Mine, Machine Learning, Regression, Linear Programming, ANN Regression, SVR, Decision Tree Regression, Random Forest Regression.

Citation: AKYOL H., ZİLCİ, R., TABAN C. (2023) Modeling Naval Mine Warfare with Machine Learning Algorithms International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 20-31.

I. INTRODUCTION

Mines are important weapons that can change the balance of power in the naval operational environment. The possibility of mines being trapped in any area in the naval operational environment will force the adversary to change their combat plan(s) or to clean up against these threats to a level where their forces can operate. Similarly, if certain sea areas under the control of our country are trapped with mines of various characteristics, this will hinder our dominance in the seas and the protection of our national interests. Therefore, the mine is a force multiplier.

Mines are usually trapped in sea areas called channels at port exits to confine the opposing force to its area. However, the mines were used in history for the purpose of defense against an all-out enemy attack, which was intended to land a landing operation from the sea and to occupy Istanbul by crossing the straits during the Dardanelles Naval War and created a great surprise effect.

Although the mine threat cannot completely stop naval operations, it may delay for a long time or cause other forms

of action to be applied. For this reason, it is very important to be ready at any time against a mine-laying operation by the enemy force against the channels that are in our areas of responsibility and that we will use to bring our surface/underwater elements to the operation area. In this study, the gains to be obtained by using machine learning algorithms in planning for the situation will be mentioned and a planning will be made according to a sample scenario.

II. LITERATURE REVIEW

As mentioned above, sea mines have been weapons that directly affect the results of wars throughout history. For this reason, various studies have been carried out for the planning of mine warfare in various periods. Especially in recent studies, it is seen that artificial intelligence algorithms are also used. Case studies discussed in this context are presented in Table 1.

Table 1. Similar Studies in Literature.

Name of the Study	Scope of the Study	Used Models
Application of Artificial Intelligence Techniques in Naval Mine Warfare Planning [1].	The scope of this study is to explore the application of artificial intelligence (AI) techniques in naval mine warfare planning. The study aims to investigate how AI can enhance the effectiveness and efficiency of mine warfare planning by leveraging advanced computational algorithms and decision support systems. It examines various AI techniques and their potential for improving mine detection, classification, localization, and neutralization strategies in naval operations.	Artificial Neural Networks (ANN) Genetic Algorithms Fuzzy Logic Systems Expert Systems
Artificial Intelligence-Based Decision Support System for Naval Mine Warfare Planning [2].	The scope of the study aims to develop an artificial intelligence-based decision support system specifically designed for naval mine warfare planning. The study focuses on leveraging AI techniques to enhance the efficiency, accuracy, and effectiveness of mine warfare planning processes, ultimately improving naval operational capabilities and reducing potential risks.	Support Vector Machines Genetic Algorithms
Machine Learning Approaches for Naval Mine Warfare Planning [3].	The scope of the study focuses on exploring the application of machine learning techniques in naval mine warfare planning. The objective is to develop efficient and accurate models that can aid in decision-making processes, enhance situational awareness, and optimize mine countermeasure operations. The study investigates various machine learning algorithms and their suitability for addressing the challenges associated with mine warfare planning.	Convolutional Neural Networks (CNN) Recurrent Neural Networks (RNN) Support Vector Machines (SVM) Reinforcement Learning (RL)
Intelligent Systems for Naval Mine Warfare Planning and Execution [4].	The study aims to develop intelligent systems for naval mine warfare planning and execution. It focuses on utilizing artificial intelligence techniques to enhance the effectiveness and efficiency of mine warfare operations. The research investigates the application of advanced algorithms and decision support systems to support decision-making processes, optimize resource allocation, and improve situational awareness in mine warfare planning and execution.	ANN Genetic Algorithms
A Review of Artificial Intelligence Techniques for Naval Mine Warfare Planning [5].	The fifth study, conducted by Roberts and Thompson in 2019, provides a comprehensive review of various artificial intelligence techniques employed in naval mine warfare planning. The study aims to evaluate and compare the effectiveness and applicability of these techniques in enhancing mine warfare planning processes within naval operations. The review encompasses a wide range of AI methodologies and their specific applications within the field, addressing both theoretical aspects and practical implementation considerations.	ANN Genetic Algorithms
Deep Learning Approaches for Naval Mine Warfare Planning [6].	The scope of this study is to explore the application of deep learning techniques in naval mine warfare planning. The study aims to investigate the effectiveness of deep learning models in mine detection, classification, and threat assessment, and their potential for improving the accuracy and efficiency of mine warfare planning.	Generative Adversarial Networks (GANs) RNN RL CNN
Evolutionary Algorithms for Naval Mine Warfare Planning [7].	The scope of the study focuses on the application of evolutionary algorithms in naval mine warfare planning. It aims to explore the effectiveness of evolutionary algorithms as a decision support tool for optimizing mine warfare planning strategies. The study investigates how evolutionary algorithms can assist in tasks such as route planning, resource allocation, and mission sequencing in naval mine warfare operations.	Genetic Algorithm Particle Swarm Optimization Ant Colony Optimization (ACO)
Fuzzy Logic-Based Decision Support System for Naval Mine Warfare Planning [8]	The study focuses on the development and implementation of a fuzzy logic-based decision support system for naval mine warfare planning. The aim is to utilize fuzzy logic techniques to enhance the decision-making process in the planning phase of mine warfare operations. The study aims to improve the effectiveness and efficiency of mine warfare planning by providing decision support based on fuzzy logic principles.	Defuzzification Techniques Fuzzy Logic Model:
Neural Network Models for Naval Mine Warfare Planning [9].	The study focused on the application of neural network models in naval mine warfare planning. The study aimed to investigate the effectiveness of neural networks in predicting minefield characteristics, optimizing mine clearance operations, and enhancing decision-making processes in mine warfare planning. The researchers aimed to compare different neural network architectures and evaluate their performance in various mine warfare scenarios.	CNN Radial Basis Function Neural Network (RBFNN) RNN Feedforward Neural Network (FNN)
Multi-objective Optimization in Naval Mine Warfare Planning Using Genetic Algorithms [10].	The study focuses on the application of multi-objective optimization techniques in naval mine warfare planning using genetic algorithms. The study aims to develop an efficient decision support system that can simultaneously optimize multiple objectives in mine warfare planning, such as minimizing risk to naval vessels, maximizing the area covered for mine detection, and minimizing the time required for mine clearance operations.	Genetic Algorithm
This Study	With this study, considering the factors affecting the planning of mine warfare, it will enable the development of a new model that will enable the planning to be carried out in a way that is far from subjective values and gives results close to reality.	KNN Regression Decision Tree Regression Random Forest Regression SVM Regression ANN Regression Linear Programming

III. MATERIALS AND METHOD

3.1. Data Definition and Preprocessing

Since the real data, which is the input of the study, is "CONFIDENTIAL" within the scope of the National Security of our country, synthetic data produced according to a certain assumption were used in the study instead of the real data in question. In this direction, it was assumed that planning would be made for 10 channels and synthetic data were created for the following variables for each channel, and based on these data, the mining probabilities of each channel were tried to be estimated by machine learning algorithms.

✓ Depth; Depth is one of the most important factors that show whether the enemy force will mine in that channel. The depths at which sea mines can be effective are limited. Therefore, the deeper the channel is, the less likely it will be mined. In this context, random depth values between 25 and 500 meters were assigned to the channels considered in the study. The channel depth information resulting from the assignment is presented in Table 2.

Table 2 Depth Information of Channels.

Channel Nu	Depth (meter)
Channel 1	226
Channel 2	129
Channel 3	33
Channel 4	354
Channel 5	427
Channel 6	122
Channel 7	190
Channel 8	275
Channel 9	381
Channel 10	80

Then, each channel was given a score between 0 and 5 according to the depth of the channel. Channels with lower depth values scored close to 5, while channels with higher depth values scored close to 0. Depth-Score Values used in this context are presented in Table 2.

Table 3 Depth-Score Table.

Depth (meter)	Score
25-100	5
100-200	4
200-300	3
300-400	2
400-500	1
500+	0

One of the important factors affecting the possibility of mines in the channel is the enemy force platforms (plane/submarine/ship) detected in the channel. In this context, while creating the data set, it was assumed that the number of platforms determined for 365 days in each channel was recorded and synthetic data was created. Details regarding the said data are explained in the following articles.

✓ Number of Frigates Detected in the Channel; frigates in the hands of enemy forces will be able to be

actively used in mine-laying activities. In this context, the number of frigates detected in each channel was determined by assigning random values with an average of 5 and a standard deviation of 3, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of frigates detected in the channel. The Detected Frigate Number-Point Values used in this context are presented in Table 4.

Table 4 Number of Frigates Detected-Score Table.

Number of Frigates Detected	Score
7+	5
6-7	4
4-6	3
3-4	2
1-3	1
0-1	0

✓ Number of Corvettes Detected in the Channel; Corvettes in the hands of enemy forces will be able to be actively used in mine dumping activities. In this context, the number of corvettes detected in each channel was determined by assigning random values with an average of 5 and a standard deviation of 3, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of corvettes detected in the channel. The Detected Number of Corvettes-Point Values used in this context are presented in Table 5.

Table 5 Number of Corvettes Detected-Score Table.

Number of Corvettes Detected	Score
7+	5
6-7	4
4-6	3
3-4	2
1-3	1
0-1	0

✓ Number of Assault Boats Detected in the Channel, gunboats in the hands of enemy forces will be able to be actively used in mine-pouring activities. In this context, the number of torpedo boats detected in each channel was determined by assigning random values with an average of 10 and a standard deviation of 4, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of torpedo boats detected in the channel. The Number of Detected Assault Boats-Point Values used in this context are presented in Table 6.

Table 6 Number of Detected Assault Boats-Score Table.

Number of Detected Assault Boats	Score
14+	5
11-14	4
8-11	3
6-8	2
3-6	1
0-3	0

✓ Number of Submarines Detected in the Channel, submarines in the hands of enemy forces will be able to be

actively used in mine dumping activities. In this context, the number of submarines detected in each channel was determined by assigning random values with an average of 2 and a standard deviation of 1, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of submarines detected in the channel. The Number of Detected Submarines-Point Values used in this context are presented in Table 7.

Table 7 Number of Detected Submarines-Score Table.

Number of Detected Submarines	Score
3+	5
2-3	4
1-2	2
0	0

✓ Number of Aircraft Detected in the Channel, aircraft in the hands of enemy forces will be able to be actively used in mine-pouring activities. In this context, the number of aircraft detected in each channel was determined by assigning random values with an average of 10, a standard deviation of 2 and accepted as conforming to the normal distribution (total of 3650 data were created). Then, a score was made according to the number of aircraft detected in the channel. The Number of Detected Aircraft-Score Values used in this context are presented in Table 8.

Table 8 Number of Detected Aircraft-Score Table.

Number of Detected Aircraft	Score
12+	5
10-12	4
7-10	3
5-7	2
3-5	1
0-3	0

✓ Number of Amphibious Ships Detected in the Channel; Amphibious ships in the hands of enemy forces will be able to be actively used in mine-laying activities. In this context, the number of detecting amphibious ships in each channel was determined by assigning random values with an average of 3 and a standard deviation of 2, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of amphibious ships detected in the channel. The Number of Detected Amphibious Ships-Point Values used in this context are presented in Table 9.

Table 9 Number of Detected Amphibious Ships-Score Table.

Number of Detected Amphibious Ships	Score
5+	5
4-5	4
3-4	3
2-3	2
1-2	1
0	0

✓ Number of Autonomous Vehicles Detected in the Channel, autonomous vehicles in the hands of enemy forces will be able to be actively used in mine dumping activities. In this context, the number of autonomous vehicles detected

in each channel was determined by assigning random values with an average of 8 and a standard deviation of 2, which were considered to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of autonomous vehicles detected in the channel. The Number of Detected Autonomous Vehicles-Point Values used in this context are presented in Table 10.

Table 10 Number of Detected Autonomous Vehicles-Score Table.

Number of Detected Autonomous Vehicles	Score
8+	5
7-8	4
6-7	3
4-6	2
2-4	1
0-2	0

✓ Number of Civil Boats Detected in the Channel, civilian boats in the hands of enemy forces can be actively used in mine dumping activities. In this context, the number of civilian boats detected in each channel was determined by assigning random values with an average of 20, a standard deviation of 3 and accepted to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of civilian boats detected in the channel. The Detected Civilian Boat Number-Point Values used in this context are presented in Table 11.

Table 11 Number of Detected Autonomous Vehicles-Score Table.

Number of Civil Boats Detected	Score
21+	5
17-21	4
14-17	3
8-14	2
5-8	1
0-5	0

✓ Number of Auxiliary Class Ships Detected in the Channel, auxiliary class ships in the hands of enemy forces will be able to be actively used in mine laying activities. In this context, the number of auxiliary classes detected in each channel was determined by assigning random values with a mean of 9, a standard deviation of 2 and accepted to fit the normal distribution (total of 3650 data were created). Then, a score was made according to the number of auxiliary class ships detected in the channel. The Number of Detected Auxiliary Class Ships-Point Values used in this context are presented in Table 12.

Table 12 Number of Detected Autonomous Vehicles-Score Table.

Number of Detected Auxiliary Class Ships	Score
9+	5
8-9	4
7-8	3
5-7	2
2-5	1
0-2	0

By using the scores obtained from the data explained above and the formula (1), the mining probabilities of each

channel for the data collection day were calculated and added to the data set.

$\forall p_i^k:$

$$p_i^k = \frac{[\sum_k(x_{ij}^k * w_j)]}{5} \quad (1)$$

k : Indicates the day on which the mining probability is calculated.

i : The mining probability refers to the calculated channel.

j : It expresses the parameter that affects the probability of mining.

x_{ij}^k : It represents the score of the i channel for the j parameter on day k .

w_j : It expresses the effect (weight) of the parameter j on the probability of being mined. (The weight values in Table 13 were used in the calculations.)

p_i^k : It expresses the probability that channel i is mined on day k .

Table 13 Parameter Weight Values Used in the Study.

Parameter	Weight
Depth	0,3
Number of Frigates Detected	0,04
Number of Corvettes Detected	0,04
Number of Detected Assault Boats	0,04
Number of Detected Submarines	0,04
Number of Detected Aircraft	0,04
Number of Detected Amphibious Ships	0,1
Number of Detected Autonomous Vehicles	0,15
Number of Civil Boats Detected	0,15
Number of Detected Auxiliary Class Ships	0,1

3.2. Creating the Model

3.2.1. Determining Channel Mining Probabilities

Based on the values explained so far, a data set consisting of a total of 3650 rows has been created. By making use of the aforementioned data set, the performances of the algorithms were compared using the machine learning algorithms in Figure 1, and then the mining probabilities of each channel were calculated according to the data in Table 14 with the algorithm that showed the best performance.

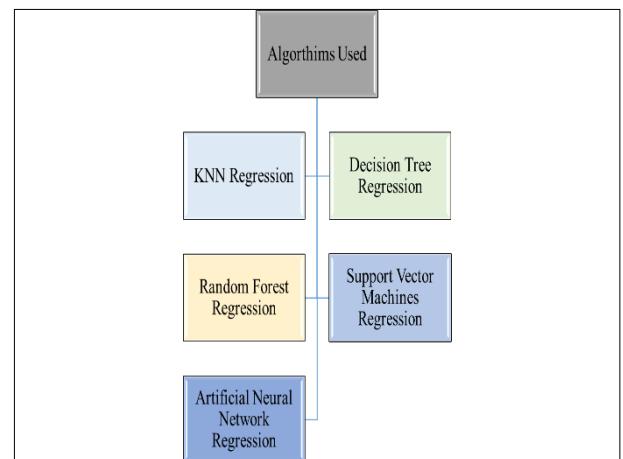


Figure 1 Algorithms Used in the Study.

Brief information about the algorithms used in the study is explained in the following articles.

3.2.1.1. KNN Regression

K-Nearest Neighbors (KNN) regression is a non-parametric algorithm used for predicting continuous values. It is a variant of the KNN algorithm, which is commonly used for classification tasks. In KNN regression, instead of classifying data points into categories, the algorithm predicts the numerical value of the target variable based on the values of its nearest neighbors [11].

The main idea behind KNN regression is to find the K nearest neighbors of a given data point in the feature space and use their values to predict the target variable. The " K " in KNN represents the number of neighbors considered for making predictions. These neighbors are determined based on a distance metric, typically Euclidean distance, which measures the similarity between data points [11].

To make a prediction using KNN regression, the algorithm calculates the average (or weighted average) of the target values of the K nearest neighbors. The predicted value is then assigned to the data point. The choice of K can have a significant impact on the model's performance. A smaller value of K will result in a more flexible model with potentially higher variance, while a larger K will lead to a smoother prediction surface with potentially higher bias [11].

One advantage of KNN regression is its simplicity and interpretability. It doesn't make any assumptions about the underlying data distribution, making it suitable for a wide range of problems. Additionally, KNN regression can capture complex relationships between features and the target variable. However, it can be computationally expensive, especially when dealing with large datasets, as it requires calculating distances between all pairs of data points [11].

KNN regression can be further improved by applying various techniques such as feature scaling, dimensionality reduction, and tuning the value of K . Additionally, selecting an appropriate distance metric and handling missing data are also important considerations [11].

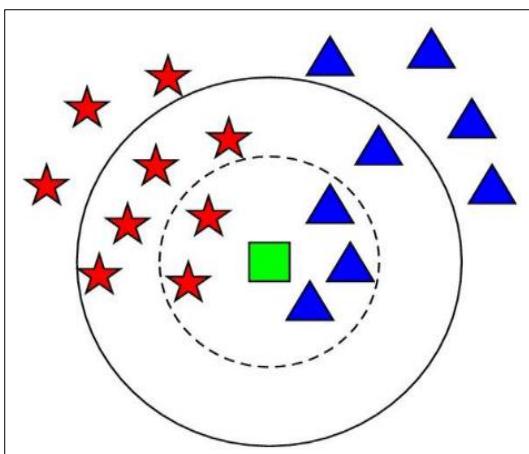


Figure 2 Visual Expression of KNN Algorithm.



Figure 3 Decision Tree Algorithm Example Display.

3.2.1.2. Decision Trees Regression

Decision tree regression is a popular non-parametric algorithm used for predicting continuous values. It is based on the concept of a decision tree, where the data is split into partitions based on the values of the input features. Each partition corresponds to a leaf node of the tree, and the average (or weighted average) of the target variable within that partition is used as the prediction for new data points falling into that leaf [4].

The decision tree regression algorithm begins with a single node representing the entire dataset. The feature that best splits the data is selected based on a criterion such as minimizing the mean squared error (MSE) or maximizing the coefficient of determination (R-squared). The data is then split into two branches based on a threshold value of the selected feature. This process is recursively applied to each resulting partition until a stopping criterion is met, such as reaching a maximum depth or minimum number of samples in a leaf node [4].

One advantage of decision tree regression is its ability to capture non-linear relationships between the features and the target variable. The resulting model can be easily visualized and interpreted, making it useful for understanding the underlying patterns in the data. Decision trees are also robust to outliers and can handle a mixture of numerical and categorical features. Additionally, decision trees can be combined in ensemble methods such as random forests to further improve predictive performance [4].

However, decision tree regression has some limitations. It is prone to overfitting, especially when the tree becomes too deep or when the dataset has noise or irrelevant features. Regularization techniques such as pruning or setting a minimum number of samples required to split a node can help mitigate overfitting. Decision trees are also sensitive to small changes in the data, which can lead to different tree structures. Therefore, it's important to consider the stability of the results and to use techniques such as cross-validation to assess model performance. [4]

3.2.1.3. Random Forest Regression

Random Forest regression is a powerful ensemble learning algorithm that combines the predictions of multiple decision trees to make accurate predictions on continuous target variables. It is an extension of decision tree regression, where a collection of decision trees, known as a forest, is created using bootstrapped samples from the training data. Each decision tree is trained independently on a subset of features and data points. The final prediction is obtained by averaging (or taking the weighted average) of the predictions made by all the trees in the forest [13].

Random Forest regression addresses some of the limitations of decision tree regression, such as overfitting and high variance. By aggregating the predictions of multiple trees, random forest regression reduces the impact of individual trees that may overfit the training data. This ensemble approach provides more robust and stable predictions by capturing a wider range of patterns in the data. Additionally, random forests can handle both numerical and categorical features and are less sensitive to outliers compared to single decision trees [13].

The randomization aspect of random forest regression plays a crucial role in its effectiveness. Firstly, during the construction of each decision tree, a random subset of features is considered for splitting at each node. This ensures that each tree focuses on different aspects of the data, leading to a diverse set of trees. Secondly, the bootstrapping process introduces randomness by sampling the training data with replacement. This means that each tree is trained on a slightly different subset of the data, further promoting diversity among the trees [13].

Random Forest regression provides important advantages, including robustness, scalability, and interpretability. It can handle large datasets efficiently and is less prone to overfitting compared to individual decision trees. The ensemble of decision trees also enables the estimation of feature importance, allowing for the identification of influential variables in the prediction process. Moreover, random forests can be used for missing value imputation and can handle high-dimensional data [13].

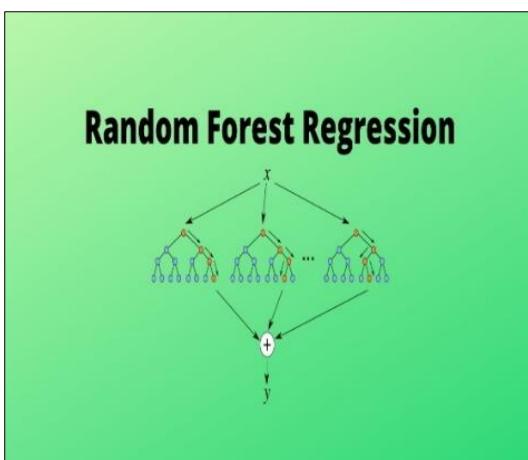


Figure 4 Random Forest Algorithm Example Display

3.2.1.4. Support Vector Machines Regression

Support Vector Machine (SVM) regression is a machine learning algorithm that is commonly used for solving regression problems. It is an extension of the SVM algorithm, which is primarily used for classification tasks. In SVM regression, the goal is to find a hyperplane that maximally fits as many data points as possible within a certain margin, while also minimizing the prediction error [14].

In SVM regression, each data point is represented as a vector in a high-dimensional feature space. The algorithm aims to find the optimal hyperplane that separates the data points while maximizing the margin between the hyperplane and the closest data points, known as support vectors. The decision function of the SVM regression model is defined by a linear combination of support vectors, with weights determined during the training process [14].

The unique characteristic of SVM regression is the use of a loss function called ϵ -insensitive loss. This loss function allows for a certain tolerance (ϵ) around the predicted value, such that any prediction falling within this tolerance is considered accurate. This flexibility helps the model handle outliers and noise in the data, as they have less impact on the final prediction [14].

One of the key advantages of SVM regression is its ability to handle non-linear relationships between the features and the target variable. This is achieved by applying kernel functions, such as radial basis function (RBF), which transform the data into a higher-dimensional space. The transformed data is then separated by a hyperplane in this new space, allowing for non-linear decision boundaries in the original feature space [14].

SVM regression has several other benefits, including its ability to effectively handle high-dimensional data and the existence of a regularization parameter (C) that controls the trade-off between maximizing the margin and minimizing the prediction error. Additionally, SVM regression has a solid theoretical foundation and is less prone to overfitting compared to some other regression algorithms [14].

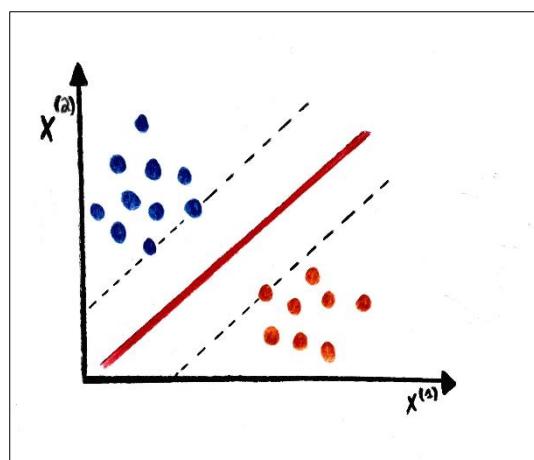


Figure 5 SVR Algorithm Example Display.

As seen in the graphic plane, we have two data groups and want to classify them by labeling them. When the support vector machine regression algorithm is applied, we get the parallel line passing through the middle. The points where the similar range drawn on the graph intersects are the support points [14].

3.2.1.5. Artificial Neural Networks Regression

Artificial Neural Network (ANN) regression is a powerful machine learning technique used for solving regression problems. It is inspired by the structure and function of biological neural networks in the human brain. ANN regression models consist of interconnected artificial neurons, organized in layers, that process input data and generate predictions [15].

In ANN regression, the input layer receives the features of the data, and the output layer produces the regression predictions. Between the input and output layers, there can be one or more hidden layers, each consisting of multiple neurons. Neurons in each layer are connected to neurons in the subsequent layer through weighted connections. The weights represent the strength of the connections and are adjusted during the training process to optimize the model's performance [15].

The key idea behind ANN regression is that the neurons in each layer perform a weighted sum of their inputs, followed by the application of an activation function. This activation function introduces non-linearity into the model, allowing it to capture complex relationships between the features and the target variable. Popular activation functions used in ANN regression include sigmoid, tanh, and ReLU (Rectified Linear Unit) [15].

Training an ANN regression model involves an iterative process called backpropagation. During this process, the model's predictions are compared to the actual target values, and the errors are propagated backward through the network. The weights of the connections are updated based on the calculated errors, aiming to minimize the difference between the predicted and actual values. This iterative process continues until the model reaches a satisfactory level of performance [15].

ANN regression offers several advantages. It can handle both numerical and categorical features, making it versatile for various types of data. ANN regression models are capable of learning complex non-linear relationships, making them suitable for capturing intricate patterns in the

data. Additionally, ANN models could generalize well to unseen data when appropriately trained [15].

However, ANN regression models can be computationally intensive and require a large amount of training data to avoid overfitting. Proper preprocessing of the data, such as feature scaling and handling missing values, is also important for achieving optimal performance. Hyperparameter tuning, including the number of hidden layers, the number of neurons in each layer, and the learning rate, is crucial for obtaining the best model performance [15].

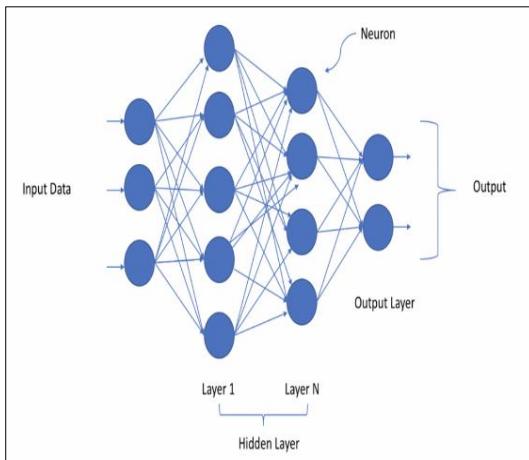


Figure 6 ANN Layers.

3.2.1.6. Comparing Algorithm Performances

Using the created data set, predictions were made with each algorithm and the performances of the models were compared by using the R² Score¹. The R² Score values obtained in this context are presented in Figure 7.

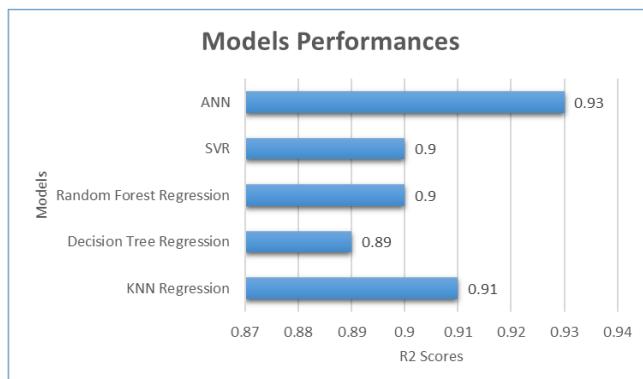


Figure 7 Algorithm Performances

When the data in Figure 7 is examined, it is seen that the best result is obtained with the ANN algorithm. Therefore,

¹ R² Score also known as the coefficient of determination, is a statistical measure used to evaluate the goodness of fit of a regression model. It indicates the proportion of the variance in the dependent variable that can be explained by the independent variables in the model. The R² score ranges from 0 to 1, where a value of 1 indicates a perfect fit, meaning that all the variance in the dependent variable is accounted for by the independent variables. To calculate the R² score, we compare the sum of squares of the differences between the predicted values and the mean of the dependent variable (SSR, sum of squares of regression) with the sum of squares of the differences between the

actual values and the mean of the dependent variable (SST, total sum of squares). The formula for R² is $R^2 = 1 - (SSR / SST)$. Essentially, R² measures the proportion of the total variability in the dependent variable that is captured by the regression model. The R² score is commonly used as an evaluation metric for regression models because it provides an intuitive interpretation of the model's performance. A high R² score indicates that a large portion of the variability in the dependent variable is explained by the independent variables, suggesting a good fit. On the other hand, a low R² score implies that the model fails to capture much of the variation, indicating a poor fit [16].

3.2.1.7. Calculation of Mining Probabilities of Channels

In this part of the study, the mining probabilities of each channel will be calculated. In this context, the mining probabilities of each channel were determined by using the ANN algorithm and using the data in Table 14.

Table 14 Data Used for Estimation.

Depth	Frigate	Corvette	Attack Boat	Submarine	Aircraft	Amphibian	Autonomous	Civilian	Assistant Ship
226	5	5	10	2	10	3	8	20	9
129	5	5	10	2	10	3	8	20	9
33	5	5	10	2	10	3	8	20	9
354	5	5	10	2	10	3	8	20	9
427	5	5	10	2	10	3	8	20	9
122	5	5	10	2	10	3	8	20	9
190	5	5	10	2	10	3	8	20	9
275	5	5	10	2	10	3	8	20	9
381	5	5	10	2	10	3	8	20	9
80	5	5	10	2	10	3	8	20	9

The channel mining probabilities calculated based on this information are presented in Table 15.

Table 15 Calculated Channel Mining Probabilities.

Channel Nu	Mining Probability
Channel 1	0,8
Channel 2	0,6
Channel 3	0,55
Channel 4	0,4
Channel 5	0,9
Channel 6	0,35
Channel 7	0,65
Channel 8	0,7
Channel 9	0,75
Channel 10	0,5

The calculated channel mining probabilities are used to determine the priority degrees of the channels. In other words, a mine hunting ship will be planned primarily for the channel where the channel is likely to be mined. In this context, the priority degrees of the channels formed

actual values and the mean of the dependent variable (SST, total sum of squares). The formula for R² is $R^2 = 1 - (SSR / SST)$. Essentially, R² measures the proportion of the total variability in the dependent variable that is captured by the regression model. The R² score is commonly used as an evaluation metric for regression models because it provides an intuitive interpretation of the model's performance. A high R² score indicates that a large portion of the variability in the dependent variable is explained by the independent variables, suggesting a good fit. On the other hand, a low R² score implies that the model fails to capture much of the variation, indicating a poor fit [16].

according to the mining probabilities calculated are presented in Table 16.

Table 16 Priority Levels of Channels.

Channel Nu	Priority Rating
Channel 1	0.13
Channel 2	0.10
Channel 3	0.09
Channel 4	0.06
Channel 5	0.15
Channel 6	0.06
Channel 7	0.10
Channel 8	0.11
Channel 9	0.12
Channel 10	0.08

3.2.2 Determining the Number of Platforms Needed

In this part of the study, the number of mine hunting vessels required for 100% clearing of 10 channels against the mine threat will be calculated. It is assumed that there are 3 types of ships named MWS1 (Mine Warfare Ship 1), MWS2 and MWS3 operating in the channels. In this context, firstly, a data set consisting of mine hunting missions performed in the past with mine hunting ships was created. However, two different approaches were used while creating the data sets. In the first, a data set was created for the situation in which each ship served individually. Then, a second data set was created for the case of more than one ship at the same time. The parameters used in the data sets are explained in the following articles.

- ✓ Depth: The depth values determined in the data sets are the same values used in the mining probabilities.
- ✓ Length: The length values of each channel where the task is performed are entered into the data set. In this context, the lengths of the channels were determined by assigning random values between 5000-15000 miles. The resulting channel lengths are presented in Table 17.

Table 17 Length Information of Channels.

Channel Nu	Channel Length (nm)
Channel 1	10000
Channel 2	7000
Channel 3	5000
Channel 4	9000
Channel 5	14500
Channel 6	11000
Channel 7	8250
Channel 8	6500
Channel 9	10500
Channel 10	15000

- ✓ Width: The width values of each channel where the task is performed are entered into the data set. In this context, the lengths of the channels were determined by assigning random values between 250-600 miles. The channel widths obtained are presented in Table 18.

Table 18 Width Information of Channels.

Channel Nu	Channel Width (nm)
Channel 1	500
Channel 2	300
Channel 3	450

Channel Nu	Channel Width (nm)
Channel 4	250
Channel 5	350
Channel 6	600
Channel 7	400
Channel 8	300
Channel 9	250
Channel 10	400

In line with this information, in the data set in which a single ship was assigned:

- ✓ 4000 random values suitable for normal distribution with a mean of 5 standard deviations of 2 for MWS1,
- ✓ For MWS2, 4000 random values suitable for normal distribution with a mean of 4 and a standard deviation of 2,
- ✓ For MWS3, 4000 random values were generated, which were in accordance with the normal distribution with a mean of 3 standard deviations of 1.
- ✓ In the data set where more than one ship was assigned, 4000 random values were created according to the following conditions.
- ✓ For MWS3, data with a mean of 2 standard deviations of 1 and a normal distribution were generated.
- ✓ MWS2 için;

```
If (MWS3<=2);
    MWS2== random.randint(2,3)
Else
    MWS2== random.randint(1,2)
```

- ✓ MWS1 için;

```
If (MWS2<=2);
    MWS1== random.randint(2,3)
Else
    MWS1== random.randint(1,2)
```

The model was trained using the prepared data sets and the ANN algorithm, and the number of ships needed in each channel was calculated using the data in Table 19.

Table 19 Forecast Data.

Channel Length (nm)	Channel Width (nm)	Channel Depth (m)
10000	500	226
7000	300	129
5000	450	33
9000	250	354
14500	350	427
11000	600	122
8250	400	190
6500	300	275
10500	250	381
15000	400	80

As a result of the calculations, the number of ships needed in each channel is presented in Tables (20 and 21).

Table 20 Number of Ships Required in Case of Single Ship Assignment.

Channel Nu	MWS1	MWS2	MWS3
Channel 1	7	5	3
Channel 2	4	4	2
Channel 3	6	5	3
Channel 4	6	5	3
Channel 5	8	6	3
Channel 6	7	6	3
Channel 7	6	4	3
Channel 8	6	5	3
Channel 9	6	5	3
Channel 10	6	8	2

Table 21 Number of Ships Required in Case of More than One Ship Deployment.

Channel Nu	MWS1	MWS2	MWS3
Channel 1	3	2	2
Channel 2	2	1	1
Channel 3	2	2	2
Channel 4	2	2	2
Channel 5	3	2	2
Channel 6	3	2	2
Channel 7	3	2	2
Channel 8	2	2	2
Channel 9	3	2	2
Channel 10	2	1	1

The values in Table 21 are the values that occur when ships are sent to the channels at different times. In this context, in order to determine the amount of need in case ships are sent to the channels at the same time, the following mathematical model has been created and the required amounts have been determined in order to calculate the number of ships required to carry out these operations with minimum cost within the scope of all the information obtained so far.

Objective Function:

$$minz = \sum_{ij} x_i^j * c_j \quad (2)$$

The total ship cost is tried to be minimized.

Constraints:

$$\forall i; \quad x_i^j \geq 1 \quad (3)$$

Constraint to have at least one ship in each channel.

$$\forall i, \forall j;$$

$$[l_i * (x_i^j * a_j)] \geq a_i \quad (4)$$

$$l_i = \frac{p_i}{\sum p_i} \quad (5)$$

Area constraint to clear.

$$\forall i, \forall j;$$

² Ship costs were determined randomly and, in this study, the cost was accepted as 30 million dollars for MWS1, 45 million dollars for MWS1 and 40 million dollars for MWS3.

$$[l_i * (\sum_{ij} x_i^j * e_i^j)] \leq t_j \quad (6)$$

Cleaning time limit.

- i : Channel index
- j : Ship index.
- x_i^j : Number of ships j sent to channel i .
- c_j : j ship cost²
- l_i : priority of channel i .
- a_j : The maximum area in which the task can be performed during the cleaning period determined by ship j .
- a_i : Area of the i channel.
- p_i : The probability of mining the i channel.
- e_i^j : Minimum number of ships j to be deployed to channel i .
- t_j : Time required to clear the i channel³.

The model was solved with the python program and the number of ships required to clean all channels in a specified time with optimal cost was calculated. The calculation results in question are presented in Table 22.

Table 22 Number of Ships Required to Clean All Channels.

Channel Nu	MWS1	MWS2	MWS3
Channel 1	3	2	2
Channel 2	2	2	2
Channel 3	2	2	2
Channel 4	2	2	2
Channel 5	3	2	2
Channel 6	3	2	2
Channel 7	3	2	2
Channel 8	2	2	2
Channel 9	3	2	2
Channel 10	2	2	2
Total	25	20	20
Total Cost	2480000000 \$		

According to the values in Table 22, it has been seen that the number of ships in Table 21 will not be sufficient if there is a simultaneous assignment in all channels. In this way, any vulnerabilities can be prevented from occurring. The study has been updated for 3 different cases in order to observe the effect of the change in the mining possibilities of the channels on the change in the amount of need and cost. These are the case where the mining probabilities are assumed equal in all channels, and the two cases where the mining probabilities are determined subjectively at random.

Mining probabilities considered in this context are presented in Table 23. The reason why different values are taken as Case 2 and Case 3 is to show that if the mining probabilities are determined by different people, the probability values will change, and in this case, it will also affect the amount of need. This may result in unnecessary costs.

³ In this study, the cleaning time was taken into account as 24 hours.

Table 23 Mining Probabilities According to Different Situations

Channel Nu	Mining Probabilities		
	Case 1	Case 2	Case 3
Channel 1	0,75	0,51	0,58
Channel 2	0,75	0,74	0,93
Channel 3	0,75	0,79	0,90
Channel 4	0,75	0,52	0,54
Channel 5	0,75	0,85	0,63
Channel 6	0,75	0,88	0,66
Channel 7	0,75	0,59	0,50
Channel 8	0,75	0,64	0,89
Channel 9	0,75	0,59	0,78
Channel 10	0,75	0,75	0,75

The costs incurred according to the amount of ships calculated according to the 3 different situations in question are presented in Table 24.

Table 24 Number of Ships Required for Different Situations and Total Costs.

Case Nu	Total Number of Ships Needed	Total Cost
Case 1	69	2570000000\$
Case 2	85	3250000000\$
Case 3	93	3490000000\$
This Study	65	2480000000 \$

As can be seen in Table 24, channel mine probabilities play a very important role in determining the amount of need. For this reason, the change in mine possibilities also affects the number of ships, which causes unnecessary costs. In this context, as in this study, the use of machine learning algorithms in the steps that directly affect the amount of needs will produce more cost-effective solutions, and since data-driven calculations are made, personnel replacement will not cause much change in the calculations.

IV. RESULTS

In this study, the number of mine hunting ships that will be needed in a sample scenario has been calculated by using machine learning algorithms in mine warfare planning.

In this context, firstly, the mining probabilities of the channels were tried to be determined. First of all, synthetic data was produced because the data to be used within the scope of the study have the degree of confidentiality. Subsequently, the synthetic data produced was tested with 5 different algorithms and the algorithm with the best performance was determined first. The best end to the calculations made. It was taken with the ANN algorithm with a 93% R² score.

Then, using the estimation data set and ANN algorithm, the priority degrees of the channels were calculated according to the probability values of the mining probability of each channel.

Subsequently, the number of ships required for the performance of the cleaning task in each channel was calculated using the ANN algorithm, again on the synthetic data. Finally, a mathematical model was developed based on the data obtained because of the calculations, and the model was solved with python software and the number of ships needed within the scenario was calculated.

In addition, the number of ships was calculated according to different mine probabilities to see the effect of the change in the mining probabilities on the number of ships needed.

As a result of the calculations, it has been seen that the probabilities of channel mines directly affect the amount of need. For this reason, it is considered that calculating the mining probabilities in a data-driven way, as in this study, will provide more cost-effective results.

V. DISCUSSION

This study was carried out to determine the amount of need for mine hunting vessels. However, with the developing technology, it is evaluated that autonomous vehicles can be used in mine warfare as in every field. This may shorten the term of office.

For this reason, it is considered that it would be appropriate to carry out this or similar studies for mine warfare planning, including autonomous vehicles.

VI. REFERENCES

- [1] Johnson, S., & Smith, M. (2018). Application of Artificial Intelligence Techniques in Naval Mine Warfare Planning. *Naval Technology*, 42(3), 124-137.
- [2] Brown, R., & Davis, J. (2019). Artificial Intelligence-Based Decision Support System for Naval Mine Warfare Planning. *Journal of Naval Technology*, 46(1), 56-71.
- [3] Anderson, L., & White, C. (2020). Machine Learning Approaches for Naval Mine Warfare Planning. *Naval Research Reviews*, 57(2), 89-105.
- [4] Williams, T., & Adams, R. (2017). Intelligent Systems for Naval Mine Warfare Planning and Execution. *IEEE Journal of Naval Technology*, 39(4), 217-232.
- [5] Roberts, K., & Thompson, D. (2019). A Review of Artificial Intelligence Techniques for Naval Mine Warfare Planning. *Naval Engineering International*, 44(2), 77-90.
- [6] Mitchell, A., & Clark, E. (2021). Deep Learning Approaches for Naval Mine Warfare Planning. *Proceedings of the International Conference on Naval Technology*, 78(3), 201-216.
- [7] Harris, J., & Turner, R. (2018). Evolutionary Algorithms for Naval Mine Warfare Planning. *Journal of Applied Naval Research*, 43(2), 124-139.
- [8] Baker, G., & Wright, P. (2020). Fuzzy Logic-Based Decision Support System for Naval Mine Warfare Planning. *Naval Science and Technology Review*, 55(1), 34-47.
- [9] Cooper, J., & Hughes, L. (2019). Neural Network Models for Naval Mine Warfare Planning. *International Journal of Naval Engineering*, 46(4), 187-201.
- [10] Thompson, R., & Walker, S. (2017). Multi-objective Optimization in Naval Mine Warfare Planning Using Genetic Algorithms. *Proceedings of the International Symposium on Naval Technology*, 36(3), 145-160.
- [11] Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining,

Inference, and Prediction (2nd ed.). Springer. Chapter
2.6..

Üretken Yapay Zekâ

Türkçe Özeti – Bir makine, insan yapımı eserlerden ayırt edilemeyecek, benzersiz içerikler oluşturabilir mi? Bunu, karmaşık gerçek dünya veri örneklerinin yapısını öğrenerek ve aynı yapıya bağlı benzer sentetik örnekler üreterek, üretken çekişmeli ağların (GAN'lar) yardımıyla yapmak mümkün müdür? Üretken modellerin gelişmesindeki ilerlemelere göre, cevap en azından bir dereceye kadar evet gibi görünüyor. Üretken modellerde hedef, mevcut veri setine yakın sentetik örnekler üretmektir; diğer bir deyişle, verilen bir veri setindeki örneklerin türetildiği dağılımı öğrenip bu dağılımdan yeni örnekler üretmektir. Genel olarak veri setleri sınırlı sayıda örnekler içerdiginden, her zaman veri seti dağılımını tam olarak öğrenmek mümkün olmamaktadır. Bu nedenle gerçek veri dağılımına mümkün olduğunda benzer bir dağılım modellenmeye çalışılmaktadır. Üretilen verilerin kalitesini ölçmek için kapsamlı ve kapsayıcı bir metriğe ihtiyaç duyulmaktadır. Bu çalışmada, GAN'ların değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilecek yeni bir yöntemden bahsedilmiş olup çeşitli uygulamalar yapılmıştır. Ayrıca GAN'lar ile ilgili etik ve hukuki problemlere değinilmiştir.

Anahtar Kelimeler – Üretken Çekişmeli Ağlar, Üretken Çekişmeli Ağların Uygulamaları, Etik, Yapay Zekâ, Derin Öğrenme

Atıf: Gözet, M., Filiz, U. ve Yılmaz, A. E. (2023). Üretken Yapay Zekâ. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 32-40.

Generative Artificial Intelligence

Extended Abstract

Can a machine attempt to approach the task of creating unique content that would be indistinguishable from human-produced artefacts? Is it possible to do this with the help of generative adversarial networks (GANs) by learning the structure of the complex real-world data examples and generating similar synthetic examples that are bound by the same structure? According to the recent advances in the development of generative models, the answer seems to be yes, at least to an extent. In generative models, the goal is to generate synthetic samples close to the existing dataset; In other words, it is to learn the distribution from which the samples in a given data set are derived and to generate new samples from this distribution. In general, since the datasets contain a limited number of samples, it is not always possible to learn the dataset distribution exactly. For this reason, it is tried to model a distribution as similar as possible to the actual data distribution. A comprehensive and inclusive metric is needed to measure the quality of the data produced. In this study, a new method that can help mitigate the effects of small changes and subtle differences in real datasets that can significantly affect the evaluation scores of GANs is mentioned and various applications are made. In addition, ethical and legal problems related to GANs are mentioned.

Keywords – Generative Adversarial Networks, GANs Applications, Ethic, Artificial Intelligence, Deep Learning

Citation: Gozet, M., Filiz, U. and Yılmaz, A. E. (2023). Generative Artificial Intelligence. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(1): 32-40.

I. GİRİŞ

Makine öğrenmesi algoritmaları, veri setinin etiketlenip etiketlenmemesine göre denetimli ve denetimsiz öğrenme olmak üzere iki kategoriye ayrılabilir. Denetimli öğrenme için farklı özelliklere sahip bir veri seti gereklidir ve veri setindeki her örnek etiketlenmelidir. Denetimli öğrenmenin temsilcileri sınıflandırma, regresyon ve yapılandırılmış çıktı problemleridir. Ancak denetimsiz öğrenme, etiketli veri içermez diğer bir deyişle bağımlı değişken yoktur. Veriler bir dizi örnek x'ten oluşur ve amaç, x'in istatistiksel yapısını öğrenmektir. Genel olarak yoğunluk tahmini, kümeleme, sentez ve gürültü giderme denetimsiz öğrenme olarak kabul

edilir. Denetimli öğrenme durumunda, etiketleri otomatik olarak toplamak veya not eklemek zordur. Bu nedenle, araştırmacılar denetimsiz öğrenmeye daha fazla önem vermektedir. Denetimsiz öğrenme görevinde, üretken modeller en umut verici teknolojilerden biridir. Tipik üretken modeller genellikle Markov zincirlerine, maksimum olabilirliği ve yaklaşık çıkarımı dayalıdır. Üretken modeller, bir süredir farklı alanlardaki araştırmacıların ilgisini çekmektedir. Makine öğrenimi ve daha spesifik olarak derin öğrenme alanlarındaki son gelişmelerle birlikte, üretken modellemenin araştırma çalışmalarının sayısında ve farklı alanlardaki uygulamalarında muazzam bir artış görülmektedir. Üretken modelleme sanat eseri ve müzik bestelerinden,

sentetik ve tıbbi veri kümelerine kadar, hem hayal gücünün hem de zekanın sınırlarını zorlamaktadır [5].

Üretken modellerin girdi değişkenleri genellikle gerçek dünya değerleriyle hiç ilgili olmayan ve hatta çoğu zaman rastgele oluşturulmuş sayı vektörleridir. Üretken modeller, görüntü üretimindeki başarısının yanı sıra rastgele gürültüden metin, müzik veya video üretme gibi birçok farklı alanda çalışmalar yapılmaktadır [39, 40].

Gerçek görüntülere benzer sentetik görüntülerin üretiminde Üretken Çekişmeli Ağlar (Generative Adversarial Networks-GAN) oldukça başarılı bir performans sergilediği görülmektedir [1].

II. MATERİYAL VE YÖNTEM

2.1. Üretken Modeller ve Üretken Çekişmeli Ağlar

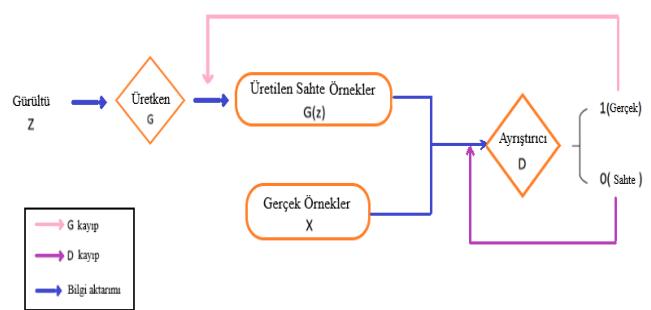
Büyük ölçüde oyun teorisi kavramlarından ilham alan üretken çekişmeli ağlar, ilk olarak Goodfellow ve arkadaşları tarafından önerilmiştir [1]. Üretken çekişmeli ağlar, yapay zekâ alanındaki en önemli araştırma yollarından biridir ve olağanüstü veri üretme kapasitesi geniş ilgi görmüştür [18]. Bu ağların amacı, veri kümelerindeki örnek görsellere benzer sentetik görüntüler üretmektir. Klasik derin ağ mimarilerinden farkı, üretici ve ayırcı olmak üzere iki derin ağ mimarisinin eğitiminin çekişmeli ve eşzamanlı bir şekilde gerçekleşirebilmesidir.

Üretken modeller yeni veri örnekleri oluşturabiliyorken ayırcı modeller, farklı veri örnekleri türleri arasında ayırmaya çalışmaktadır. Üretken bir model, gerçek hayvanlara benzeyen yeni hayvan fotoğrafları oluşturabiliyorken, ayırt edici bir model bir köpeği bir kediden ayırt edebilmektedir. Bir dizi X veri örneği ve bir dizi Y etiketi verildiğinde: üretken modeller ortak olasılık $p(X, Y)$ veya etiket yoksa yalnızca $p(X)$ 'i yakalarken ayırcı modeller koşullu olasılığı $p(Y | X)$ yakalar.

Üretken bir model, verilerin dağılımını içerir ve belirli bir örneğin ne kadar olası olduğunu söyler. Örneğin, bir dizideki bir sonraki kelimeyi tahmin eden modeller tipik olarak üretken modellidir, çünkü bunlar bir kelime dizisine bir olasılık atayabilirler. Ayırcı bir model, belirli bir örneğin muhtemel olup olmadığı sorusunu yok sayar ve yalnızca bir etiketin örneğe uygulanma olasılığının ne kadar olduğunu söyler [7].

2.2. Klasik Üretken Çekişmeli Ağ Mimarisi

Klasik üretken çekişmeli ağ mimarisi araştırmacılar tarafından geleneksel üretken modellerin performansını artırmak için geliştirilmiş, denetimsiz öğrenme için kullanılan bir sinir ağı mimarisidir. Şekil 1'de gösterildiği gibi bir üretken (generative, G) ve bir ayırtıcı (discriminator, D) olmak üzere iki farklı derin ağ mimarisine sahiptir. Bu yapısı ile bilinen derin ağ mimarilerinden farklılık gösterir ve öğrenme işlemi bu iki ağı rekabetçi bir şekilde çalışmasıyla gerçekleşir. Üretken çekişmeli ağlar hem üretken hem de ayırtıcı bir model içerirken, üretken ve ayırtıcı modeller ayrı ayrı var olabilmekte ve farklı görevler için kullanılabilmektedir. Sadece üretken modeller hedef dağılımdan yeni veri örnekleri oluşturabilmektedir.



Şekil 1. Klasik GAN mimarisi [41]

Şekil 1. de G derin ağı, giriş olarak aldığı bir gürültü vektöründen gerçek görüntülere benzer görüntüler üretmeye çalışırken; D derin ağı, üretici tarafından üretilen sentetik görüntüler sahte (0) ile gerçek (1) görüntülerini ayırt etmeye çalışır. Bu şekilde her iki ağı da paralel, çekişmeli bir şekilde eğitilir ve bu eğitim aşamasında G kademeli olarak gerçek görüntüler ile ayırt edilemeyecek yeni görüntüler üretir [9]. Bu çekişmeli eğitim, üretken ve ayırt edici kayıpların değer fonksiyonu ile minimax oyunu olarak adlandırılır. Kayıp fonksiyonu denklem 1'de formüle edilmiştir.

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

Burada x , gerçek veri dağılımı $p_{data(x)}$ 'den örneklenir, z , önceki dağıtım $p_{z(z)}$ 'den örneklenmiştir. Üretici gerçek verilerle aynı verileri üretebildiğinde ve ayırtıcı artık sahte verileri gerçek verilerden doğru bir şekilde ayırt edemediğinde, iki ağı Nash dengesine ulaşmak için eş zamanlı olarak eğitilir.

Klasik üretken çekişmeli ağ mimarisinin geleneksel üretken modellere göre çeşitli avantajları vardır. Gerçek veri noktalarına benzer yüksek kaliteli veri noktaları üretebilmek, çeşitli uygulamalar için çeşitli veri noktaları üretebilmek ve etiketli verilere olan ihtiyacı azaltan denetimsiz öğrenme modelleri kullanılarak eğitilebilmektedir. Bununla birlikte, klasik üretken çekişmeli ağ mimarisinin de bazı sınırlamaları vardır. Ana sınırlamalardan biri, özellikle büyük veri kümelerinin eğitilmesinin hesaplama açısından pahalı olmasıdır. Ek olarak, optimum performans elde etmek için kullanılan hiperparametreleri ayarlamadan çok kolay bir iş olmamasıdır. Fakat yine de gerçek veri noktalarına benzer yüksek kaliteli veri noktaları üretebilen denetimsiz öğrenme için güçlü bir araçtır. Bazı sınırlamaları olmakla birlikte, üretken modelleme alanında devrim yaratma ve gerçekçi veri noktaları üretebilen yapay zekâ sistemlerinin oluşturulması için yeni olasılıklar açma potansiyeline sahiptir.

Üretken çekişmeli ağlar Goodfellow tarafından önerildiğinden beri, çok fazla üretken çekişmeli ağ varyantı yayınlanmıştır [22].

Tablo 1. Üretken çekişmeli ağ taksonomisi mimariler

GAN Taksonomisi		
Mimariler		
Ağ Mimarileri	Gizli Alan Mimarileri	Uygulamaya Odaklı Mimariler
LAPGAN, 2015 / DCGAN, 2016 / BEGAN, 2017 / PROGAN, 2017; AutoGAN, 2019 / SAGAN, 2018; BigGAN, 2019; YLG, 2020	CGAN, 2014; AC-GAN, 2017; InfoGAN, 2016 / BiGAN, 2016 / SGAN, 2016	CycleGAN, 2017; DiscoGAN, 2017; DualGAN, 2017 / SRGAN, 2016 / StyleGAN, 2019 / Face Completion GAN, 2017 / AlphaGAN, 2018 / Moco-GAN, 2018 ; DVD-GAN, 2019 / SinGAN, 2019

GAN taksonomisi, GAN mimarileri ve kayıp değişkenleri olmak üzere iki ana kategoriye ayrılmıştır. Tablo 1 GAN mimarilerini içermektedir. Mimariler: ağ mimarisi, gizli alan mimarileri ve uygulama odaklı mimariler olmak üzere üç alt kategoriye ayrılmıştır.

Tablo 2. Üretken çekişmeli ağ taksonomisi kayıp değişkenler

GAN Taksonomisi		
Kayıp		
Kayıp Tipleri		Düzenleştirme
IPM Tabanlı	IPM Tabanlı Olmayan	WGAN-GP, 2017 / WGAN-CT, 2018 / WGAN-LP, 2017 / MRGAN, 2016 / SN-GAN, 2018 / SS-GAN, 2019
RGAN, 2018 / WGAN, 2017 / Geometric GAN, 2017; Sphere GAN, 2019	FCGAN, 2014; LSGAN, 2016; f-GAN, 2016 / UGAN, 2016 / LS-GAN, 2017	

Tablo 2. de kayıp değişkenler, kayıp tipleri ve düzenleme olarak iki alt kategoriye ayrılmıştır. Yazarlar, bu taksonomiyi 323 üretken çekişmeli ağ makalesini inceleyerek hazırlamışlardır [22].

2.3. Değerlendirme Metrikleri

Son zamanlarda, üretken çekişmeli ağların teorik

başarılarına rağmen, üretilen verilerin kalitesini ölçmek için kapsamlı ve kapsayıcı bir metriğe ihtiyaç duyulmaktadır. Bu nedenle üretken modelleri karşılaştırmak için IS, MS, FID, MS-SSIM, vb. gibi farklı metrikler kullanılmaktadır. Son yıllarda alanda yapılan çalışmalar bazları FID metriğinin temel sorunları olan taraflılık (bias) ve küçük ayrıntılara hassaslık problemlerine bir çözüm bulmak amacıyla geliştirilmiştir. Bu başlık altında ek olarak Filiz tarafından önerilmiş, değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilecek yeni bir yöntemden de bahsedilmiştir.

2.3.1. Başlangıç Puanı (IS)

Bu metrik, üretken çekişmeli ağlarda yaygın olarak kullanılmaktadır ve Salimans vd. tarafından [36] önerilmiştir. IS'nin yüksek olması, oluşturulan modelin yüksek kaliteli örnekler üretебildiğini, aynı zamanda örneklerin de çeşitli olduğunu göstermektedir.

$$IS(G) = e^{(\mathbb{E}_{x \sim P_g} D_{KL}(p(y|x)||p(y)))} \quad (2)$$

Burada x , P_g den örneklenir ve $D_{KL}(p(y|x)||p(y))$ x ve y dağılımları arasındaki Kullback-Leibler sapması, $p(y|x)$ koşullu sınıf dağılımı ve $p(y) = \int_x p(y|x)p_g(x)$ marjinal sınıf dağılımıdır.

İyi sonuçlar için karşılanması gereken 2 koşul önerilmiştir:

- 1- 1) $p(y|x)$ düşük entropiye sahip olmalıdır, yani görüntüde tek bir nesne olmalıdır.
- 2) $p(y)$ yüksek entropiye sahip olmalıdır.

Bu varsayımlar karşılandıktan sonra, daha yüksek IS puanı, daha iyi bir üretim performansını göstermektedir. Bununla birlikte, IS'nin de sınırlamaları vardır, eğer üretici model, çöküş moduna girerse, IS puanı yüksek olsa da doğru bir başarı değerlendirme yöntemi olmayacağındır. GAN, bir görüntü veri kümelerindeki tüm sınıfları algılamada başarısız olduğunda, başlangıç puanı değişmez, bu nedenle, GAN'in performansını göstermez. Bunun için başka metriklere ihtiyaç duyulmaktadır.

2.3.2. Mod Puanı (MS)

IS'ye dayanarak, oluşturulan örneklerin çeşitliliğini ve görsel kalitesini aynı anda yansıtabilen MS adlı başka bir değerlendirme ölçütü önermiştir. Bu değerlendirme metriği, yer本来 etiketleri üzerindeki önceki dağılımlara duyarlı olmayan IS sorununu ele alır.

2.3.3. Frechet Başlangıç Mesafesi (FID)

FID, Heusel ve diğerleri tarafından önerilmiştir [37] ve sınıf içi modun düşmesini tespit etmek için kullanılır. Bu yaklaşımında, üretilen örnekler, başlangıç ağının belirli katmanı tarafından sağlanan özellik uzayına gömülüdür. Üretilen örneklerin çok boyutlu bir Gauss'u takip ettiği varsayıma dayanarak, oluşturulan örnekler ile gerçek veriler arasındaki

ortalama ve kovaryans hesaplanır. FID'in, resim kalitesi ile arasında negatif bir ilişki vardır. Düşük FID puanı, modelin daha iyi performans gösterdiğini gösterir. Aktivasyonların kovaryans matrislerinin ortalamaları ve izleri arasındaki Öklid mesafesinin karesi olarak hesaplanır:

$$FID = \|\mu_t - \mu_g\|_2^2 + Tr(\Sigma_t + \Sigma_g - 2\sqrt{\Sigma_t \Sigma_g}) \quad (3)$$

IS ile karşılaşıldığında, gürültüye karşı daha dayanıklıdır. Yetersiz örnek olması durumunda bile (yalnızca bir tür resim üretilir), yüksek bir FID değeri oluşmaktadır [41]. FID, pratik açıdan oldukça popüler olmasına rağmen, "görüntünün birden fazla anı üzerinde çalışma" [2] ve görüntüdeki küçük değişikliklerin yüksek etkisi gibi pek çok dezavantajlı davranışa sahiptir [44].

2.3.4. Görüntü Kalitesi için Çok Ölçekli Yapısal Benzerlik (MS-SSIM)

İki görüntü arasındaki benzerliği ölçmek için kullanılan tek ölçekli SSIM metriğinden farklı olarak, Wang ve ark. [22] ilk olarak çoklu ölçekli görüntü kalitesi değerlendirmesi için MS-SSIM'i önermiştir. İnsan algısı benzerlik yargısını tahmin ederek görüntülerin benzerliğini nicel olarak değerlendirir.

İyi bir değerlendirme metriği, oluşturulan örnekleri gerçek olandan ayırmalı, mod çöküsünü doğrulamalı ve aşırı ezberlemeyi tespit etmelidir.

2.3.5. Çekirdek Başlangıç Mesafesi (KID)

Çekirdek başlangıç puanı, rastgele seçilen örneklerle gerçek bir görüntü dağılımı P_r ile oluşturulan görüntü dağılımı P_g arasındaki farklılık miktarını ölçen bir metiktir. [45]. Teorik olarak MMD, bir polinom Gauss çekirdeği ile karelenmiş maksimum ortalama tutarsızlık olarak hesaplanır (Fortet ve diğerleri 1953):

$$\begin{aligned} M_k(P_r, P_g) &= \mathbb{E}_{x, x' \sim P_r}[k(x, x')] - 2\mathbb{E}_{x \sim P_r, y \sim P_g}[k(x, y)] \\ &+ \mathbb{E}_{y, y' \sim P_g}[k(y, y')] \end{aligned} \quad (4)$$

Burada k Gauss çekirdeğidir. $k(x, x') = e^{\|x-x'\|^2}$ dir. Uygulamada, yapılacak bu hesaplama için bir tahmin yapılması gereklidir, bu nedenle hem üretici hem de gerçek görüntü dağılımlarından sonlu örneklerle tahmin ediciler burada $P_r = \{x_1, x_2, \dots, x_n\}$ ve $P_g = \{y_1, y_2, \dots, y_n\}$ dir.

$$\begin{aligned} \hat{M}_k(P_r, P_g) &= \frac{1}{\binom{n}{2}} \sum_{i \neq i'} k(x_i, x_{i'}) - \frac{2}{\binom{n}{2}} \sum_{j \neq j'} k(x_j, y_j) + \\ &\frac{1}{\binom{n}{2}} \sum_{j \neq j'} k(y_j, y_{j'}) \end{aligned} \quad (5)$$

Tipki Fréchet Başlangıç Mesafesi gibi, Çekirdek Başlangıç Mesafesi de Inception-V3 ağının tahmininde normal dağılım varsayılar ve daha düşük Çekirdek Başlangıç puanı daha iyi bir performansı gösterir.

2.3.6. Önerilen yöntem

Yığınlama yöntemi, Üretken Çekişmeli Ağların (GAN'lar) değerlendirmesini iyileştirmenin bir yolu olarak önerilmiştir. Toplu işlemede, orijinal görüntü birden çok daha küçük görüntüye veya "görüntü parçalarına" bölünür. Metrik daha sonra her yığın için hesaplanır ve her yığının puanları toplanarak nihai puan elde edilir. Bu işlem matematiksel olarak aşağıdaki formülle temsil edilir:

$$\emptyset_{Total} = \sum_{b=0}^{\alpha * \beta} \emptyset_b \quad (6)$$

Burada \emptyset süreçte kullanılan metriği temsil eder ve b yığının indeksini gösterir. α ve β değerleri, yığınların sırasıyla satırını ve sütununu kontrol eden parametrelerdir.

Bu yöntemin amacı, her seferinde yalnızca bir görüntü yerine mevzubahis görüntünün içindeki birden çok görüntü grubunu dikkate alarak GAN'ların daha kapsamlı bir değerlendirme yapmasını sağlamaktır. Bu yaklaşım, Parmar vd. [44] tarafından tartışıldığı gibi değerlendirme puanlarını önemli ölçüde etkileyebilecek gerçek veri kümelerindeki küçük değişikliklerin ve ince farklılıkların etkilerini hafifletmeye yardımcı olabilir.

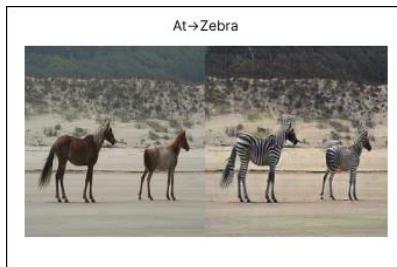
2.4. Üretken Çekişmeli Ağların Uygulamaları

Bir tür üretken model olan, GAN'ların doğrudan uygulama alanı veri üretimidir. Bu, gerçek örneklerin dağılımından öğrenmektedir ve dağılımla tutarlı örnekler oluşturmaktadır. Şu anda GAN'ların en başarılı uygulamaları; görüntü çevirisisi, görüntü süper çözünürlüğü, görüntü sentezi ve video üretimi vb. dahil olmak üzere bilgisayarla görme alanlarında kullanılmaktadır. Sadece görüntü değil, diğer medya türleri de (ses, metin) bu şekilde üretilebilir [10-13].

Görüntü içi boyama, görüntülerin eksik kısımları doldurulabilmektedir. Bir görüntüdeki boşlukları doldurma görevi olan görüntü içi boyama birçok uygulamada kullanılmaktadır. Ortaya çıkan alanı uygun görüntülerle doldururken istenmeyen görüntü içeriğini kaldırmak için de kullanılmaktadır [14].

Görüntü süper çözünürlüğü, düşük çözünürlüklü görüntüler, gözle görülür yükseltme kusurları olmaksızın yüksek çözünürlüğe yükseltir [15]. Süper çözünürlük, yakalanan görüntüleri iyileştirir ve gürültüyü oldukça iyi bir şekilde ortadan kaldırabilir, ancak güvenlik endişeleri nedeniyle birçok deney ve deneme yapılması gerektiğinden, tıbbi alanda GAN'ların benimsenmesi oldukça yavaştır. Sağlık hizmetiyle uğraşırken, modelleri değerlendirmek ve gürültü gidermenin görüntünün gerçek içeriğini yanlış bir teşhise yol açabilecek bir şekilde bozmamasını sağlamak için bir dizi alan ile ilgili uzmanın dahil edilmesi zorunlu hale gelmektedir.

Etki alanı uyarlaması, bir alandan gelen verileri diğer alandan gelen verilere benzettmektedir (ör. orijinal olarak tasvir edilen içeriği korurken normal bir fotoğrafı yağlı boyaya tablo gibi göstermek) [16]. Şekil 2. de at içeriği bulunan bir fotoğrafın CycleGAN modeli ile Zebralara dönüştürüldüğü bir örnek verilmiştir.

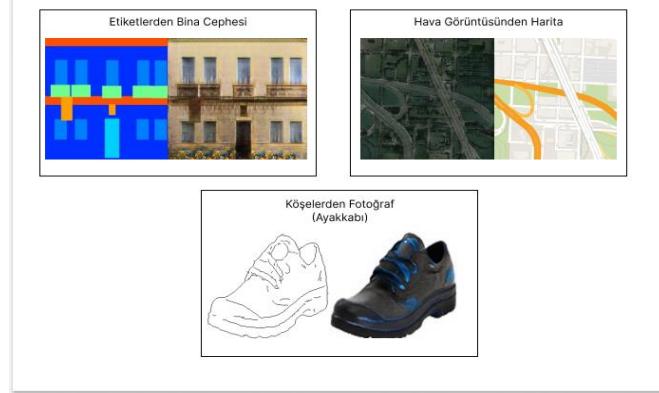


Şekil 2. Herhangi iki sırasız görüntü koleksiyonu X ve Y verildiğinde, algoritma bir görüntüyü otomatik olarak birinden diğerine "çevirmeyi" öğrenir ve bunun tersi de geçerlidir: ImageNet veri setinden alınan at görseli (solda) ve stil dönüşümü sonucunda oluşturulan zebra görseli (sağda).

Çizgi film karakteri üretmek, insan yüzleri girdi olarak alınıp yüksek yoğunluklu bir çökgen elde etmek için işleyerek GAN ile karakterler oluşturulabilir, bu da sıfırdan çizgi film karakterleri geliştirirken zaman kazandırılabilir [48].

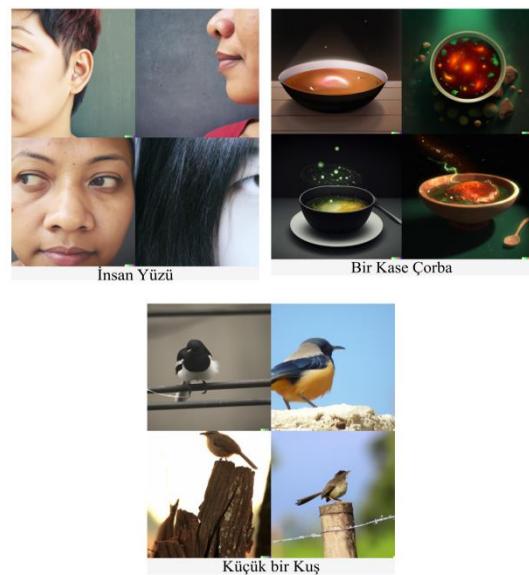
Sahte haberler ve sohbet robotları, insanlar her zaman makinelerle konuşmak istemişlerdir; ilk sohbet robottu ELIZA [6], 1960'larda MIT'de yazılmıştır ve bir kullanıcının girdisini dönüştürmek ve bir yanıt oluşturmak için basit bir program kullanılmıştır. BERT modeli daha sonra dönüştürücü birimleri, doğal dil kalıplarının ve bağlamsal önenin güçlü birçok boyutlu kodlamasında birleştirir. Bu yaklaşım, doğal dil işleme (NLP) görevleri veya chatbot diyalog sistemleri için belge oluşturmada kullanılabilir.

Üretken yapay zeka görüntü dönüşümleri için de sıkça kullanılmaktadır. Etiket girişlerinden bina cephesi üretimi, siyah beyaz görüntülerin renklendirilmesi, uydu/hava haritası giriş görüntülerini Google Haritalar benzeri çıktılara dönüştürme, etiketleri segmentlere ayırmak için sokak görünümü gibi anlamsal segmentasyon görevleri eskiden fotoğrafa, eskiden portreye, eskiden kediye, eskiden renkli Pokémon'a ve hatta ayakkabılar, çantalar vb. arka planı kaldırma boyama sırasında veya görüntü tamamlama, termalden RGB görüntüye çeviri, gündüzden geceye manzara ve yazdan kışa manzara dönüşümü gibi birçok farklı uygulaması bulunmaktadır. Şekil 3'te pix2pix algoritması ile oluşturulmuş farklı uygulamalar verilmiştir.



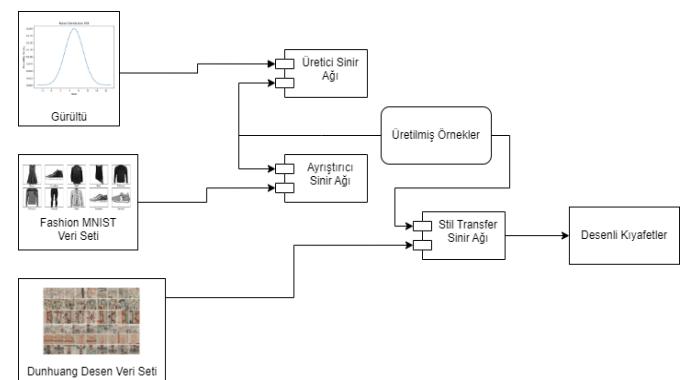
Şekil 3. Pix2pix algoritmasıyla görüntü çevirisi örnekleri [16, 49, 50]

Derin sahtecilik (Deepfake), çoklu girdilerden öğrenen ve çıktı üreten en iyi tekniklerden biridir. Yüz değiştirmek, görüntü oluşturmak için de kullanılabilir. Şekil 4'te farklı metinler verildiğinde Deepfake modeli ile oluşturulan farklı görseller verilmiştir.



Şekil 4. Deepfake ile oluşturulan görüntü örnekleri. Görüntüler DALL-E modeli ile oluşturulmuştur.

Moda endüstrisinde tasarım ve desenler çok önemli bir rol oynamaktadır ve zaman geçtikçe tasarımcılar yeni giysiler için yeni tasarım ve desenler bulmaları gerekmektedir. Bu teknik, moda tasarımcısının kumaş ayakkabı, çanta ve cüzdanlar için yeni bir tasarım oluşturmaya yardımcı olan eski tasarım ve desenlerin kombinasyonundan desen ve tasarım oluşturmada kullanılabilir [8, 42]. Şekil 5'te Dunhuang desen veri seti içindeki farklı desenler, Fashion MNIST veri seti içindeki kıyafetlerle birleştirilerek farklı kıyafet tasarımlarının nasıl elde edileceğini gösteren diyagram verilmiştir.



Şekil 5. Dunhuang desen veri seti ve Fashion MNIST veri seti kullanılarak farklı desenlerden kıyafet elde edilmesi [42]

Bu teknoloji eğlence amaçlı yaratılmıştır, ancak şimdi derin sahtecilik popülerlik kazandıkça, kullanımı artmaya başlamıştır. Bu teknik artık ünlülerin ve yüksek profilli politikacıların yüzünü başka biriyle değiştirerek karakter karalaması için kullanılmaktadır. Bu teknik, gelecek yıllarda etik olmayan şekillerde kullanılırsa problem teşkil edeceğinin öngörümektedir [38].

Kendisine birçok farklı kullanım alanı bulmasına rağmen,

GAN'ların hala çözülmesi gereken problemleri vardır. GAN'ları eğitmek herkesin bildiği gibi zordur ve bazen bu ağlar, gerçek hayatı belirli şeylerin nasıl çalıştığını anlamak için eğitim verilerinde yeterli bilgiye sahip olmadığı için, beklenmedik görüntüler üretebilmektedir. Örneğin, portre görüntülerinden oluşan bir veri kümesi verildiğinde, ağ insanların yüzlerinin nasıl modelleneceğini biliyor olabilir, ancak belirli giysi öğelerinin nasıl görünmesi gerektiği fikrini kavramada başarısız olabilir. Bu nedenle, beklenen sonuçla ilgili olacak verilerin dikkatli bir şekilde seçilmesi zorunludur.

2.5. Zorlukları ve Sınırlılıkları

Temel üretken çekişmeli ağ mimarisi ile düşük çözünürlüğe sahip veri setleri kullanılarak nispeten iyi sonuçlar üretilmektedir. Fakat yüksek çözünürlüklü veri setleri kullanıldığında genel olarak iki ana problem meydana gelmektedir. İlk problem, üretken çekişmeli ağın kararsızlık durumuna düşmesidir. Bu problem ayırtıcı ağı, üretici ağa üstünlük sağlama sonucu ortaya çıkmaktadır; diğer bir deyişle ayırtıcı ağı, üretici ağı için yüksek gradyan değerleri üretmekte ve üretici ağını istikrarsız hale getirmektedir. Yakın zamanda bu probleme başa çıkmak için, kayıp fonksiyonları [24-27], düzenlileştirme teknikleri [28-31], üretken çekişmeli ağ mimarileri [32-35] önerilmektedir.

Üretken çekişmeli ağlardaki ikinci temel sorun, her zaman çökme moduna girmesidir. Mod çöküşü; üretici ağı çok boyutlu uzayda benzer özelliklere sahip çok fazla örnek ürettiği veya üretilen örnekler arasında minimum çeşitlilik olduğu durumu göstermektedir. Coğu zaman, GAN'lar gerçek deneye yaklaşamaz ve optimal olmayan çözümler üretir. Bu problemin üstesinden gelmek için ise ayırtıcı ağa girdi olarak her bir yığındaki imgelerin birbirile olan benzerlik istatistikleri verilmektedir.

GAN'ların eğitilmesinin zor olduğu bilinmektedir ve bu da genellikle anlamsız çıktılar üreten üreticilere neden olmaktadır. GAN'ların öğretiklerini ve çok katmanlı GAN'ların ara temsillerini anlamaya ve görselleştirmeye çalışan çok sınırlı yayınlanmış araştırma vardır [17].

2.6. Problemlere Yönük Oluşturulan Çözüm Önerileri

Umut verici başarılarla rağmen, gradyan kaybolması, mod çökmesi ve iraksak veya salınımlı davranış gibi birkaç yaygın sorunlu kararsız eğitim ve yakınsama davranışları nedeniyle GAN'ları eğitmek hala zordur. Üretken çekişmeli ağların eğitimindeki bu sorunlar genellikle bu alanda daha fazla araştırma ve uygulanabilirliği engellemektedir. Son zamanlarda, yukarıda belirtilen sorunları hafifletmek için mevcut çalışmalar, daha kararlı ağ mimarileri tasarlamak, öğrenme hedeflerini değiştirmek, hedefleri düzenli hale getirmek, eğitim stratejileri, hiperparametreleri ayarlamak vb. gibi çeşitli çözümler önerilmiştir.

Mevcut çalışmaların çoğu ya görüntü kalitesine ya da görüntü çeşitliliğine odaklanmıştır. Olası bir araştırma yönü,

düşük görüntü çeşitliliğinden zarar görmeyen görüntü kalitesi üzerinde çalışmak olabilir. Ayrıca, GAN'ların eğitim istikrarsızlığı sorununu ele almak için mevcut yöntemler, değişikliklere karşı çok hassas olan bulușsal yöntemlere hala bağlıdır. Bu yaklaşımın yeni alanlarda uygulanabilirliğini kısıtlayan temel sebeplerden biri de budur. Öte yandan, mevcut çalışmaların çoğunun bir seferde yalnızca bir eğitim sorununu çözmeyi önerdiğini ve çoğu zaman teorik analiz içermemiş gözlemlenmiştir. Diğer bir önemli araştırma yönü, daha izlenebilir formülasyonları keşfetmek ve eğitimi istikrarlı ve anlaşıllır kılmak amacıyla GAN'ların eğitim sürecindeki sorunları ele almak için teorik bir çerçeveye/analizlere sahip olmaktadır.

Ayrıca, önerilen çözümler eğitim iyileştirme ölçüğünde farklılık göstermektedir. Modelerin çoğu, hiperparametre ayarlarını ve hesaplama kaynaklarını iyileştirmek benzer sonuçlara ulaşabilir. Bu nedenle, ilgili çalışmaların büyük çoğunluğunun en son teknoloji verimlilik yerine en yüksek doğruluk elde etmeye odaklandığını söyleyebilir. Mevcut işlerin üzerinde algoritmik iyileştirmelere sahip çözümler geliştirmek, geleceğe yönelik bir yön olabilir.

Uygun mimari seçiminin, amaç fonksiyonlarının ve optimizasyon tekniklerinin GAN eğitim kararlılığını geliştirdiği GAN tasarım ve optimizasyon çözümü önerilmiştir. Ek olarak, amaç fonksiyonları, farklı GAN'lar için gelecekteki araştırmalarda keşfedilebilecek olan optimizasyon stratejilerinin kullanımına, hiperparametre seçimine ve eğitim adımlarının sayısına duyarlıdır. Öte yandan, GAN eğitimini geliştirmek için çevrimiçi öğrenme, oyun teorisi varyantları vb. gibi diğer teknolojilerin kullanılmasına yönelik araştırmalar henüz başlangıç aşamasındadır. Uygun mimari, kayıp fonksiyonu ve optimizasyon tekniklerinin bir kombinasyonu, üstün sonuçlar verebilir ve gelecekte keşfedilecek bir araştırma yönü olabilir.

2.7. Etik

Dünyanın nasıl modellendiği ve bu modelleri kullanmanın diğerlerinin dünyayı algılama biçimini nasıl etkileyebileceği önemli bir konudur. GAN'ların öğrendiği semantik kavramlar, verilere dayalıdır ve dünyanın nasıl çalıştığını dair gerçeği tam olarak temsil etmemektedir. Örneğin, çoğu insan verisi erkek veya kadın olarak tanımlanmaktadır. Bu nedenle bir GAN, tek tip bir spektrum olarak erkek ve kadın arasında bir şekilde doğrusal bir ilişki öğrenmektedir. Ancak bu, sadece erkek ya da kadından oluşan birçok insan için gerçekle uyusmamaktadır. GAN'lar kullanılarak bir görüntüde cinsiyetin manipüle edilmesi, bu nedenle, onu herhangi bir sistemin parçası olarak açıklamadan önce düşünülmeli gerekmektedir. Oluşturulan herhangi bir sistem (makine öğrenimi veya başka türlü) için bazı basit sorular sorulmalıdır: Sisteme faydalanan veya zarar gören insanlar var mı ve bu insanlar bu faydayı veya zararı görmeli mi? İnsanların davranışlarını olumlu veya olumsuz yönde değiştirebilir veya

İyi niyetli kullanıcılar tarafından bile kötüye kullanılabilir mi? Genel olarak, mikro ve makro ölçekte neyin yanlış gidebileceği düşünülmelidir. Etik çok karmaşık bir konudur. Ancak derin öğrenmeyle birlikte birçok farklı şeyi otomatikleştirme yeteneği vardır. Bu, toplum için bir nimet olabilir ve insanları zahmetli ve yorucu işlerden kurtarabilir, ancak aynı zamanda istenmeyen eşitsizlikleri bir ölçekte büyütübilir ve çoğaltabilir.

GAN'lar, güvenlik tehdidi oluşturabilecek sahte belgeler veya diğer hassas materyaller oluşturmak için kullanılabilir. Örneğin, birine ait olan ağız hareketlerini başka bir sesle eşleştirerek taklit ettip bilgilendirebilir ve videoları değiştirmek için kullanılabilir. Ayrıca başkalarını yanılmak için güçlü bir araçtır. Kodu çevirmişi yayınlarsanız, başkalarına zarar vermek için kolayca kötüye kullanılabilir. Bu kodu halka yerleştirmenin faydalari nelerdir ve zararlarından ağır basar mı? Eğer kötüye kullanılabilen bir üretken oluşturursanız, belki de modelinizden/yaklaşımınızdan bir görüntünün gelip gelmediğini anlayan ve böylece herhangi bir kötü amaçlı kullanımı tespit etmeye yardımcı olan bir detektör üzerinde çalışılabilir. Bunlar soyut problemler gibi görünebilir, ancak işin içindeyken bazı endişeler olacaktır. Örneğin, yakın tarihli bir rapor, derin sahtekarlık olarak bilinen deepfakelerin insanları yüzbinlerce doları dolandırmak için kullanıldığını göstermiştir [43]. Etik kolay cevapları olan siyah beyaz bir mesele değildir. Yapay zekanın sosyal adalet, demokrasi ve insan onuru üzerindeki etkisi gibi daha geniş toplumsal ve kültürel konuları kapsar. Bir iş yaparken etrafında düşünülmesi gerektiği unutulmamalıdır.

2.8. Hukuki Hususlar

Makine öğrenimi, veri bilimi ve üretken çekişmeli ağlar alanlarındaki hızlı gelişmeler, derin sahtekarlık (deepfake) olarak bilinen yeni bir içerik oluşturma teknolojisi oluşmuştur. Tıpkı önceki birçok teknoloji gibi (Sony Betamax kaydedici, sanal gerçeklik veya Bitcoin), derin sahtekarlıklar başlangıçta bazı yasa dışı veya ahlaksız faaliyetlere uygulanmıştır [47]. Medyanın yaratılmasından ve kullanılmasından kaynaklanan ve yasal yelpazeyi kapsayan, seçim yasası, ceza hukuku, kanıt ve fikri mülkiyet alanlarındaki sonuçlar da dahil olmak üzere potansiyel sonuçlar vardır [46].

Hukuki açıdan, mahremiyete yönelik saldırının yanı sıra, yaratıcı derin sahtekarlıkların yasallığıyla ilgili anlaşmazlıklarda sözleşme, haksız fil veya mülkiyet hukukundan kaynaklanan bir dizi başka temel yasa doktrin geçerli olabilir. Ek olarak, yaratıcı derin sahteler, IP ile ilgili belirli tartışmalara yol açabilir. Daha spesifik olarak, telif hakkı yasası açısından, bir derin sahte yaratıcının yeni oluşturulan derin sahtecilik için telif hakkı sahibi olduğunu iddia edip edemeyeceği veya orijinal içeriğin kullanımının (bir veya daha fazla telif hakkıyla korunan çalışma) ihlal teşkil edip etmediği sorulanabilir. Ayrıca telif hakkı ve/veya görüntü hakları derin sahtekarlığın yaratıcısının sorumluluktan muaf

olacak belirli bir doktrine güvenip güvenemeyeceği sorgulanabilir. Örneğin, telif hakkı ihlali durumunda, derin bir sahtekarlığın yaratıcısı, parodi veya hiciv gibi yasal muafiyetlere başvurabilir.

Ortak hukuk mahkemeleri önünde bir telif hakkı ihlali iddiası söz konusu olduğunda, derin sahtekarlığın yaratıcısı sorumluluktan kaçmak için adil kullanım doktrinine güvenebilir. Daha spesifik olarak, derin sahtekarlığın yaratıcısı ABD mahkemelerinde dava edilirse, davalı, adil kullanımı olumlu bir savunma olarak, yani davacı bir telif hakkı ihlali tespit etmemi Başardıktan sonra ileri sürebilir. Derin sahtekarlığın yaratıcısının sorumluluktan kaçip kaçamayacağı sorusu, davanın olgusal koşullarına ve ihlalde bulunduğu iddia edilen kişinin mahkemeyi adil analizin dört faktörünün kendi lehine olduğuna ikna edip edemeyeceğine bağlı olacaktır. İlk olarak, sanık yeni yaratılan derin sahtekarlığın doğası gereği dönüştürücü olduğunu ve derin sahtekarlığın ahlaki açıdan iyi amaçlar için "kullanılmasını" amaçlandığını göstermelidir. Ancak derin sahtecilik ticari amaçlarla kullanılırsa davalı adil kullanım göstermekte zorluk yaşayabilir. İkincisi, adil kullanım doktrini, orijinal çalışanın doğasının ne olduğuna bakmayı gerektirir: yayınlanmış mı, yayınlanmamış mı? Derin sahtecilik söz konusu olduğunda, özellikle derin sahteciliğin çok sayıda girdi dosyasına dayandığı durumlarda, adil kullanım doktrinin bu ikinci şartının belirli bir durumda nasıl sonuçlanacağını görmek zor olabilir. Üçüncü, bir derin sahte davadaki sanık, derin sahte oluşturmak için kullanımın önemsiz olduğunu göstermede başarılı olabilir ve tüm anlaşmazlık, derin sahte oluşturmak için kullanılan orijinal çalışanın (veya eserlerin) kalitesi ve miktarı etrafında dönecektir. İhlal ettiği iddia edilen kişi, bir filmin yalnızca kısa bir parçası kullanılmışsa daha fazla şansa sahip olabilir; ancak bu kısa parça bir filmin en kötü şöhretli sahnesiyse, davalı bu noktada başarılı olamayabilir. Son olarak ve dördüncü olarak, adil kullanım analizi, orijinal ürünün potansiyel pazarı üzerindeki etkisinin değerlendirilmesini gerektirir. Yine, bu, davanın verili olgusal koşullarına bağlı olacaktır [47].

Gelişmekte olan birçok teknoloji için, yasanın ortaya çıkardıkları benzersiz sorunlara acil bir çözümü yoktur. Sonuç olarak, mahkemeler ve avukatlar, kendi davalarında ve masalarında karşılaşlıklarını bu sorunlara çözüm üretemelidir. Bu sürecin etkinliği, hukuk alanına, teknolojinin türüne, davayı gören mahkemeye ve bir dizi başka faktöre bağlı olarak önemli ölçüde değişmektedir [46]. Bu nedenle, derin sahtelerin kaderinin, derin sahte tespit teknolojilerinin geliştirilmesine ve içerik dağıtım platformlarının kötü niyetli içeriği belirlemeye yönelik etik taahhütlerine bağlı kalması önerilmektedir [47]. Bireylerin ve kuruluşların GAN'ları herhangi bir amaçla kullanmadan önce en son yasal gelişmelerden haberdar olmaları ve yasal riskleri azaltmak için stratejiler geliştirmeye yardımcı olabilecek hukuk uzmanlarından danışmanlık almaları önem arz etmektedir.

III.SONUÇ

Üretken modellerin ağ ve algoritmalarının mimarisini iyileştirerek, insanların ayırt etmesi zor olan görüntüler, sesler, videolar ve metinler üretebilen daha güçlü bir üretken model tasarlamak mümkün görünmektedir. Görüntülerden metinlere ve hatta melodilere kadar veri oluşturmak, buzdağının sadece görünen kısmını temsil etmektedir. Yapay zekânın sürekli gelişmesiyle birlikte siber güvenlik ve hatta yapay zekâ güvenliği araştırmacılar tarafından giderek daha fazla ilgi görmektedir. Özel yeni üretken çekismeli ağlar uygulamalarının ortaya çıkışını, artırılmış gerçeklik, eğitim verisi oluşturmaktan, güvenlik alanından tıp alanına kadar üretken çekismeli ağların büyük fayda sağlayacağı öngörmektedir. Üretken çekismeli ağ modellerinin hem ele alınan problemlerde daha iyi sonuçlar almasını sağlamak hem de benzer birçok problemde kullanışlı hale getirmek için değerlendirme metrikleri geliştirilerek performansını artırmaya yönelik çalışmalar yapılmaya devam etmektedir. Diğer taraftan GAN'lar, kimlik hırsızlığı, var olmayan kişilerin sentetik görüntülerini oluşturmaktan, birinin yapmadığı bir şeyi söylemiş veya yapmış gibi görünmesi için değiştirilmiş videolar veya resimler olan deepfake'ler oluşturmaktan de kötü amaçlar için kullanılabilir. GAN'lar, mevcut telif haklarını veya ticari markaları ihlal edebilecek ve potansiyel yasal anlaşmazlıklara yol açabilecek içerikler üretemek. GAN tarafından oluşturulan içeriğin kötü amaçlarla kullanılma potansiyeli veya GAN'ların insan yaratıcılığının ve özgürlüğünün yerini alma potansiyeli gibi bir dizi etik kaygıyı gündeme getirmektedir. Bu kaygıları önüne geçmek için GAN'ları kullanırken yasal ihlalleri önlemek, etik yönergeleri kullanmak/gelistirmek, yetkili eğitim verileri kullanmak, gizliliğe saygı duymak, derin sahtekarlıklarını tespit etmek için önlemler almak ve hukuk uzmanlarına danışmak gerekmektedir. GAN'ların potansiyel risklerini ve faydalarını anlamak için daha fazla araştırmaya ihtiyaç vardır.

KAYNAKÇA

- [1] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). *Generative Adversarial Networks*, In Proceedings of the 27th International Conference on Neural Information Processing Systems - (NIPS'14), 2, (pp.2672–2680). Montreal, Canada, December.
- [2] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
- [3] Xu, L., Zeng, X., Li, W., & Huang, Z. (2020). Multi-granularity generative adversarial nets with reconstructive sampling for image inpainting. *Neurocomputing*, 402, 220–234. <https://doi.org/10.1016/j.neucom.2020.04.011>
- [4] Hedjazi, M. A., & Genc, Y. (2021). Efficient texture-aware multi-GAN for image inpainting, *Knowledge-Based Systems*, 217, 106789. <https://doi.org/10.1016/j.knosys.2021.106789>
- [5] Babcock, J., & Bali, R. (2021). *Generative AI with Python and TensorFlow* 2. Birmingham, UK: Packt Publishing.
- [6] Available:<http://blogs.evergreen.edu/cpat/files/2013/05/Computer-Power-and-Human-Reason.pdf> (Erişim tarihi: 02.01.2023)
- [7] Available:<https://developers.google.com/machine-learning/gan/generative> (Erişim tarihi: 29.12.2022)
- [8] Gatys, L. A., Ecker, A. S., & Bethge, M. (2016). Image style transfer using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2414-2423).
- [9] Çelik, G. *Üretken Ağlar ve Uygulamaları*. Türkçe Doktora Tezi. İnönü Üniversitesi Fen Bilimleri Enstitüsü, İnönü, Haziran, 2021.
- [10] Available: <https://github.com/NVLabs/stylegan2> (Erişim tarihi: 10.01.2023)
- [11] Wu, Y., Donahue, J., Balduzzi, D., Simonyan, K., & Lillicrap, T. (2019). Logan: Latent optimisation for generative adversarial networks. *arXiv preprint arXiv:1912.00953*.
- [12] Available: <https://github.com/robbiebarrat/art-DCGAN> (Erişim tarihi: 12.01.2023)
- [13] Available:<https://news.mit.edu/2020/rewriting-rules-machine-generated-art-0818> (Erişim tarihi: 13.01.2023)
- [14] Liu, G., Reda, F. A., Shih, K. J., Wang, T. C., Tao, A., & Catanzaro, B. (2018). Image inpainting for irregular holes using partial convolutions. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 85-100).
- [15] Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4681-4690).
- [16] 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).
- [17] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [18] Pan, Z., Yu, W., Yi, X., Khan, A., Yuan, F., & Zheng, Y. (2019). Recent progress on generative adversarial networks (GANs): A survey. *IEEE Access*, 7, 36322-36333.
- [19] Cai, Y., Wang, X., Yu, Z., Li, F., Xu, P., Li, Y., & Li, L. (2019). Dualatt-GAN: Text to image synthesis with dual attentional generative adversarial network. *IEEE Access*, 7, 183706-183716.
- [20] Karras, T., Laine, S., & Aila, T. (2019). A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 4401-4410).
- [21] Figueira, A., & Vaz, B. (2022). Survey on synthetic data generation, evaluation methods and GANs. *Mathematics*, 10(15), 2733.
- [22] Wang, Z., She, Q., & Ward, T. E. (2021). Generative adversarial networks in computer vision: A survey and taxonomy. *ACM Computing Surveys (CSUR)*, 54(2), 1-38.
- [23] Saxena, D., & Cao, J. (2021). Generative adversarial networks (GANs) challenges, solutions, and future directions. *ACM Computing Surveys (CSUR)*, 54(3), 1-42.
- [24] Zhao, J., Mathieu, M., & LeCun, Y. (2016). Energy-based generative adversarial network. *arXiv preprint arXiv:1609.03126*.
- [25] Arjovsky, M., Chintala, S., & Bottou, L. (2017, July). Wasserstein generative adversarial networks. In *International conference on machine learning* (pp. 214-223). PMLR.
- [26] Park, S. W., & Kwon, J. (2019). Sphere generative adversarial network based on geometric moment matching. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4292-4301).
- [27] Jolicoeur-Martineau, A. (2018). The relativistic discriminator: a key element missing from standard GAN. *arXiv preprint arXiv:1807.00734*.
- [28] Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. C. (2017). Improved training of wasserstein gans. *Advances in neural information processing systems*, 30.
- [29] Miyato, T., Kataoka, T., Koyama, M., & Yoshida, Y. (2018). Spectral normalization for generative adversarial networks. *arXiv preprint arXiv:1802.05957*.
- [30] Wei, X., Gong, B., Liu, Z., Lu, W., & Wang, L. (2018). Improving the improved training of wasserstein gans: A consistency term and its dual effect. *arXiv preprint arXiv:1803.01541*.
- [31] Chen, T., Zhai, X., Ritter, M., Lucic, M., & Houlsby, N. (2019). Self-supervised gans via auxiliary rotation loss. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 12154-12163).
- [32] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [33] Berthelot, D., Schumm, T., & Metz, L. (2017). Began: Boundary equilibrium generative adversarial networks. *arXiv preprint arXiv:1703.10717*.

- [34] Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). Progressive growing of gans for improved quality, stability, and variation. *arXiv preprint arXiv:1710.10196*.
- [35] Gong, X., Chang, S., Jiang, Y., & Wang, Z. (2019). Autogan: Neural architecture search for generative adversarial networks. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 3224-3234).
- [36] Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved techniques for training gans. *Advances in neural information processing systems*, 29.
- [37] Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). Gans trained by a two time-scale update rule converge to a local nash equilibrium. *Advances in neural information processing systems*, 30.
- [38] Yadav, D., & Salmani, S. (2019, May). Deepfake: A survey on facial forgery technique using generative adversarial network. In *2019 International conference on intelligent computing and control systems (ICCS)* (pp. 852-857). IEEE.
- [39] Shahriar, S., & Al Roken, N. (2022). How can generative adversarial networks impact computer generated art? Insights from poetry to melody conversion. *International Journal of Information Management Data Insights*, 2(1), 100066.
- [40] Aldausari, N., Sowmya, A., Marcus, N., & Mohammadi, G. (2022). Video generative adversarial networks: a review. *ACM Computing Surveys (CSUR)*, 55(2), 1-25.
- [41] Cheng, J., Yang, Y., Tang, X., Xiong, N., Zhang, Y., & Lei, F. (2020). Generative adversarial networks: a literature review. *KSII Transactions on Internet and Information Systems (TIIS)*, 14(12), 4625-4647.
- [42] Wu, Q., Zhu, B., Yong, B., Wei, Y., Jiang, X., Zhou, R., & Zhou, Q. (2021). ClothGAN: generation of fashionable Dunhuang clothes using generative adversarial networks. *Connection Science*, 33(2), 341-358.
- [43] Raff, E. (2022). *Inside deep learning: Math, algorithms, models*. Manning Publications.
- [44] Parmar, G., Zhang, R., & Zhu, J. Y. (2022). On aliased resizing and surprising subtleties in gan evaluation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11410-11420).
- [45] Bińkowski, M., Sutherland, D. J., Arbel, M., & Gretton, A. (2018). Demystifying mmd gans. *arXiv preprint arXiv:1801.01401*.
- [46] Gerstner, E. (2020). Face/off: "DeepFake" face swaps and privacy laws. *Def. Counsel J.*, 87, 1.
- [47] Li, Y., Chang, M. C., & Lyu, S. (2018). In ictu oculi: Exposing ai generated fake face videos by detecting eye blinking. *arXiv preprint arXiv:1806.02877*.
- [48] Kataoka, Y., Matsubara, T., & Uehara, K. (2016, June). Image generation using generative adversarial networks and attention mechanism. In *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)* (pp. 1-6). IEEE.
- [49] Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A., A. (2017). "Image-to-Image Translation with Conditional Adversarial Networks" *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 5967 - 5976), IEEE.
- [50] Zhu, J. Y., Zhang, R., Pathak, D., Darrell, T., Efros, A. A., Wang, O., & Shechtman, E. (2017). Toward multimodal image-to-image translation. *Advances in neural information processing systems*, 30.