

## GÖRSEL İLETİŞİM TASARIM EĞİTİMİNİN DEĞERLENDİRME SÜREÇLERİNDE ÜÇÜNCÜ GÖZ: BİR YAPAY ZEKÂ MODELİ

Doç. Murat Ertürk\*  
N. Erhan Üzümcü\*\*

**Özet:** Yapay zekâ hemen her alanda olduğu gibi tasarım alanındaki varlığını giderek artırmaktadır. Tasarım disiplininde ise tasarımcıların mesleki hayatında meydana getirdiği değişimler ile tasarım üretimini otomatikleştiren uygulamalar veya yazılımlarla adından söz ettirdiği görülmektedir. “Yapay zekâ bir tasarımı ürününü değerlendirebilir mi?” sorusundan hareketle, tasarım eğitiminde yapay zekânın potansiyeli üzerine fikir yürütmenin ve tartışmaya açmanın önemli olduğu düşünülmektedir.

Bu çalışmada, gözetimli öğrenme kullanılarak görsel iletişim tasarımı ve grafik tasarımı bölümü öğrencilerinin logo tasarımlarının yer aldığı sınıflandırılmış veri seti ile CoreML uzantılı bir yapay zekâ modeli hazırlanmıştır. Veri setinde bulunmayan, sınıflandırılmamış logo örneklerinin yer aldığı bir kontrol grubu oluşturularak model test edilmiş ve yapılan deney sonucunda ortaya çıkan çıktılar aktarılmıştır. Yapay zekânın tasarım ilkelerini öğrenerek estetik çıkarımlarda bulunma potansiyeli ve tasarım eğitimindeki ölçme-değerlendirme süreçlerinde alabileceği role ilişkin öneriler getirilmiştir.

**Anahtar Kelimeler:** Yapay Zekâ, Yapay Zekâ Modeli, Görsel İletişim Tasarımı, Görsel İletişim Tasarımı Eğitimi.

Geliş Tarihi: 08.05.2021

Kabul Tarihi: 21.10.2021

Makale Türü: Araştırma Makalesi

\*Sakarya Üniversitesi Sanat, Tasarım ve Mimarlık Fakültesi Görsel İletişim Tasarımı Bölümü, merturk@sakarya.edu.tr, ORCID No: 0000-0001-9761-5906

\*\* TEYTAG: Elektronik Yayıncılık Tasarım Araştırma Grubu, teytag@gmail.com, ORCID No: 0000-0001-9670-8289

## THIRD EYE IN EVALUATION PROCESSES OF VISUAL COMMUNICATION DESIGN EDUCATION: AN ARTIFICIAL INTELLIGENCE MODEL

Assoc. Prof. Murat Ertürk\*  
N. Erhan Üzümcü\*\*

**Abstract:** Artificial intelligence (AI) increases its presence in the field of design, as in almost every area. AI in the design discipline is seen by the changes the designers have brought about in their professional life with the application or software that automate the design process. It is essential to think about the potential of AI in design education and open it up for discussion, based on the question “Can AI evaluate a design product?” In this study, an artificial intelligence model with CoreML framework was created using supervised learning with a classified data set containing logotypes designed by students of the visual communication design and graphic design department. The model was tested by creating a control group with unclassified logotypes that did not exist in the data set, and explained the result of the experiment. The potential of AI to make aesthetic inferences by learning the design principles and their role in the assessment and evaluation processes in design education is mentioned.

**Keywords:** Artificial Intelligence, Artificial Intelligence Model, Visual Communication Design, Visual Communication Design Education.

Received Date: 08.05.2021

Accepted Date: 21.10.2021

Article Types: Research Article

\* Sakarya University, Faculty of Art, Design and Architecture, Department of Visual Communication Design, merturk@sakarya.edu.tr, ORCID No: 0000-0001-9761-5906

\*\* TEYTAG: Electronic Publishing Design Research Group, teytag@gmail.com, ORCID No: 0000-0001-9670-8289

## 1. GİRİŞ

Günlük hayatımızda adını sıkça duymaya başladığımız yapay zekâ ve ona bağlı olarak makine öğrenimi; mühendislik, sağlık, sosyal bilimler gibi birçok alanda kendine yer bulmaktadır. Eğitim de bu alanlardan biridir. Eğitim, dijital dönüşüm yaşayan alanlardan biri olup yapay zekâ ve onun türevi teknolojik olanaklardan yararlanmaya başlamıştır. Mevcut teknolojilerin ve yapay zekâ uygulamalarının yaygın kullanımı, şu anda ne yaptığımızı ve nereye gittiğimizi yanıtlamak için yapay zekânın eğitimde nasıl kullanıldığını yeniden gözden geçirmemizi gerektirmektedir (Bozkurt vd., 2021). Eğitimde yapay zekâdan çeşitli yöntemler ile yararlanıldığı görülürken tasarım da bu konu daha çok yapay zekânın büründüğü tasarımcı rolü ve üretim süreçlerine nüfuz etme becerisi üzerinden tartışılmaktadır. Bir tasarımcıya ihtiyaç duymadan kendini tasarlayan ağ sayfaları söylemiyle ortaya çıkan ve daha sonra beklenen etkiyi yapamayan *The Grid*<sup>1</sup>; firma adı ve birkaç anahtar sözcük ile logo tasarlayan *Brandmark*<sup>2</sup> benzeri uygulamalar, yapay zekânın tasarımcının yerini alma potansiyeli üzerinden yürütülen tartışmalara yol açar. Yayımlandığı yıl tüm dünyada 7,5 milyon indirme sayısına ulaşan, yapay zekâ ve derin öğrenme kullanarak fotoğrafları sanatsal birer tablolara dönüştüren Prisma (http-1), cep telefonu ile çekilen görüntüyü makinenin görmesini sağlayarak ona en uygun efekti otomatik olarak uygular. Bir diğer örnek, 2017 yılında Google'ın tanıttığı, çizilen eskizleri tahmin ederek onları otomatik olarak tamamlayan *AutoDraw*<sup>3</sup> uygulamasıdır (http-2). Makine öğrenimi sayesinde ne kadar çok kullanıcı çizim yaparsa, yapay zekâ kullanıcıların çizimini öğrenerek yeni tasarımları tahmin etme oranı o kadar artar. Görsel iletişim tasarımcılarının yazılımlarını sıkça kullandığı

Adobe ise yapay zekâ alanına *Adobe Sensei* ile giriş yapar (http-3). Adobe Sensei, yapay zekânın alt alanı olan makine öğrenimi ile görüntüyü okuyarak tasarımcının yapmak istediği eylemi öngören, onu kolaylaştıran bir hizmet sunar. Aslında bu örneklerde yapay zekâ tasarımcı rolüne bürünmez, tasarımcının işini kolaylaştıran hatta ona zaman kazandıran birer yardımcıdır.

Tasarımda ve tasarım eğitiminde yapay zekâdan *yardımcı* rolünün dışında, farklı konularda da yararlanılabilir. Her tasarım eğitiminde olduğu gibi görsel iletişim tasarımı eğitimi de ağırlıklı olarak uygulama dersleri üzerinden yürütülür. Derslerde iletişim problemlerine çözümler üretmek amacıyla öğrencilere uygulamalar yaptırılır ve değerlendirme süreçleri, dersin öğretim elemanı veya elemanlarının oluşturduğu jürinin katılımıyla gerçekleşen, —özellikle YKS ile öğrenci alan bölümlerdeki kontenjanlar dikkate alındığında— uzun süre alan, meşakkatli ve kişisel beğenilerin etkisinin egemen olduğu bir süreçtir. Değerlendirme her ne kadar projeye özgü ve nesnel ölçütler dikkate alınarak yapılmaya çalışılsa da değerlendiricinin eğitim durumu, öğretim deneyimi, estetik düzeyi, hatta güncel tasarım anlayışlarına hâkim olma gibi değişken ve nesnel olmayan unsurlar da ölçme-değerlendirmede etkili olabilmektedir.

Bu çalışmada, uygulama projelerinin ölçme-değerlendirme süreçlerine yardımcı olması ve daha homojen değerlendirme çıktıları elde edilmesi amacıyla görsel iletişim tasarımı ve grafik tasarımı bölümü öğrencilerinin uygulama derslerinde yaptıkları logo tasarımları veri seti olarak kullanılarak bir yapay zekâ modeli hazırlanmıştır. Bu model, belirli ortak özelliklerdeki sınıflandırılmış (etiketlenilmiş) veriden öğrendiğini, sınıflandırılmamış yeni veriye uygulayarak çıkarımlarda bulunur. Dolayısıyla bu çıkarımlar, biçimsel özellikler

<sup>1</sup><https://thegrid.io>

<sup>2</sup><https://brandmark.io>

<sup>3</sup>AutoDraw; Google'ın yazma, öğrenme, müzik temaları üzerine yoğunlaşan Yapay zekâ Deneyleri (AI Experiments) adını verdiği platformun ürünüdür. Daha fazlası için: <https://experiments.withgoogle.com/collection/ai>

üzerinden yapılan tahminler olacaktır. Kuşkusuz, logo veya herhangi bir görsel iletişim tasarımı ürününün değerlendirilmesinde sadece biçim ve estetikle ilgili niteliklere bakılmaz. Bu çalışmadaki amaç, yapay zekâ modeli ile nihai değerlendirme sonucuna ulaşmak değil, yapay zekânın değerlendirme süreçlerindeki alabileceği rolü ve potansiyeli araştırmaktır.

Yapılan incelemeler sonucunda, tasarım eğitiminde doğrudan uygulama çalışmalarını değerlendirmek amacıyla yapay zekâdan yararlanılmasına yönelik çalışmalarla karşılaşmamıştır. Eğitimde yapay zekânın kullanımına ilişkin akademik çalışmalara bakıldığında yapay zekânın, akıllı eğitim süreçleri oluşturmak amacıyla eğitim verilerini tahmin etmek, tanımlamak veya kullanmaya karar vermek için makine öğrenimi ve derin öğrenme gibi yaklaşımların kapsayan genel bir teknik olarak anlaşıldığı görülmektedir (Bozkurt vd., 2021). Berlin Teknik Üniversitesinde geliştirilen ve öğrencilere öğrenim planlarını yapmada sorularını yanıtlayarak yardımcı olan (chatbots) Alex (<http-4>), Georgia Teknoloji Üniversitesinden Prof. Dr. Ashok Goel'in 2016 yılında başlattığı ve öğrencilerin sorularını yanıtlamak için kullanılan öğretim asistanı Jill Watson gibi (<http-5>) eğitim sürecinde yardımcı veya destekçi unsur olarak kullanıldığına ilişkin çeşitli örnekler de bulunmaktadır.

## 2. MAKİNE ÖĞRENİMİ VE ÖĞRENME MODELLERİ

Yapay zekânın alt alanı olarak “makine öğrenimi, verilerden bilgi çıkarmakla ilgilidir” (Müller ve Guido, 2017, s. 1) ve öğrenme süreçlerinin çoklu sonuçlarının incelenmesi ve bunların bilgisayar modellemesi makine öğreniminin konusunu oluşturur (Michalski vd., 1983, s. 3). Çok sayıda verinin işlenmesi, analizinin yapılması zaman ve yoğun işgücü gerektirdiğinden, makine öğrenimi eldeki verilerden belirli bir problemi çözmeye yönelik anlamlı bilgiler elde edebilmek

için algoritmaları kullanır. Makine öğrenimi algoritmaları, temelde gözetimli öğrenme (supervised learning) ve gözetimsiz öğrenme (unsupervised learning) olarak iki gruba ayrılır. Gözetimli öğrenme, girdi ve çıktı örneklerinin bulunduğu, daha önceden tanımlanmış veriden belirli bir sonuç tahmin etmek için kullanılan bir modeldir (Müller ve Guido, 2017, s. 25). Böylece gözetleyen/denetleyen tarafından önceden sınıflandırılmış etiket (label) bilgisi girilen veriler temel alınarak etiketi olmayan verinin tahmin edilmesi amaçlanır. Shalev-Shwartz ve Ben-David, iki öğrenme modeli için istenmeyen (spam) e-posta örneğini verir. Daha önceden istenmeyen olup olmadığı etiketlenmiş e-postaları içeren veri setinden deneyim kazanan model, daha önce hiç görmediği örneklerde eksik olan etiketi (istenen e-posta veya istenmeyen e-posta) tahmin etmeye çalışır (Shalev-Shwartz ve Ben-David, 2014, s. 4-5). “Gözetimli öğrenme, öğrenim modelini oluşturmak için genellikle insan çabası gerektirir, ancak daha sonra zahmetli veya meşakkatli bir görevi otomatikleştirir, genellikle de hızlandırır” (Müller ve Guido, 2017, s. 25).

Gözetimsiz öğrenme modelinde ise etiket bilgisi bulunmaz. Müller ve Guido, bu tür modelleri veriyi oluşturan bileşenleri ve parçaları bularak verinin yeni temsilini oluşturan algoritmalar olarak açıklar (Müller ve Guido, 2017, s. 131). Böylece, veri seti içerisinde tekrar eden, kümelenen bileşenlerden anlamlı bir çıkarıma, yani sınıflandırmalı etikete ulaşmak hedeflenir.

## 3. COREML UZANTILI YAPAY ZEKÂ MODELİNİN HAZIRLANMASI

Yapay zekâ modeli hazırlanma sürecinde verilerin belirlenmesi birincil önem taşır. Bu çalışmada, Sakarya Üniversitesi STMF Görsel İletişim Tasarımı ile Çankırı Karatekin Üniversitesi STMF Grafik Tasarımı Bölümünden, ikinci ve üçüncü sınıfta okuyan, toplam 135 öğrencinin uygulama derslerinde kendileri veya çeşitli

firmalar için yaptıkları, 135 logo tasarımı veri seti olarak kullanılmıştır. Öğrencilerin çalışmalarından oluşan görsel verilerle yapay zekâ modeli oluşturmadaki amaç, makine öğrenimi çıktılarının öğrencilerin düzeyi ile aynı seviyede kalmasını sağlamaktır. Model üretimi öncesinde veri setindeki logoların kodlamayla döndürülmesi, eğme/bükme gibi farklı algoritmalarından geçirip bir logodan birçok sürüm üreterek veri setindeki adedi çoğaltma uygulamaları (augmentation) yapılmamış, veri setinin özgünlüğü korunmuştur.

Logolar; 30x30 cm ölçü içerisinde, paspartulu, uzun kenarı 15 cm olacak şekilde RGB renk uzayına sahip JPG biçiminde dosyalar olarak hazırlanmıştır. Her bir renkli JPG için asgari %60 sıkıştırma uygulanmıştır. Görsel verinin yanlışlık göstermemesi dikkate alınarak logo çalışmaları farklı sektörlere ait öğrenci tasarımlarından seçilmiştir.

### 3.1. Sınıflandırmanın (Etiketlemenin) Yapılması

Çalışmada gözetimli öğrenme yapay zekâ modeli kullanılacağından logoların değerlendirmesi, ikili (Data 4) ve onlu (Data 3) sınıflandırması makalenin yazarı olan bir öğretim üyesi tarafından yapılmıştır. Veri setinde bulunan 135 logoya; *özgünlük, kompozisyon, oran/orantı ve soyutlama becerisi* ölçütleri dikkate alınarak puan verilmiştir. Sınıflandırmada iki yöntem kullanılarak yapay zekâ modeli üretilmiş, iki model arasındaki çıktılar karşılaştırma yoluna gidilmiştir.

Data 4 verilerinden oluşturulan birinci sınıflandırma yönteminde 135 logo, 0–50 ve 51–100 olarak puanlanmış/etiketlenmiştir. Dolayısıyla model çıktısında, 0–50 ve 51–100 olasılık yüzdeleri görülecektir. Böylece değerlendirilecek logoların 50'nin altında ve 50'nin üstünde olup olmadığı, temelde iyi veya kötü değerlendirilmesinin yapılması


amaçlanmıştır.

Data 3 verilerinden oluşturan ikinci sınıflandırma yönteminde ise 135 logo; 0–10, 11–20, 21–30, 31–40, 41–50, 51–60, 61–70, 71–80, 81–90 ve 91–100 olarak puanlanarak sınıflandırılmış/etiketlenmiştir. İkinci sınıflandırma ile yapay zekâ modelinden on adet olasılık yüzdesi elde edilecektir. İki farklı yapay zekâ modelinin üretilmesi için veriler sınıflandırılmış olup çıktılardan elde edilecek olasılık yüzdeleri ile model davranışını anlamak, kavramak amacıyla öncelikle ön analiz çalışmasına geçilmiştir.

### 3.2. Ön Analiz

Veri setindeki görsellere ilişkin edinilecek her türlü bilgi, modelin düşünme biçimini, tercihlerini anlamak ve modelin verdiği nihai çıktıyı doğru yorumlamak adına önemlidir. Bu modelde, veri setini analiz ederek anlamlandırabilmek için veriye yönelik bazı sorular sorulmuş ve alınan yanıtlar tablolar ile verilmiştir.

Çalışmaya katılan logo tasarımları; metin içerip içermediği, yazı/şekil ağırlığı, amblem ile yazının oran ilişkisi, geometrik biçimi, renk sayısı, ağırlıklı rengi olmak üzere altı parametre üzerinden incelenmiştir (bkz. Şekil 1). Yapay zekâ modelini oluşturacak görsel verinin %95'i metin içermektedir. Tasarımların %87'sinde amblem, %13'ünde tipografi ön plandadır. Amblem ve yazının oransal ilişkisine bakıldığında, azami değerdeki 28 tasarım 4/1 oranında yazı yüksekliğine sahiptir. Tasarımların %82'si dikdörtgen, %18'i kare, %1'i ise daire biçimindedir. Her bir tasarımın içerdiği renk sayısı dağılımına bakıldığında 41 adedi bir renk, 59 adedi iki renk içermekte, görsel veride iki renkli logo tasarımlarının ağırlıkta olduğu görülmektedir. Tasarımların ağırlıklı içerdiği renk dağılımına bakıldığında %24'ü siyah, %20'si kırmızı, %14'ü yeşil olup en az tercih edilen renk %3 ile gridir.



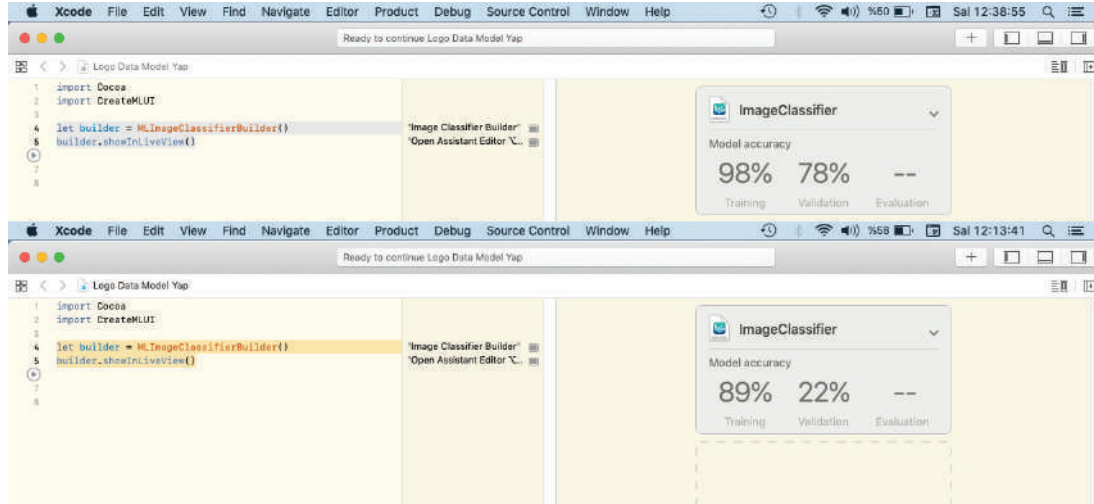
Şekil 1. Ön analiz sonuçları.

### 3.3. Yapay Zekâ Modelini Üretmek: CoreML

Çalışmada Apple tarafından sunulan makine öğrenme kütüphanesi CoreML kullanılmıştır. CoreML, makine öğrenimi algoritmaları kullanarak veriye dayalı tahminler yapan eğitilebilir modellerin üretilebildiği bir teknolojidir (http-6). 2.5 GHz Intel Core i5 işlemciye sahip MacBook Pro bilgisayarda ve Apple ürünü Xcode programında Swift dili ile iki farklı sınıflandırmaya sahip klasörler kullanılarak Şekil 2’de gösterildiği gibi CoreML kütüphanesi kullanılarak iki model üretilmiştir. Bu kütüphane verilerin %20’sini test (validation) amaçlı ayırıp

diğer %80’lik kısmını modelin eğitimi için kullanmaktadır. Eğitim aşamasında ise verilere 10 tekrar (iteration) değeri verilerek modelin eğitilmesi sağlanmıştır. Yapay zekâ modelinden iki çıktının istendiği birinci sınıflandırma yönteminde test değeri %78 olup on çıktının istendiği ikinci sınıflandırmadaki test değeri %22’dir.

Sınıflandırma çıktısının artması ile oluşabilecek veri kaybı (log loss) dikkate alındığından iki farklı sınıflandırma modeli üretilmiş ve kontrol grubu test aşamasında karşılaştırmaları yapılmıştır.



Şekil 2. Yapay zekâ modeli ve sınıflandırma değerleri.

### 3.4. Kontrol Grubunun Oluşturulması ve Test Edilmesi

Üretilen CoreML modelini test etmek için bir kontrol grubu oluşturulmuştur. Kontrol grubu, 10 logo ve 3 işaretçi (marker) olmak üzere 13 logo içermektedir. İşaretçiler sadece siyah çizgiden oluşan kare, daire ve dikdörtgenden oluşturulmuş primitif öğelerdir. Modelin, logolar dışındaki geometrik biçimlere vereceği çıktıların neler

olabileceğinin, belirli bir biçime yatkın olup olmadığının gözlenmesi amaçlanmıştır. Modelin bu biçimlere verdiği yüzde (%) çıktıları, kontrol grubu tablosunda ilk üç sırada gösterilmiştir (bkz. Şekil 3).

Şekil 3’te görüleceği üzere, Data 3 ve Data 4 renkli kontrol grubu yapay zekâ tarafından değerlendirildiğinde, 10 logonun tamamında 51 puan ve üzerinde çıktı yüzdeleri elde edilmiştir.

Onlu Sınıflandırmalı Data 3 ile Kontrol Grubu Karşılaştırması Renkli Logolar										İkili Sınıflandırmalı Data 4 ile Kontrol Grubu Karşılaştırma Renkli Logolar				İkili Sınıflandırmalı Data 4 ile Kontrol Grubu Karşılaştırma Siyah-Beyaz Logolar			
No	Logo Adet	13	21	11	12	14	19	13	16	16	10	Logo Adet	66	69	Logo Adet	66	69
	Sınıflama	0-10	11-20	21-30	31-40	41-50	51-60	61-70	71-80	81-90	91-100	Sınıflama	0-50	51-100	Sınıflama	0-50	51-100
		1			99								99	1		99	1
		55					5		9	26			9	91		11	89
		32			63		3			1			93	7		94	6
1		11							44	23	9		4	96		15	85
2		0					0		99		1		2	98		5	95
3		0							100	0	0		1	99		1	99
4		15						13	25	28			31	69		13	87
5		10					10		37	23			29	71			
6		25					12	37	14				11	89		7	93
7		0					100		0	0			17	83		25	75
8		2	2				89			7			14	86			
9		19					18	20			12		31	69		39	61
10		3					75	2		19			1	99		7	93

Şekil 3. Kontrol grubu.

Kontrol grubundaki 10 logonun yapay zekâ modelindeki veri setinde kullanılan öğrenci logolarından daha nitelikli tasarımlara sahip olduğu düşünüldüğünde, öğrenme sonucunda modelin nitelik ayrımı yapabildiği ve verdiği sonuçlarda kararlı olduğu çıkarımına varılabilir.

Data 3 Kontrol Grubu'nda en yüksek başarı puanı olan 91-100 puan sınıfına bakıldığında, kontrol grubundaki sadece dört logonun bu aralıkta yüzde çıktısı aldığı görülmektedir. Öğretim elemanı tarafından sınıflandırılan veri setinde, benzer olarak yalnız 10 adet logonun 91-100 puanı aldığı ve sayıca en az logo içeren puanın da 91-100 etiketinde olduğu bilinmektedir. Böylece yapay zekâ modelinin öğretim elemanının değerlendirme yaklaşımını kavradığı ve çok farklı bir davranış göstermediği anlaşılmaktadır. Bu açıdan, öğretim elemanı puanlama değerlendirmesi ile yapay zekâ değerlendirmesi

arasında bir çelişki ortaya çıkmamıştır.

İşaretçi logoların değerlerine bakıldığında model, Data 3 grubunda kare ve dikdörtgen gibi sert, kararlı olarak değerlendirilebilecek öğelerde 51 puanın altında olduğuna dair kararlı bir davranış göstermektedir. Böylece modelin, logo gibi özellikli biçimlere sahip olan veri ile daha primitif yapıya sahip veriyi kolaylıkla ayırt edebildiği anlaşılmaktadır. Veri setindeki logoların %82'sinin dikdörtgen biçiminde olduğu dikkate alınır (bkz. Şekil 1), dikdörtgen biçimine birebir uyan kontrol grubundaki 1, 2 ve 3 numaralı logolara 71-80 puan aralığında en yüksek değerleri vermesi dikkate değerdir. Daire biçimindeki işaretçide ise 51 puanın üzerinde toplam 40, 51 puanın altında ise 55 vererek kararsız ancak düşüğe daha yakın olduğunu göstermektedir. Model, veri setinde %1 daire biçimine sahip logo olmasına karşın, kontrol



grubundaki daire logolara 51 ve üzerinde puan vermiştir. Böylece modelin yalnız biçimi dikkate almadığı, biçim dışındaki grafik unsurlara karşı da duyarlılık gösterdiği anlaşılmaktadır.

Kontrol grubunda iki logonun etrafındaki beyaz kenar boşlukları silinmiş ve tekrar değerlendirilmeye alınmıştır. Model, beyaz kenar boşluğu olan logolara 51 puan üzerinde çıktı verirken, olmayan logoları ise daha düşük olarak değerlendirmiştir. Böylelikle beyaz kenar boşluğu olan logoların daha iyi olduğu yönünde kararlı davranış gösterdiğinden, modelin, veri setinin genelinde ortak olan görsel genelgeçerleri dikkate aldığı söylenebilir.

Veri seti içerisindeki logonun %13'ü tipografi içermektedir (bkz. Şekil 1). Modelin tipografisi karşı olan duyarlılığını ölçmek için kontrol grubundaki 10 numaralı logonun içerisindeki yazı silinerek tekrar çıktı alınmıştır. Modelin, 7 numaralı logoya 51-60 aralığında %100 vererek yükseğe daha yakın, yazısı silinmiş 8 numaralı logoya %89 vererek düşüğe daha yakın puan verdiği anlaşılmaktadır. Veri setinde tipografi ağırlıklı logo sayısının az olmasına rağmen, veri setinde %95 oranında metin içeren logoların bulunması nedeniyle yapay zekâ modelinin ağırlıklı tipografik öğelere sahip olan logolara duyarlı olduğu gözlemlenmiştir.

Yapay zekâ ayrı bir katmanda, görsellerin RGB verilerini işleyen bir algoritmaya sahiptir. Bu özelliğini ölçmek amacıyla, Şekil 3'te sağdaki tabloda, kontrol grubundaki işaretçi logolar dahil her bir renkli logo siyah-beyaz değerlere çevrilmiş ve tekrar modelin değerlendirmesine sokulmuştur. Elde edilen çıktılarına göre, siyah-beyaz logolar ortalama %6, azami %18 çıktı değeri kaybetmiştir. Böylece modelin renkli logoların daha iyi olduğu yönünde karar verdiği anlaşılmaktadır. Ayrıca turuncu ve mavi renk içeren 4 numaralı logodaki mavi renk, turuncu ile değiştirilmiş ve 5 numaralı logo olarak tekrar test çıktısı alınmıştır. Tek renkli 5 numaralı logoya

kiyasla iki renge sahip olan 4 numaralı logo daha yüksek sınıfta çıktı vermiştir. Veri setinde kırmızı ve siyah renk ağırlıklı logoların fazla olmasına karşın modelin yanlış bir davranış göstermediği, aksine rengi biçim ve kompozisyon ilişkisi üzerinden değerlendirdiği gözlemlenmiştir.

## SONUÇ

Yapay zekâ, izlediğimiz filmlerden yaptığımız alışverişe kadar günlük hayatımızın bir parçasıdır ve bu parçanın önümüzdeki yıllarda yoğunluğunu daha da artıracığı açıktır. Yapay zekânın egemen olduğu veya olacağı süreçleri göz ardı etmek, onu yok saymak, tasarımcının yerini veya işlerini elinden alacağı gibi kısır ve sınırlı bir pencereden bakmak yerine, ondan nasıl daha fazla yararlanabileceğimize odaklanılmalıdır. Yalnız tasarım süreçlerinde değil, bir iletişim problemine yönelik görsel çözümlerin tasarlanması, üretilmesi, organizasyonu ve analizini içeren bütüncül bir iş akışında yapay zekânın nasıl kullanılacağı üzerinde durulmalıdır. Prof. Andrew Ng, birçok uygulama için model ve algoritmanın temelde çözülmüş bir problem olduğunu, artık modeller belirli bir noktaya ulaştığına göre verilerin de çalışır hale getirilmesi gerektiğini belirtir. Daha iyi eğitim ve güvenilir değerlendirme için veri odaklı yaklaşımı benimsemeye ve daha çok sayıda, tutarlı veri kümeleri oluşturmaya odaklanılmalıdır (http-7). Tasarım bölümlerin nihai çıktısı yetiştirdikleri tasarımcı adayları, yani öğrenciler olduğundan daha nitelikli tasarımcı adayları yetiştirebilmek için ilgili bölümlerdeki eğitim süreçlerine veri gözüyle bakmak, veriyi daha etkin kullanabilmenin üzerine düşünmek ve bunun için yapay zekâdan yararlanmak bölümlerin eğitim anlayışlarına yeni soluklar getirebilir.

Tasarım eğitiminde yapay zekânın değerlendirme süreçlerine üçüncü bir göz olarak katılması, değerlendirme süreçlerini kısaltabilir, iş yükünü azaltabilir ve yapılan değerlendirmeyi daha

homojen bir noktaya taşıyabilir. Şöyle ki, hızlı çıktı elde etmek yapay zekânın en önemli özelliğidir. Zaman açısından bakıldığında, makine öğrenmesinin 35,72 saniyede görsel veriyi öğrenip model oluşturması ve hızlı sonuç vermesi çok önemli bir avantajdır. Sınıflandırılmış veri seti ile yüzlerce verinin değerlendirilmesi saniyeler içerisinde yapılabilir.

Zaman içerisinde sınıflandırılmış veri setinin aynı temada yeni öğeler eklenerek genişletilmesi, modelin daha doğru sonuçlar vermesini sağlayabilir. Böylelikle veri setinin düzenli ve sistemli bir şekilde sürdürülmesi, modelin kararlılığına doğrudan etki edecektir. Veri setinin yeterli sayıya erişebilmesi ve modelin kararlılığı için veri setini oluşturan öğelerin sayısının artması, bununla birlikte tekrar ön analiz sürecinin disiplinli bir şekilde yapılmasını gerektirmektedir. Veri seti artan her bir model ayrı ayrı kayıt edilmelidir. Her modelin çıktı performansı bir önceki modellerin çıktıklarına kıyasla düzenli bir şekilde test edilmelidir. Her bir test sonucu ayrı ayrı olarak değerlendirilmeli ve en uygun modelin hangisi olacağına zamanla karar verilmelidir.

Yapay zekâ modeli, son değerlendirme olarak kullanılabilir gibi ön değerlendirme olarak da kullanılabilir. Öğrenciler, çalışmalarını teslim etmeden önce modelden olası puanını görebilir ve çalışmasını yeniden gözden geçirebilir.

Değerlendirmenin tamamının yapay zekâ modeline bırakılması, modelin ilk zamanları için erken olabilir. Kuşkusuz bir tasarım ürününün değerlendirilmesinde biçimle ilgili ölçütlere ek olarak; iletişim işlevini yerine getirmesi, müşterinin ihtiyaçlarına karşılık vermesi, zamanın ruhuna uygunluk gibi birçok işlevle ilgili ölçütler de bulunmaktadır. Hazırlanan modelden bu ölçütleri değerlendirmesinin beklenmediği açıktır. Bu nedenle modelin ilk zamanlarında, yapay zekânın üçüncü göz olarak değerlendirilmeye katılması, yani değerlendirmede

küçük payın yapay zekâ modeline ayrılması, kalan büyük payın yine ilgili öğretim elemanı veya elemanlarının oluşturduğu jüri tarafından verilmesi daha doğru bir başlangıç olabilir.

Bu çalışmada üretilen örnek modelde yalnız bir değerlendiricinin ölçütleri ile sınıflandırma yapıldığından dolayı, modelin sonuçları da değerlendiricinin ölçütleriyle ve estetik anlayışıyla büyük oranda uyumlu olacaktır. Bu nedenle, önceden belirlenmiş ölçütler ışığında, aynı alanda birden fazla eğiticiden oluşan jürinin değerlendirmeyi yapması, modelin daha homojen çıktılar vermesini sağlayabilir. Hazırlanan modele eklenecek algoritmalar aracılığıyla, değerlendirmeye tabi olan öğrencilerin daha az puan almasına neden olan ölçütlerin belirlenmesi, böylelikle hangi ölçütlerin geliştirilmeye açık olduğu, daha önce yapılan tasarım çalışmaları ile benzerlik oranı, öğrencinin performans istatistikleri gibi çeşitli çıkarımlar edinilebilir ve model, öğrenciye ve eğitime geri bildirimler verebilir. Eğitici, model ve algoritmaların sağladığı çıkarımları derslerini geliştirmek, derslerinin öğrenme çıktılarının sağlanmasını yapmak ve kendi eğitim anlayışını yeniden gözden geçirmek için kullanabilir. “Öğrenme analitiği ve akıllı ders sistemleri aracılığıyla yapay zekâ tarafından oluşturulan verilerin kullanılmasının öğrenci performansını iyileştirdiği bildirilmektedir.” (Bozkurt vd., 2021) Böyle bir uygulama yapıldığında, kurum, yapay zekâyı eğitim anlayışının bir parçası olarak görmeli, algoritmanın daha yansız ve kararlı çıktılar vermesi için örnek modele uygulanacak algoritmaların ve veri setinin düzenli olarak izlenmesini sağlayacak ortam ve şartları hazırlamalıdır.

Model, değerlendirme sonucu yüzde olarak çıktı vermekte, bu yüzdeler incelenerek modelin kararlı veya kararsız kaldığı sonuçlar ortaya çıkmaktadır. Böylece modelin oluşturulmasında ve oluşturulan model ile yapılan değerlendirme

sonucunda, insanın rolü önem kazanmaktadır. Modelin oluşturulmasında veri setinin hazırlanması, ölçütlerin belirlenmesi ve test aşamaları sonrasında değerlendirmenin yapılmasında insanın rolü açıktır. Bu anlamda, değerlendirme süreci için bir yapay zekâ modelinin oluşturulması, insan faktörünü devreden çıkarmak değil, insan faktörüyle birlikte değerlendirmeyi hızlı ve daha homojen bir noktaya taşımaktır. Değerlendirme sonucunda çıktı yüzdelerine bakarak nihai kararı yine insan, yani eğitimci verecektir.

Bu çalışmada örneği sunulan bir yapay zekâ modeli, binlerce tasarımın katıldığı logo, afiş gibi ulusal veya uluslararası yarışmaların ön eleme süreçlerinin kısaltılmasında veya şartlara uymayan tasarımların elenmesinde kullanılabilir. Hazırlanan model ile değerlendirme aşamalarında tarafsız bir göz olarak yapay zekâ modellerine yer verilebileceğinin anlaşılması önemlidir.

Eğitimci (insan)-yapay zekâ etkileşiminin artırılarak eğitimcilerin diğer paydaşlarla disiplinlerarası çalışmalar yapması; yapay zekâ, makine öğrenimi ve derin öğrenme gibi konularda temel eğitim almaları yararlı olabilir. Böylelikle duygusal durumlarının, bilgi düzeylerinin, bireysel kişilik özelliklerinin ve becerilerinin analizine dayalı doğru öğrenci profilleri ve modelleri yaratarak öğrenme süreçlerini özelleştirme, özelleştirilebilir bir öğrenme ortamı yaratma olanaklarını ifade eden Eğitim 4.0 (Education 4.0) (Bozkurt vd., 2021) anlayışına hazır olunabilir.

Yapay zekâdan belirli bir temada veri sunabilen her etkinlikte yararlanılabilir. Bu açıdan, eğitim sürecinde elde edilen çıktılara veri gözüyle bakmak, eğitimcilerin kendilerini ve ilgili programların eğitim-öğretim anlayışlarını geliştirmek için veriden yararlanmak anlamlı olacaktır.

## KAYNAKLAR

- Bozkurt, A., Karadeniz, A., Baneres, D., Guerrero-Roldán, A. E., Rodríguez, M. E. (2021). *Artificial Intelligence and Reflections from Educational Landscape: A Review of AI Studies in Half a Century*. *Sustainability*, 13, 800. <https://doi.org/10.3390/su13020800>
- Müller, Andreas C. ve Guido, Sarah (2017). *Introduction to Machine Learning with Python*, USA: O'Reilly Media.
- Michalski, R. S., Carbonell J. G. ve Mitchell, T. M. (1983). *Machine Learning An Artificial Intelligence Approach*. USA: Morgan Kaufmann.
- Shalev-Shwartz, Shai ve Ben-David, Shai (2014). *Understanding Machine Learning: From Theory to Algorithms*. USA: Cambridge University Press.

## İnternet Kaynakları

- http-1. <https://www.digitaltrends.com/cool-tech/prisma-app-ai-painter/#selection-2233.0-2235.1>, (Erişim Tarihi: 11.2.2020).
- http-2. <https://experiments.withgoogle.com/autodraw>, (Erişim Tarihi: 11.2.2020).
- http-3. <https://techcrunch.com/2016/11/14/adobe-makes-big-bets-on-ai-and-the-public-cloud/>, (Erişim Tarihi: 11.2.2020).
- http-4. <https://alex.qu.tu-berlin.de>, (Erişim Tarihi: 19.10.2021).
- http-5. <https://ic.gatech.edu/news/631545/jill-watson-ai-pioneer-education-turns-4>, (Erişim Tarihi: 19.10.2021).
- http-6. <https://developer.apple.com/documentation/coreml>, (Erişim Tarihi: 5.5.2021).
- http-7. Kızrak, A. (2021). Veri Odaklı Yapay Zekâ, <https://ayyucekizrak.medium.com/veri-odakli-yapay-zeka-490469a10c7b> (Erişim Tarihi: 20.10.2021).

## Görsel Kaynaklar

- Şekil 1. Görsel tarafımızca oluşturulmuştur.
- Şekil 2. Görsel tarafımızca oluşturulmuştur.
- Şekil 3. Görsel tarafımızca oluşturulmuştur.