

**MİMARİ ÇİZİM ÖLÇÜTLERİNİN YAPAY ZEKAYLA
KONTROLÜ**

SESERVAN BARIN EKİN

**YÜKSEK LİSANS TEZİ
MİMARLIK ANABİLİM DALI**

**DANIŞMAN
DR. ÖĞR. ÜYESİ NURAY BENLİ YILDIZ**

DÜZCE, 2024

T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MİMARİ ÇİZİM ÖLÇÜTLERİNİN YAPAY ZEKAYLA
KONTROLÜ

Seservan BARIN EKİNTarafından hazırlanan tez çalışması aşağıdaki jüri tarafından
Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Mimarlık Anabilim Dalı'nda **YÜKSEK**
LİSANSTEZİolarak kabul edilmiştir.

Tez Danışmanı

Dr. Öğr. ÜyesiNuray BENLİ YILDIZ

Düzce Üniversitesi

Jüri Üyeleri

Dr. Öğr. Üyesi Nuray BENLİ YILDIZ

Düzce Üniversitesi

Prof. Dr. Hakan Arslan

Düzce Üniversitesi

Dr. Öğr. Üyesi Ahmet Berk ÜSTÜN

Bartın Üniversitesi

Tez Savunma Tarihi: 22/04/2024

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Tarih:22.04.2024

Seservan BARIN EKİN

TEŞEKKÜR

Tez çalışmamın tamamlanmasında emeği geçen değerli akademisyenlere, aileme ve sevdiklerime şükranlarımı sunarım.

Öncelikle, tez danışmanım Yrd Dr. Öğr. Üyesi Nuray BENLİ YILDIZ, Prof. Dr. Hakan ARSLAN ve Dr. Öğr. Üyesi Ahmet Berk ÜSTÜN'e sonsuz teşekkür ederim. Değerli öneri ve yönlendirmeleri sayesinde, bu çalışmanın her aşamasında daha derin bir anlayışa ulaşabildim. Bilgeliği ve rehberliği, benim için gerçek bir ilham kaynağı oldu.

Tez sürecindeki her zorluğa karşı yanımda olan ve beni motive ederek çalışmalarına devam etmemi sağlayan sevgili eşim Emrah EKİN'e teşekkür ederim. Sabrı, anlayışı ve destekleri, bu çalışmanın başarılı bir şekilde tamamlanmasında büyük bir etken oldu.

Desteğini hiçbir zaman esirgemeyen ve düşüncelerimde daha geniş bir perspektif kazanmamı sağlayan abim Yakup BARIN'a değerli katkılarından dolayı teşekkür ederim.

Son olarak, annem Rahima BARIN, babam İbrahim BARIN, kız kardeşlerim Sibel BARIN ÖZKAN ve Gülse BARIN'a teşekkür etmek isterim. Onların sevgisi ve moral desteği, bu uzun ve meşakkatli süreçte beni ayakta tuttu. Bu tez, onların öğrettikleri değerlere bir minnet ifadesidir.

Her birinize içten teşekkürlerimi sunar, bu çalışmanın ortaya çıkmasında katkısı olan herkesi saygıyla anarım.

Nisan 2024

Seservan BARIN EKİN

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ.....	vii
ÇİZELGE LİSTESİ.....	ix
KISALTMALAR.....	x
SİMGELER	xi
ÖZET	xiii
ABSTRACT	xiv
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	8
3. MİMARİ TASARIM.....	20
4. Yapay ZEKÂ	27
4.1. YAPAY ZEKÂ TARİHÇESİ	28
4.2. YAPAY ZEKÂ TEKNİKLERİ.....	30
4.2.1. Uzman Sistemler.....	30
4.2.2. Makine Öğrenmesi	32
4.2.3. Genetik Algoritma.....	33
5. YAPAY SİNİR AĞLARI	36
5.1. YAPAY SİNİR AĞLARI TARİHÇESİ	37
5.2. BİYOLOJİK SİNİR HÜCRE YAPISI.....	38
5.3. YAPAY SİNİR AĞ ELEMANLARI	40
5.4. YAPAY SİNİR AĞ SİSTEMİNİN YAPISI	41
5.5. YAPAY SİNİR AĞI MODELLERİ	42
5.5.1. Tek Katmanlı Algılayıcılar (Perceptrons):	43
5.5.2. Çok Katmanlı Algılayıcılar (Multilayer Perceptrons - MLP):	43
5.5.3. İleri Beslemeli Yapay Sinir Ağları (Feedforward Neural Networks):	44
5.5.4. Geri Beslemeli Yapay Sinir Ağları (Recurrent Neural Networks - RNN):	45
6. YÖNTEM	46
6.1. UYGULAMA VERİLERİNİN ELDE EDİLMESİ.....	47
7. BULGULAR VE TARTIŞMA	65
7.1. ÖN PROJE ÇİZİM STANDARTLARINA UYGUN OLMA DURUMU	65
7.2. BAKIŞ YÖNÜNÜN ÖLÇÜTÜNÜN GEÇERLİ VEYA GEÇERSİZ OLMA DURUMU.....	70
7.3. ÖLÇÜLENDİRME ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU	72
7.4. MAHAL İSMİ VE M ² ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU	75
7.5. MODÜL VE İNŞAI AKS ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU	78
7.6. TEFRİŞLER ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU.....	81
8. SONUÇLAR VE ÖNERİLER.....	86

9. KAYNAKLAR	92
10. EKLER	100
10.1. EK 1: PROGRAM BAŞLAMA KODU	100
10.2. EK 2: KÜTÜPHANE EKLEME KODU	101
10.3. EK 3: ARAYÜZ KODU	102
10.4. EK 4: ANALİZ KODU	104
ÖZGEÇMİŞ	106



ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1. Proje kapsamındaki gerekliliklerin ilişkisi	2
Şekil 3.1. Tasarım süreci akış grafiği	21
Şekil 3.2. Ön proje aşamasındaki proje planlarındaki ölçütlerin fotoğrafı	24
Şekil 3.3. Ölçütlerin planda gösterimi	25
Şekil 4.1. Uzman Sistemin Elemanları ve Bilgi Akış Diyagramı (Şahin, 2007)	31
Şekil 4.2. Genetik Algoritma Elemanlarının Çalışma Diyagramı (Şahin, 2007)	34
Şekil 5.1. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, 2013)	39
Şekil 5.2. Yapay Sinir Ağ Yapısı (Şahin,2005)	40
Şekil 5.3. Yapay sinir ağı yapısı (Yurtoğlu,2005)	42
Şekil 5.4. Tek Katmanlı Algılayıcılar Modeli (Öztemel, 2006).	43
Şekil 5.5. Çok Katmanlı Algılayıcılar Modeli (Elmas, 2003).	44
Şekil 5.6. İleri Beslemeli Yapay Sinir Ağ Modeli (Ballı, 2014).	45
Şekil 5.7. Geri Beslemeli Yapay Sinir Ağ Modeli (Kurnaz 2014)..	45
Şekil 6.1. Konut planı görüntüleri	48
Şekil 6.2. Geçerli plan görselleri.	50
Şekil 6.3. Geçersiz plan görselleri.	51
Şekil 6.4. Eğitim verisinin yüklenmesi.	52
Şekil 6.5. Microsoft RestNet-50 ağ mimarisi(He, Zhang et al. 2016).	53
Şekil 6.6. Uygulama yönteminin akış diyagramı.	55
Şekil 6.7. Visual Studio 2022 Community Kurulum.	57
Şekil 6.8.NET Framework Modülü.	57
Şekil 6.9.Microsoft.ML Kütüphanesi Seçimi.	57
Şekil 6.10. Visual Studio Başlangıç Penceresi.	58
Şekil 6.11. Çözüm Gezgini “mbconfig”.	59
Şekil 6.12. Senaryo Seçim Ekranı.	60
Şekil 6.13. Görüntü Sınıflandırma Senaryosu	61
Şekil 6.14. Eğitim Ortamının Seçilmesi	61
Şekil 6.15. Veri Girişi.	62
Şekil 6.16. Eğitim Sonucu	63
Şekil 6.17. Test Verisi Analizinin Arayüzü	63
Şekil 6.18. Test Verisinin Analizi.	63
Şekil 6.19. Test Verisinin Analizi	64
Şekil 7.1. Ön Proje Çizim Standartlarına Uygun Olan Proje	66
Şekil 7.2. Ön Proje Çizim Standartlarına Uygun Olan Proje	67
Şekil 7.3. Ön Proje Çizim Standartlarına Uygun Olan Proje	67
Şekil 7.4. Ön Proje Çizim Standartlarına Uygun Olan Proje	68
Şekil 7.5. Ön Proje Çizim Standartlarına Uygun Olan Proje	69
Şekil 7.6. Ön Proje Çizim Standartlarına Uygun Olan Proje	69
Şekil 7.7. Ön Proje Çizim Standartlarına Uygun Olan Proje	70
Şekil 7.8. Bakış Yönü Ölçütüne Sahip Olmayan Proje	71
Şekil 7.9. Bakış Yönü Ölçütüne Sahip Olmayan Proje	72
Şekil 7.10. Ölçülendirme Ölçününün Çizilmemesinin Çıktısı	73
Şekil 7.11. Ölçülendirme Ölçününün Çizilmemesinin Çıktısı	74
Şekil 7.12. Ölçülendirme Ölçününün Çizilmemesinin Çıktısı	74

Şekil 7.13. Ölçülendirme Ölçününün Çizilmemesinin Çıktısı	75
Şekil 7.14. Mahal İsmi ve m ² Ölçününün Çizilmemesinin Çıktısı	76
Şekil 7.15. Mahal İsmi ve m ² Ölçününün Çizilmemesinin Çıktısı	76
Şekil 7.16. Mahal İsmi ve m ² Ölçününün Çizilmemesinin Çıktısı	77
Şekil 7.17. Mahal İsmi ve m ² Ölçününün Çizilmemesinin Çıktısı	78
Şekil 7.18. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı.....	79
Şekil 7.19. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı.....	80
Şekil 7.20. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı.....	80
Şekil 7.21. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı.....	81
Şekil 7.22. Tefrişler Ölçününün Çizilmemesinin Çıktısı.....	82
Şekil 7.23. Tefrişler Ölçününün Çizilmemesinin Çıktısı.....	83
Şekil 7.24. Tefrişler Ölçününün Çizilmemesinin Çıktısı.....	83
Şekil 7.25. Tefrişler Ölçününün Çizilmemesinin Çıktısı.....	84
Şekil 7.26. Tefrişler Ölçününün Çizilmemesinin Çıktısı.....	85



ÇİZELGE LİSTESİ

Sayfa No

Çizelge 2.1. Mimaride Yapay Zekanın Kullanılması İlişkin Literatür Taraması	15
Çizelge 6.1. Veri seti ve İçerik Bilgisi.....	52
Çizelge 8.1. Ölçütlerin olup/olmaması göre geçerlilik/geçersizlik yüzdesi.	87



KISALTMALAR

DNN	Derin Sinir Ağı
YZ	Yapay Zekâ
AI	Artificial Intelligence
CAD	Computer Aided Design
CNN	Evrişimli Sinir Ağları
GANs	Generative Adversarial Networks
MLP	Multi Layer Perceptron
NLP	Natural Language Processing
TMMOB	Türk Mühendis ve Mimar Odaları Birliği
PDF	Portable Document Format
PNG	Portable Network Graphic
DWG	DraWinG
RNN	Recurrent Neural Network
JPEG	Joint Photographic Experts Group

SİMGELER

G	Girdi
A	Ağırlık
n	Toplam Girdi



ÖZET

MİMARİ ÇİZİM ÖLÇÜTLERİNİN YAPAY ZEKAYLA KONTROLÜ

Seservan BARIN EKİN

Düzce Üniversitesi
Lisansüstü Eğitim Enstitüsü, Mimarlık Anabilim Dalı
Yüksek Lisans Tezi
Danışman: Dr. Öğr. Üyesi Nuray BENLİ YILDIZ

Nisan 2024, 105 sayfa

Günümüzde, mimarlık ve yapay zekâ arasındaki ilişki büyük bir dönüşüm geçirmektedir. Yapay zekâ teknolojisi, mimarlık alanında tasarım, inşaat ve sürdürülebilirlik gibi birçok yönü etkilemektedir. Bu ilişki, yapay zekânın mimarlık alanında nasıl kullanıldığını ve bu kullanımın sektöre getirdiği avantajları ele almaktadır. Özellikle mimari konut planlarının tasarım aşamalarında, yapay zekâ ile olan ilişki giderek daha fazla önem kazanmıştır. Mimari tasarım, sadece estetik değil, aynı zamanda işlevsellik, enerji verimliliği ve sürdürülebilirlik gibi faktörleri içermektedir. Yapay zekâ, bu alanlarda önemli avantajlar sunmaktadır. Tasarım optimizasyonu, kişiselleştirme, hız ve verimlilik, enerji verimliliği, topluluk ve mekân planlaması, yapısal dayanıklılık, maliyet analizi ve veri analizi gibi konularda yapay zekâ kullanılabilir. Yapay zekâ, tasarım süreçlerini optimize etmek ve en verimli planları önermek konusunda büyük bir potansiyele sahiptir. Ayrıca, müşteri tercihlerine özel planlar sunabilirken, mimari çizim süreçlerini hızlandırarak ve enerji verimliliğini artırabilir. Yapay zekâ aynı zamanda yapısal dayanıklılık, malzeme seçimi ve inşaat maliyetleri gibi unsurlarda analizler yapabilir. Bu tez çalışması, mimari konut planı görüntülerinin ön proje çizim standartlarına uygunluğunu değerlendirmeyi amaçlamaktadır. Bu değerlendirme, Türk Mühendis ve Mimar Odaları Birliği'nin temel prensiplerinden kaynaklanan mimarlık çalışmalarında minimum gereksinimleri belirleyerek yapılmıştır. Çalışmada, Düzce Üniversitesi, Sanat, Tasarım ve Mimarlık Fakültesi – Mimarlık Bölümü öğrencilerinin proje çizimlerinden elde edilen 171 eğitim ve 26 test verisi kullanılmıştır. Bu çalışma, DNN ve Resnet-50 modelleri kullanılarak geliştirilen yapay zekâ teknolojisi ile konut proje planlarının ön proje aşamasındaki çizim standartlarına uygunluğunu değerlendirmiştir. Mimari Proje Çizim ve Sunuş Standartları'ndan belirlenen ölçütlerin, bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi alanlarda çizim standartlarına uygunluğu analiz edilmiştir. Çalışmanın sonuçları, yapay zekânın genel olarak birçok ölçütte başarılı olduğunu göstermektedir. Ancak bakış yönü ölçütünde ise belirgin eksiklikler tespit edilmiştir. Bu eksiklikler, projenin geliştirme aşamasında yapay zekânın performansının dikkatlice incelenmesini gerektirmektedir. Çalışmanın amaçları arasında mimarlık eğitiminde yapay zeka araçlarının kullanımının önemi vurgulanmakta ve bu araçların öğrencilerin sektörel yeniliklere adapte olmalarına ve tasarım verimliliğini artırmalarına nasıl yardımcı olabileceği üzerinde durulmuştur. Belediyelerin yapay zeka destekli kontrol sistemlerini kullanarak denetim süreçlerini daha etkin ve objektif hale

getirme potansiyeli de ele alınmaktadır. Yapay zeka destekli kontrol sistemlerinin kullanımının avantajları üzerine bir akademik bakış sunmayı hedeflemektedir.

Anahtar Sözcükler: Mimari Tasarım, Çizim Standartları Kontrolü, Yapay Zekâ, Yapay Sinir Ağları.



ABSTRACT

CONTROL OF ARCHITECTURAL DRAWING CRITERIA WITH ARTIFICIAL INTELLIGENCE

Seservan BARIN EKİN

Düzce University

Graduate School, Department of Architecture

Master's Thesis

Supervisor: Dr. Öğr. Üy. Nuray BENLİ YILDIZ

April 2024, 105 pages

The relationship between architecture and artificial intelligence is undergoing a significant transformation today. Artificial intelligence technology is impacting many aspects of architecture, such as design, construction, and sustainability. This relationship explores how AI is used in architecture and the advantages it brings to the sector. Particularly in the design stages of architectural housing plans, the relationship with artificial intelligence is becoming increasingly important. Architectural design encompasses not just aesthetics but also functionality, energy efficiency, and sustainability factors. AI offers significant advantages in these areas. It can be used for design optimization, personalization, speed and efficiency, energy efficiency, community and spatial planning, structural resilience, cost analysis, and data analysis. AI has great potential to optimize design processes and suggest the most efficient plans. Additionally, it can offer personalized plans based on customer preferences, speed up architectural drawing processes, and enhance energy efficiency. Artificial intelligence can also analyze factors like structural resilience, material selection, and construction costs. This thesis aims to evaluate the compliance of architectural housing plan images with pre-project drawing standards. This evaluation is based on the minimum requirements for architectural work stemming from the basic principles of the Union of Chambers of Turkish Engineers and Architects. The study uses 171 training and 26 test data obtained from project drawings of students from the Department of Architecture at Düzce University, Faculty of Art, Design, and Architecture. This study evaluates the compliance of housing project plans with pre-project drawing standards using artificial intelligence technology developed with DNN and Resnet-50 models. Criteria from Architectural Project Drawing and Presentation Standards such as viewpoint, dimensioning, room name and m², module and construction axes, and furnishings are analyzed for compliance with drawing standards. The results of the study show that artificial intelligence is generally successful in many criteria. However, significant deficiencies were identified in the viewpoint criterion. These deficiencies require careful examination of AI performance during the project development stage. The study also emphasizes the importance of using AI tools in architectural education and how these tools can help students adapt to industry innovations and increase design efficiency. It also discusses the potential for municipalities to use AI-supported control systems to make inspection processes more effective and objective. The study aims to provide an academic perspective on the advantages of using AI-supported control systems.

Keywords: Architectural Design, Drawing Standards Control, Artificial Intelligence,

Artificial Neural Networks.



1. GİRİŞ

Mimari tasarım, insanın yaşam alanlarını şekillendiren ve onların deneyimlerini etkileyen temel unsurlardan biridir. Yüzyıllar boyunca, mimarlık sadece işlevselliğin ötesinde estetik, kültürel ve sosyal değerlerin bir ifadesi olarak kabul edilmiştir (Elogitech, 2020). Ancak, 21. yüzyılın getirdiği teknolojik gelişmeler, mimarlık ve tasarım süreçlerinde köklü değişikliklere yol açmıştır.

Yapay zekâ, insan benzeri görevleri yerine getirme, veri analizi yapma ve öngörülerde bulunma yeteneğiyle, mimarlık disiplindeki geleneksel süreçlere yeni bir boyut kazandırmaktadır. Bu teknoloji, mimarların büyük veri kümelerini analiz ederek daha bilgiye dayalı kararlar almasını, tasarım süreçlerini optimize etmesini ve hatta daha yaratıcı çözümler üretmesini sağlayarak, mimarlık pratiğini kökten değiştirebilecek bir potansiyele sahiptir(Li vd., 2018).

Yapay zekânın mimarlık alanındaki etkisi, tasarım sürecinin her aşamasında görülebilir. Tasarımcılar, yapay zekâ tabanlı araçlar kullanarak, karmaşık veri setlerini analiz edebilir, desenleri tanımlayabilir ve kullanıcı tercihlerini öngörebilirler. Ayrıca, yapay zekâ destekli tasarım sistemleri, tasarım sürecini daha verimli hale getirerek, zaman ve kaynak tasarrufu sağlayabilir(Quan, Park, Economou ve Lee, 2019).

Yapay zekânın mimari tasarım süreçlerine etkisi, tasarımın her aşamasında kendini gösterebilir. Başlangıçta, yapay zekâ, büyük veri kümelerini analiz ederek, bölgenin demografik yapısını, iklim koşullarını, kullanıcı tercihlerini ve benzeri faktörleri inceleyebilir. Bu analizler, tasarımcılara daha kapsamlı bir anlayış ve veri tabanı sağlayarak, tasarım kararlarını destekleyebilir(Wang, 2019).

Ayrıca, yapay zekâ destekli tasarım araçları, tasarımcıların tasarım alternatiflerini daha hızlı bir şekilde değerlendirmesine ve optimize etmesine yardımcı olabilir. Yapay zekâ, tasarımcılara, proje için en uygun malzemeleri seçme, enerji verimliliğini artırma ve maliyetleri azaltma gibi konularda da rehberlik edebilir.


Ancak, yapay zekânın mimari tasarım süreçlerine etkisi sadece teknik değil, aynı

zamanda kavramsal ve estetik boyutlarda da önemlidir. Yapay zekâ, tasarımcıların daha önce görülmemiş desenler ve formlar keşfetmelerine, yaratıcılıklarını teşvik etmelerine ve sınırları zorlamalarına olanak tanır(Canbeyli,2018).

Bu tez, mimari tasarım sürecinde yapay zekânın etkisi ve konut projelerinde ön proje çizim standartlarının uygunluğunun tespiti üzerine odaklanmaktadır. Bu odak, modern mimarlık pratiğinin ve geleceğin tasarım paradigmasının anlaşılmasında önemli bir adımı temsil etmektedir.

Günümüzde, yapay zekânın mimari tasarım sürecine entegrasyonu, tasarımcıların yaratıcılığını destekleyen ve karar alma süreçlerini optimize eden bir araç olarak kabul edilmektedir. Yapay zekâ, büyük veri analitiği, makine öğrenmesi ve nesne tanıma gibi alanlardaki ilerlemeler sayesinde, mimarların daha hızlı, daha verimli ve daha yenilikçi tasarımlar gerçekleştirmesine olanak tanımaktadır. Ancak, bu teknolojik ilerlemelerin mimari estetik ve insan-mekân etkileşimi gibi geleneksel değerlerle nasıl etkileşime girdiği, araştırma ve değerlendirme gerektiren önemli bir konudur.(Krizhevsky vd., 2018).

Diğer yandan, konut projelerinde kullanılan ön proje çizim standartları, mimari tasarımın temel bileşenlerinden biridir. Bu standartlar, mimarların tasarımlarını iletmek, müşterilerle iletişim kurmak ve inşaat sürecini yönetmek için kritik öneme sahiptir. Kamara ve ekibinin (2020) çalışmasında, bir inşaat projesi içindeki gerekliliklerin birbirleriyle olan ilişkileri aşağıdaki Şekil 1'de açıklanmıştır.



Şekil 1.1. Proje kapsamındaki gerekliliklerin ilişkisi(Kamara,2000)

Bu tez, mimari tasarım sürecinde yapay zekânın rolünü ve konut projelerinde kullanılan ön proje çizim standartlarının uygunluğunu inceleyerek, hem teorik hem de pratik açıdan bir katkı sağlamayı amaçlamaktadır. Bu çalışma, mimarlık ve yapay zekâ alanları arasındaki kesişim noktasında önemli bir boşluğu doldurmayı hedeflemekte ve gelecekteki mimari pratikler için değerli bir rehber oluşturmayı amaçlamaktadır.

Mimari proje çizim ve sunuş standartları, Türkiye'de yapı denetimi ve inşaat sektörünün gelişmesiyle sürekli olarak güncellenen kritik bir unsurdur. Bu standartlar, Türkiye İnşaat Mühendisleri Odası (TMMOB), Türk Mimarlar Odası (TMMOB), Çevre ve Şehircilik Bakanlığı ve diğer ilgili kurumlar tarafından belirlenir. Genellikle ulusal ve yerel yönetmeliklere uygun olarak hazırlanan bu standartlar, projelerin güvenliğini, çevresel uygunluğunu ve estetik kalitesini sağlamayı amaçlamaktadır.

Türkiye'de mimari projeler, Türkiye İnşaat Mühendisleri Odası ve Türk Mimarlar Odası gibi meslek örgütlerinin standartlarına ve Yapı Denetimi Kanunu'na uygun olarak hazırlanmalıdır. Mimari projeler, konut, ticaret, sanayi, eğitim, sağlık, kamu binaları gibi farklı proje türleri için ayrı ayrı standartlara uygun olarak hazırlanmalıdır.

Ön proje aşamasında hazırlanan mimari planların detaylarının ve standartlarının belirlenmemesi, inşaat projelerinde ciddi sorunlara yol açabilir. Bu aşamada eksik veya belirsiz bilgilerle başlamak, projenin ilerleyen aşamalarında bir dizi olumsuz etki yaratabilir. Detayların belirsiz veya eksik olması, proje paydaşları arasında farklı yorumlara ve beklentilere neden olabilir, bu da tasarım sürecini karmaşıklaştırır. Karar verme süreçleri zorlaşır ve yanlış kararlar alınabilir. Maliyet tahmini ve bütçe kontrolü, projenin başarılarından biridir ve eksik bilgi, maliyetleri artırabilir. Zaman, her inşaat projesinin önemli bir faktörüdür ve eksik bilgi, projenin zamanında tamamlanmasını zorlaştırabilir. Uyumsuzluklar ve sorunlar projenin karmaşıklığını artırabilir. Ruhsat ve izin sorunları ortaya çıkabilir, yasal uyumluluk sıkıntıları yaşanabilir. Çevresel ve sürdürülebilirlik hedeflerinin göz ardı edilmesi, projenin sonucunu ve çevresel etkileri olumsuz etkileyebilir. Sonuç olarak, müşteri memnuniyeti risk altına girebilir.

Bu noktada, yapay zekanın mimari projelerdeki rolü ve etkisi de göz önünde bulundurulmalıdır. Yapay zekânın derin öğrenme stili de, projelerde kullanılan bir analiz ve tahmin aracı olarak dikkate alınmaktadır. Derin öğrenme, büyük veri kümelerinden anlamlı desenler ve ilişkiler çıkarmak için kullanılır. Mimari projelerde,

derin öğrenme algoritmaları, geçmiş projelerden elde edilen verilere dayanarak gelecekteki tasarım eğilimlerini ve tercihleri tahmin etmek için kullanılabilir. Bu sayede, tasarımcılar, müşterilerin ihtiyaçlarını daha iyi anlayabilir ve tasarımlarını bu doğrultuda optimize edebilirler.

Sonuç olarak, bu tez, mimari tasarım sürecinin yenilikçi ve sürdürülebilir bir şekilde geliştirilmesi için önemli bir adımı temsil etmektedir. Yapay zekânın etkisi altında gelişen mimarlık pratiğinin, estetik, işlevsellik ve kullanıcı deneyimi açısından nasıl optimize edilebileceği konusunda derinlemesine bir anlayış sunmayı amaçlamaktadır. Detayların ve standartların belirlenmesi, projenin daha düzgün, verimli ve başarılı bir şekilde ilerlemesini sağlar. Yapay zekanın derin öğrenme stili gibi gelişmiş teknolojilerin de bu süreçte kullanılması, projelerin daha öngörülebilir ve verimli bir şekilde yönetilmesine yardımcı olabilir. Bu tez, mimarlık alanında yeni ufuklar açacak ve gelecekteki araştırmacılar için ilham kaynağı olabilmeyi amaçlamıştır.

- **Çalışmanın Amacı**

Ön proje aşaması, bir inşaat projesinin temelini oluşturan ve tasarımın şekillendirildiği kritik bir dönemdir. Bu aşamada, mimari planların doğru ve standartlara uygun olması, projenin başarısını etkileyen bir faktördür. Bu nedenle, bu çizimlerin detayları ve standartları eksiksiz ve doğru bir şekilde içermesi büyük önem taşır. Bu aşamada, çizimlerin içermesi gereken detaylar ve standartlar belirlenmeli ve ardından bu kriterlere uygunluğun kontrolü yapılmalıdır. Bu kontroller, çizimlerin ölçekleri, etiketler, semboller, boyutlar ve çevresel hedefler gibi bir dizi faktörü içerir. Ayrıca, müşteri veya proje sahibinin onayı ve yerel izin gereksinimlerine uygunluk da göz önünde bulundurulmalıdır. Bu kontrollerin sağlıklı bir şekilde yapılması, iletişim sorunlarını azaltır, maliyet artışlarını önler, zaman kaybını minimize eder ve projenin uyumluluğunu sağlar. Detayların ve standartların eksik veya belirsiz olması, projenin ilerleyen aşamalarında sorunlara yol açabilir.

Bu tez çalışmasında, Yapay zekâ, derin öğrenme ve yapay sinir ağ sistemleri kullanılarak mimari konut plan görüntüleri içerisinden ön proje çizim standartlarına uygun olup olmadığının tespit edilmesini amaçlamaktadır. Türk Mühendis ve Mimar Odaları Birliği (TMMOB) - Mimarlar Odası tarafından mimarın hizmetlerini eksiksiz ve kusursuz bir şekilde sunması için temel prensibe uygun olarak, mimarın çalışmalarını

açıklayan belgelerde aranacak en düşük standartlar belirlenmiştir. Bu standartlardan Projelerin İçereceği Bilgiler ve Çizim Standartlarından, Planlar (Ön Proje Aşamasında) kısmında yer alan bazı ölçütler ele alınarak projenin uygunluğunun tespiti için kullanılmıştır. Ön proje aşamasındaki proje planlarında yer alması gereken ölçütlerde, bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler kriter olarak belirlenmiştir.

Bu çalışmada, Visual Studio programında DNN modeli kullanılmıştır. Çalışma kapsamında Düzce Üniversitesi, Sanat, Tasarım ve Mimarlık Fakültesi – Mimarlık Bölümü öğrencilerinin mimari uygulama proje çizimleri veri olarak kullanılmıştır. Proje çıktıları üzerinden ön işleme yapılmıştır. Veri seti %85 eğitim verisi ve %15 test verisi olarak ayrılmıştır. Daha sonra veriler görüntü işleme kullanılarak, ResNet-50 modeli ile ön işleme yapılmıştır. Ön işleme sonrasında, yapay zekâ algoritması kullanılarak model sınıflandırılmıştır. Model sonrasında test için ayrılan test verileri programa analiz ettirilmiştir. Analiz ettirilen test verilerinin performans sonuçlarına göre oranları belirlenmiştir. Performans analizine göre sınıflandırılan sonuçlar değerlendirilmiştir. Değerlendirilen sonuçlara göre ön proje aşamasındaki proje konut planlarının çizim standartlarından geçerli veya geçersiz olma oranları tespit edilmiştir. Yapılan çalışma ile ön proje çizim standartlarını sağlayıp sağladığının tespiti edilebileceği ve oluşacak hata ve zaman kaybını önleyeceği düşünülmektedir.

- **Çalışmanın Önemi**

Bu çalışma, Türkiye'deki mimarlık sektöründe önemli bir boşluğu doldurmayı amaçlamaktadır. Geleneksel yöntemlerle yapılan proje çizimlerinin manuel olarak incelenmesi ve standartlara uygunluğunun kontrol edilmesi sürecindeki zorluklar ve eksiklikler, sektördeki uzmanlar tarafından sıkça dile getirilmektedir. Bu noktada, yapay zekâ, derin öğrenme ve yapay sinir ağları gibi yeni teknolojilerin kullanımı, ön proje aşamasında doğru çizim standartların belirlenmesi ve ölçütlerinin doğru şekilde ortaya konulmasının tespitini sağlayarak bu zorlukları aşma potansiyeline sahiptir.

Özellikle Türkiye'de yapılan çalışmalar ve literatürdeki incelemeler, bu teknolojilerin mimarlık projelerinde kullanımının sektöre önemli katkılar sağlayabileceğini göstermektedir. Zaman ve kaynak verimliliği, detayların doğruluğu, ölçeklenebilirlik ve yenilikçilik gibi avantajlar, yapay zekâ tabanlı sistemlerin mimarlık sektöründe

kullanımını desteklemektedir. Bu çalışma, bu teknolojilerin önemini vurgulayarak, sektördeki standartları yükseltmeyi ve projelerin başarısını artırmayı hedeflemektedir.

Bu bağlamda, çalışmanın Türkiye'deki mimarlık sektöründe yapılan çalışmalara ve literatüre önemli bir katkı sunacağı öngörülmektedir. Yapılan bu çalışma, sektördeki mevcut zorlukları anlamamızı ve yeni teknolojilerin kullanımıyla bu zorlukları aşma potansiyelini göstermektedir. Bu nedenle, çalışmanın sektörde büyük bir ilgi ve etki yaratacağına inanılmaktadır. Mimari projelerin ön proje aşaması, inşaat sektöründe belki de en kritik aşamalardan birini oluşturur. Bu aşama, projenin ana hatlarının çizildiği, tasarımın şekillendiği ve temel kararların alındığı bir süreçtir. Bu nedenle, ön proje aşamasında doğru standartların belirlenmesi ve detayların doğru şekilde ortaya konulması, projenin ilerleyen aşamalarında başarısını doğrudan etkileyen kritik bir faktördür. Geleneksel yöntemlerle, mimarlar ve proje ekibi, proje çizimlerini manuel olarak inceler ve standartlara uygunluğunu kontrol ederler. Ancak, bu süreç zaman alıcıdır ve insan hatalarına açıktır. Bu noktada, yapay zekâ, derin öğrenme ve yapay sinir ağları gibi yeni teknolojilerin kullanımı önem kazanmaktadır. Bu teknolojiler, proje çizimlerinin otomatik olarak analiz edilmesine ve belirlenen standartlara uygunluğunun değerlendirilmesine olanak tanır. Bu, hem zaman kazandırır, hem de insan hatalarını en aza indirir. Bu çalışmanın önemi, mimarlık alanında yapay zekâ ve derin öğrenme gibi yeni teknolojilerin kullanımının artmasıyla birlikte, mimarların bu teknolojilerden nasıl faydalanabileceklerini anlamalarına ve projelerini nasıl iyileştirebileceklerini keşfetmelerine yardımcı olmasıdır. Bu, sadece mimarlık pratiği için değil, aynı zamanda inşaat sektörü için de önemli bir adımdır. Sonuç olarak, bu çalışma, mimarlık alanında yapay zekâ ve derin öğrenme teknolojilerinin kullanımının önemini vurgulayarak, sektördeki standartları yükseltmeye ve projelerin daha etkili bir şekilde yönetilmesine katkıda bulunacaktır. Bu, hem akademik hem de endüstriyel açıdan değerli bir katkı sağlayacaktır.

- **Tezin Organizasyonu**

Bu tez çalışması beş bölümden oluşturulmuştur.

Tez çalışmasının birinci bölümünde, mimarlık ve yapay zekâ ile ilişkisi ve ön proje aşamasındaki projenin çizim standartları hakkında bilgi verilmiş, çalışmanın amacı açıklanmıştır.

İkinci bölümde, temel kavramlara değinilerek mimari tasarım süreçlerine, mimari tasarımda yapay zekâ ile çalışılan örnekler, yapay zekâ ve yapay sinir ağları kavramlarının araştırmaları yapılmıştır.

Üçüncü bölümde, ön proje aşamasındaki projenin çizim standartlarının uygun olup olmadığını tespitinin yapılabilmesi için gerekli veri hazırlığı ve veri işleme işlemleri anlatılmıştır.

Dördüncü bölümde, işlenen verilerin elde edilişi, görüntü analizinin yapılması, geçerli ve geçersiz olma durumuna göre sınıflandırma performanslarının değerlendirilmesi yapılmıştır.

Beşinci bölümde, uygulanan yapay zekâ teknolojisi tabanlı programın sonuçları detaylı bir şekilde incelenmiş, her bir analiz ve sınıflandırma sürecine ait sonuçlar ayrıntılı bir şekilde sunulmuştur. Bu bölümde elde edilen bulgular, detaylı bir analizle değerlendirilmiş ve elde edilen sonuçlar üzerinden çeşitli çıkarımlar yapılmıştır.

2. LİTERATÜR TARAMASI

Mimarlık, insanlığın tarih boyunca yaşadığı mekânsal ihtiyaçların karşılanmasında temel bir rol oynamıştır. Günümüzde ise teknolojinin hızla gelişmesi, mimarlık alanında da büyük değişimlere yol açmıştır. Bu değişimler, mimarlık uygulamalarında kullanılan teknolojilerin ve süreçlerin daha akıllı ve verimli hale gelmesini sağlamıştır.

Bu çalışma, Türkiye'deki mimari tasarım süreçlerini, izin edinme süreçlerini ve mimari proje çizimleri için standartları ele almayı amaçlamaktadır. Özellikle yapay zekanın bu süreçlere entegrasyonunun getirdiği olanakları incelemeyi hedeflemektedir. Bu bağlamda, literatür araştırmasında farklı çalışmalar özetlenmiştir.

Chen ve Chen (2018), sürdürülebilir mimari tasarım için makine öğrenimi tekniklerinin kullanımını inceler. Makine öğrenimi yöntemlerinin, enerji verimliliği, malzeme seçimi ve yeşil bina tasarımı gibi sürdürülebilirlik odaklı tasarım kararlarına nasıl uygulanabileceğini araştırır.

Lu, Sun, Yao(2019), performans odaklı mimari tasarım keşfi için derin öğrenme yaklaşımı ele alınmıştır. Makale, derin öğrenme yöntemlerinin kullanılmasıyla, mimari tasarımın performansını iyileştirmek için keşif sürecinde nasıl kullanılabileceğini araştırır.

Derix, Miranda(2019), dijital paradigmalara dayalı mimari tasarım üzerine odaklanan bir konferansın bildirilerini içerir. Yapay sinir ağları ve diğer dijital teknolojilerin mimari tasarım sürecine nasıl entegre edilebileceği üzerinde durulur. Kitap, dijital tasarım araçlarının kullanımını, parametrik tasarımı ve hesaplama tasarımını ele alan çeşitli yaklaşımları sunar.

Liu ve arkadaşları (2021), mimari mirasın 3D rekonstrüksiyonunda derin öğrenme tabanlı yaklaşımları inceler. Mimari mirasın dijital modellerini oluşturmak için derin

öğrenme tekniklerinin kullanılabilirliğini değerlendirir.

Beiranvand ve Yitmen (2020), yapay sinir ağları kullanarak karmaşık iç mekânlarda yol bulma performansının tahmin edilmesine odaklanır. Derin öğrenme tekniklerinin, iç mekân tasarımında insanların yol bulma yeteneklerini tahmin etmek için nasıl kullanılabileceğini inceler.

Zhang ve arkadaşları (2021), mimari düzenleme planlamasında makine öğrenimi tabanlı generatif(üretken) tasarım yöntemlerini gözden geçirir. Mimari yerleşim planlamasında generatif tasarımın nasıl uygulanabileceğini ve makine öğrenimi tekniklerinin nasıl kullanılabileceğini araştırır.

Mekawy ve arkadaşları (2021), yapay sinir ağlarının bina kabuğu tasarımında nasıl kullanılabileceğini değerlendirir. Derin öğrenme tekniklerinin, bina kabuğu tasarım sürecinde kullanılabilirliğini ve potansiyel avantajlarını inceler.

Baydoğan (2013), yapay zeka destekli sistemi kullanarak, konut yerleşim planları için tip imar planı ve yönetmeliklerinin gerekliliklerini karşılayacak doğru yerleşimi bulmak, yoğunluk hesaplarını yapmak ve sonuç olarak çıkan kütle büyüklüğü ve kat adedini tasarımcıya göstermektedir. Bu program, mimari tasarımcılara tasarım sürecinde önemli bir destek sağlayarak daha bilinçli ve optimize edilmiş tasarım çözümleri üretmeye yardımcı olmayı hedeflemiştir.

Aslı Çekmiş (2016), bulanık mantık sistemini kullanarak, konut yerleşim düzenlerinin avantajlı konumlarını belirlemede etkili bir model sunmaktadır. MATLAB'da Sugeno tipi FIS editörü kullanılarak her konut biriminin avantajlı değeri değerlendirilmiştir. Bulanık çıkarım süreci, girdi vektöründeki değerlere dayanarak çıktı vektörüne değerler atanmıştır. Bu sayede, bir alandaki konutların yerleşim düzenlerinin en avantajlı konumlarını belirlemeyi amaçlamıştır.

Hao Zheng ve Weixin Huang (2018), mimari planlar üzerinde çalışan üretken ağ sistemini CGAN (Koşullu Üretken Çekişmeli Ağ) kullanarak mimari tasarım sürecinde,

kullanıcı ve mimar arasındaki ön görüşmelerde doğru analiz yapılamadığından sürecin uzunluğuna dikkat çekilmiş ve üretken ağ sistemlerinin kullanılmasının süreci hızlandırabileceği ve farklı alternatifler sunabileceği gözlemlenmiştir.

Bingöl ve ekibi(2020), derin öğrenme temelli bir makine öğrenimi yöntemi kullanarak taşıyıcı sistemlerin depreme dayanıklılığını değerlendirebilen bir çalışma gerçekleştirmiştir. Python ve IMAGE AI programları kullanılarak oluşturulan çalışmada, derin öğrenme teknikleri ve görüntü okuma yöntemi ile oluşturulan Düzensizlik Kontrol (DK) asistanının yeni tasarımlar için yorum yapması hedeflenmiştir.

Çerçi (2022), mimari konum planlama sürecinde geleneksel yöntemler dışında yapay zeka, makine öğrenmesi ve meta-sezgisel optimizasyon algoritmaları gibi modern yöntemlerin kullanılmasıyla blok yerleşimi optimizasyonunu gerçekleştirmeyi hedeflemektedir. Bu algoritmalar, büyük boyutlara ve karmaşık kısıtlamalara sahip pratik problemler için uygun olan problem bağımsız tekniklerdir ve makul hesaplama zamanlarında iyi kalitede çözümler elde etmeyi amaçlamaktadırlar. Araştırma, meta-sezgisel algoritmalarından yararlanarak mimari yerleşimdeki optimizasyon sorununa çözüm getirmeyi hedeflemektedir.

Zekić ve Ognjanović (2021), mimari tasarımda derin öğrenme ve yapay zekâ tekniklerinin kullanımını incelemektedir. Makale, mimari tasarım sürecinde derin öğrenme ve yapay zekânın nasıl entegre edilebileceğini ve potansiyel faydalarını ele almaktadır. Örneğin, mimarlıkta stil analizi, tasarım optimizasyonu, kullanıcı davranışı tahmini gibi konulara derin öğrenme yaklaşımlarının nasıl uygulanabileceği incelenmektedir.

Zhang, Yu, Xiong ve Wang(2019), mimari uygulamalarda 3D rekonstrüksiyon için derin öğrenme tekniklerinin kullanımını ele almaktadır. Dergide, 3D modelleme, lazer tarama ve görüntü işleme gibi tekniklerin yanı sıra derin öğrenme yöntemlerinin nasıl kullanılabileceğini inceler. Bu sayede, mimari alanında daha hızlı ve doğru 3D rekonstrüksiyon yöntemlerinin geliştirilmesine katkıda bulunulabilir.

Balaban ve arkadaşları (2020), binalarda iç mekân konforunun tahmin edilmesinde derin öğrenme tekniklerinin kullanımını araştırmaktadır. Makalede, sensör verileri, hava durumu koşulları ve enerji tüketimi gibi faktörler kullanılarak derin öğrenme modelleri oluşturulması ele alınır. Bu modeller, bina içindeki sıcaklık, nem ve hava kalitesi gibi parametrelerin tahmininde kullanılabilir ve bina konforunu artırmak için önleyici tedbirler alınabilir.

Liu ve arkadaşları(2020), bina kabuğu tasarımında çok amaçlı optimizasyon için derin öğrenme temelli bir yöntem ele alınmaktadır. Dergide, enerji verimliliği, konfor düzeyi, aydınlatma kalitesi gibi farklı hedeflere sahip çoklu amaçlı optimizasyon problemleri için derin öğrenme modelleri kullanılarak en iyi tasarım çözümlerinin bulunması üzerine odaklanılmıştır. Bu sayede, bina kabuğu tasarımının enerji tasarrufu ve performans açısından optimize edilmesi amaçlanır.

Ahmad ve arkadaşları (2021), bina sistemleri tasarım optimizasyonunda derin öğrenmenin kullanımını değerlendirmektedir. Makalede, elektrik, ısıtma, havalandırma ve iklimlendirme gibi bina sistemlerinin tasarımının geliştirilmesi için derin öğrenme tekniklerinin nasıl kullanılabileceği incelenmektedir. Bu teknikler, enerji verimliliği, operasyonel performans ve kullanıcı konforu gibi faktörlerin iyileştirilmesine yardımcı olabilir.

Nguyen ve arkadaşları (2021), mimaride yapay zekâ tekniklerinin sistemli bir şekilde incelenmesini sağlayan bir derleme makalesidir. Makalede, mimari tasarım sürecinde yapay zekâ tekniklerinin kullanım alanları, yapı bilgisi, şekil optimizasyonu, enerji analizi ve kullanıcı deneyimi gibi farklı konular üzerinde ayrıntılı bir inceleme yapılmaktadır. Bu sayede, mimarlık alanında yapay zekânın potansiyel uygulamaları ve etkileri hakkında genel bir bakış sunulmaktadır.

Kwon, Cho, ve Park (2021), kentsel tasarımı alanında derin öğrenme tekniklerinin kullanımını ele almaktadır. Makalede, derin öğrenme modellerinin kentsel alanların analizi, yoğunluk tahmini, ulaşım planlaması ve peyzaj tasarımı gibi alanlarda nasıl kullanılabileceği incelenmektedir.

Ahn, Park ve Jeong (2020), binaperformansının tahmin edilmesinde derin öğrenme uygulamalarını değerlendirmektedir. Makalede, bina enerji tüketimi, ısıtma-soğutma yükleri ve termal konfor gibi faktörlerin derin öğrenme modelleri kullanılarak nasıl tahmin edilebileceği üzerinde durulmaktadır.

Wei ve arkadaşları (2021), bina düzenlemeleri için derin öğrenme tabanlı generatif tasarım yöntemlerini incelemektedir. Makalede, derin öğrenme tekniklerinin kullanıldığı otomatik planlama, yerleşim düzenioptimizasyonu ve bina yerleşimi oluşturma gibi konulara odaklanılmaktadır.

Zhang, Janssen ve Wei (2020), mimari tasarımda makine öğrenimi uygulamalarını incelemektedir. Makalede, makine öğrenimi tekniklerinin tasarım optimizasyonu, performans analizi, biçim araştırması ve tasarım bilgisi yönetimi gibi alanlarda nasıl kullanılabileceği üzerinde durulmaktadır.

Chen ve Jin (2020), yapay sinir ağlarının bina tasarım özellikleri için kullanıcı tercihlerini tahmin etmek için nasıl uygulanabileceğini inceliyor. Makalede, kullanıcıların bina tasarımıyla ilgili tercihlerini belirlemek için yapay sinir ağı modelleri kullanılarak kullanıcı geri bildirimlerinden veri toplamanın ve analiz etmenin önemi vurgulanmaktadır.

Akbarzadeh ve arkadaşları (2020), mimarlıkta derin öğrenmenin etkisini değerlendiren bir incelemeyi sunar. Makale, derin öğrenme yöntemlerinin mimari tasarımın farklı yönlerinde nasıl kullanıldığına dair bir genel bakış sunar. Bu inceleme, derin öğrenmenin yapay zekâ destekli tasarım, yapısal analiz, enerji analizi ve tasarım optimizasyonu gibi alanlarda nasıl uygulandığını araştırır.

Ghaffarianhoseini ve arkadaşları (2019), yapay sinir ağlarının kentsel tasarım alanında nasıl kullanılabileceğini incelemektedir. Makalede, yapay sinir ağları kullanılarak kentsel tasarım problemlerinin modellemesi ve analizi için örnekler sunulmaktadır. Örneğin, kentsel doku analizi, trafik tahmini ve yeşil alan planlaması gibi konularda yapay sinir ağları kullanılarak tasarım kararları desteklenebilir.

Tan ve arkadaşları (2020), yapay sinir ağlarının binaların enerji performansını tahmin etmek için nasıl kullanılabileceğini ele alıyor. Makalede, bina enerji tüketimi verilerinin yapay sinir ağı modelleri kullanılarak nasıl analiz edilebileceği ve enerji tasarrufu potansiyelinin nasıl belirlenebileceği üzerinde durulmaktadır.

Elmas ve Ergen(2020), yapay sinir ağları kullanılarak kentsel tasarım kararlarını desteklemek için bir karar destek modeli geliştirilmesini inceliyor. Makalede, yapay sinir ağlarının kullanıldığı bir modelin nasıl tasarlandığı ve kentsel tasarım kararlarında nasıl kullanılabileceği üzerinde durulmaktadır. Model, farklı kentsel tasarım senaryolarının performansını değerlendirmek ve optimize etmek için kullanılabilir.

Zhang, Wang ve Jia (2020), mimaritasarım optimizasyonunda derin takviye öğrenme yöntemlerinin nasıl kullanılabileceğini inceliyor. Makalede, derin öğrenme ve takviye öğrenme tekniklerinin kullanılarak otomatik tasarım optimizasyonunda nasıl kullanılabileceği ve mimari tasarım kararlarının iyileştirilmesine nasıl katkıda bulunabileceği üzerinde durulmaktadır.

Zhu ve Gero (2019), derin öğrenme tabanlı generatif tasarım yöntemlerinin yüksek boyutlu tasarımlarının keşfedilmesinde nasıl kullanılabileceğini araştırıyor. Makalede, yapay sinir ağları ve genetik algoritma gibi yöntemlerin birleşimiyle, karmaşık tasarım alanlarında alternatif çözümler üretebilen bir modelin nasıl geliştirilebileceği üzerinde durulmaktadır.

Goodfellow, Bengio ve Courville (2016), derin öğrenme konusunu ele alan kapsamlı bir kitap yayınlamışlardır. Derin öğrenme temellerini, derin sinir ağları mimarisini ve çeşitli derin öğrenme tekniklerini içeren bir inceleme sunar. Kitap, derin öğrenmeye dair temel bilgileri içeren bir giriş niteliğindedir.

Oyarzun ve arkadaşları (2020), yapay sinir ağlarının mimari tasarım sürecinde karar verme sürecine nasıl destek sağlayabileceğini araştırıyor. Makalede, yapay sinir ağları ve veri analizi tekniklerinin kullanılarak tasarım kararlarına yönelik bilgi sağlanabileceği ve karar verme sürecinin iyileştirilebileceği üzerinde durulmaktadır.

O'Brien ve Sodhi (2021), mimari tasarımda evrişimli sinir ağlarının potansiyelini araştırıyor. Makalede, evrişimli sinir ağlarının mimari biçimlerin analizi, özellik çıkarımı ve benzerlik ölçümü gibi alanlarda nasıl kullanılabileceği ve tasarım sürecine nasıl entegre edilebileceği üzerinde durulmaktadır.

Tsai ve Huang (2020), derin öğrenme tekniklerinin bina cephesi görsellerinin estetik değerlendirmesinde kullanımını araştırıyor. Makalede, görsel özellik çıkarımı, estetik değerlendirme ve derin öğrenme modellerinin nasıl eğitilebileceği üzerinde durulmaktadır.

Radwan ve Afify (2019), derin öğrenme tabanlı bir yaklaşımın cephe kaplama sistemlerinin verimli bir şekilde seçiminde nasıl kullanılabileceğini araştırıyor. Makalede, cephe kaplama malzemelerinin özellikleri, performans kriterleri ve tasarım tercihleri ile ilgili veriler kullanılarak derin öğrenme modellerinin nasıl eğitileceği ve kullanılabileceği üzerinde durulmaktadır.

Li, Sun ve Wei (2019), jeneratif karşılaştırmalı ağlar (GAN'lar) kullanarak mimari tasarımda nasıl kullanılabileceğini incelemektedir. GAN'lar, yeni tasarım örneklerinin üretilmesi, tasarım varyasyonlarının keşfedilmesi ve tasarım sürecinde yaratıcı bir yaklaşımın teşvik edilmesi gibi alanlarda kullanılabilmektedir.

Zhang, Wu ve Chen (2020), derin takviye öğrenme yöntemlerinin optimal mekân düzeni tasarımında nasıl kullanılabileceğini araştırıyor. Makalede, mekân düzeni tasarımının bir optimizasyon problemi olarak ele alınması ve derin takviye öğrenme algoritmalarının kullanılarak optimal bir mekân düzeni tasarımının otomatik olarak elde edilebileceği üzerinde durulmaktadır.

Literatür taramasına ait özet tablosu Çizelge 2.1'de verilmiştir. Çizelge, her bir çalışmanın adı, yazar(lar), yayın yılı, kullanılan teknik ve yöntem seçimini içermektedir.

Çizelge 2.1.Mimaride Yapay Zekanın Kullanılmasına İlişkin Literatür Taraması

Çalışma Adı ve Yazar(lar)	Yıl	Kullanılan Teknik	Yöntem Seçimi
Machine Learning Techniques for Sustainable Architecture Design. Sustainability (Chen ve Chen)	2018	Makine Öğrenimi Teknikleri	Enerji verimliliği, malzeme seçimi, yeşil bina tasarımı gibi sürdürülebilirlik odaklı tasarım kararlarına uygulama için seçilmiştir.
A Deep Learning Approach for Performance-Driven Architectural Design Exploration. Automation in Construction (Lu, Sun, Yao)	2019	Derin Öğrenme Yaklaşımı	Mimari tasarımın performansını keşif sürecinde iyileştirmek için seçilmiştir.
Architectural Design and Digital Paradigms: Proceedings of the 5th International Conference on the Architectural Design and Digital Paradigms (Derix, Miranda)	2019	Dijital Tasarım Araçları	Yapay sinir ağları ve diğer dijital teknolojilerin mimari tasarım sürecine entegrasyonunu incelemek amacıyla seçilmiştir.
Deep Learning-Based 3D Reconstruction for Architectural Heritage: A Review. Journal of Cultural Heritage (Liu ve Ark.)	2021	Derin Öğrenme Tabanlı Yaklaşımlar	Mimari mirasın dijital modellerini oluşturmak için derin öğrenme tekniklerinin kullanılabilirliğini değerlendirmek için seçilmiştir.
Predicting Wayfinding Performance in Complex Indoor Environments: A Deep Learning Approach. Frontiers of Architectural Research (Beiranvand ve Yitmen)	2020	Yapay Sinir Ağları	İç mekân tasarımında insanların yol bulma yeteneklerini tahmin etmek için derin öğrenme tekniklerinin kullanılabilirliğini incelemek için seçilmiştir.
Generative Design in Architectural Layout Planning Using Machine Learning: A Review (Zhang ve ark.)	2021	Makine Öğrenimi Tabanlı Generatif Tasarım	Mimari yerleşim planlamasında generatif tasarımın uygulanması ve makine öğrenimi tekniklerinin kullanımının araştırılması
Deep Learning for Building Envelope Design: A Review (Mekawy ve ark.)	2021	Yapay Sinir Ağları	Bina kabuğu tasarımında derin öğrenme tekniklerinin kullanılabilirliğinin değerlendirilmesi

Çizelge 2.1. (devamı) Mimaride Yapay Zekanın Kullanılmasına İlişkin Literatür Taraması

Tip İmar Yönetmeliğine Uygun Vaziyet Planı Üreten Bir Yapay Zeka Destek Sistemi(Baydoğan)	2013	Yapay Zeka	Tip imar planı ve yönetmeliklerine uygun konut yerleşim planlarını belirlemek ve yoğunluk hesaplarını yaparak tasarımcıya doğru kütle büyüklüğü ve kat adedi bilgilerini sunmak
Fuzzy logic in architectural site planning design(Çekmiş)	2016	Bulanık Mantık	Konut yerleşim düzenlerinin avantajlı konumlarını belirlemede etkili bir model sunmak
Architectural drawings recognitionand generationthrough machine learning(Huang ve ark.)	2018	Makine Öğrenmesi	Akıllı mimari plan üreten bir örnek olma özelliğini taşımaktadır
Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti (Bingöl)	2020	Derin Öğrenme	Programın, taşıyıcı sistemin görsel özelliklerini değerlendirerek depreme dayanıklılığı üzerinde uzman benzeri yorumlar yapabilmesi
Mimari Konum Planı Ön Tasarımında Bir Yapay Zeka Uygulaması(Çerçi)	2022	Yapay Zeka	Mimari tasarım sürecinde ön tasarım aşamasında blok yerleşimi problemini çözmek ve meta-sezgisel algoritmaların etkisini incelemeyi amaçla
Deep Learning and Artificial Intelligence in Architectural Design: A Review (Zekić ve Ognjanović)	2021	Derin Öğrenme ve Yapay Zekâ	Mimari tasarımda derin öğrenme ve yapay zekânın entegrasyonu ve potansiyel faydalarının incelenmesi
A Review of Deep Learning Techniques for 3D Reconstruction in Architectural Applications (Zhang, Yu, Xiong ve Wang)	2019	Derin Öğrenme Teknikleri	Mimari uygulamalarda 3D rekonstrüksiyon için derin öğrenme tekniklerinin kullanılması
Deep Learning-Based Indoor Comfort Prediction in Buildings (Balaban ve ark.)	2020	Derin Öğrenme Modelleri	Binalarda iç mekân konforunun tahmin edilmesi ve bina konforunun artırılması için kullanılması

Çizelge 2.1. (devamı)Mimaride Yapay Zekanın Kullanılmasına İlişkin Literatür Taraması

Deep Learning-Based Multi Objective Optimization for Building Envelope Design (Liu ve ark.)	2020	Derin Öğrenme Temelli Çok Amaçlı Optimizasyon	Bina kabuğu tasarımında enerji tasarrufu ve performans açısından optimize edilmesi
Deep Learning for Building Systems Design Optimization: A Review (Ahmad ve ark.)	2021	Derin Öğrenme Teknikleri	Bina sistemleri tasarım optimizasyonunda derin öğrenme kullanımının değerlendirilmesi
Artificial Intelligence in Architecture: A Systematic Review (Nguyen ve ark.)	2021	Yapay Zekâ	Mimari tasarımda yapay zekâ tekniklerinin kullanım alanlarının sistemli bir şekilde incelenmesi
Deep Learning for Urban Design: A Review (Kwon, Cho, ve Park)	2021	Derin Öğrenme Modelleri	Kentsel tasarım alanlarında derin öğrenme tekniklerinin kullanımının incelenmesi
Generative Design for Building Layouts Using Deep Learning: A Review (Wei ve ark.)	2021	Derin Öğrenme Tabanlı Generatif Tasarım	Bina düzenlemeleri için derin öğrenme tabanlı generatif tasarım yöntemlerinin incelenmesi
Deep Learning Applications for Building Performance Prediction: A Review (Ahn, Park ve Jeong)	2020	Derin Öğrenme Uygulamaları	Bina performansının tahmin edilmesinde derin öğrenme uygulamalarının değerlendirilmesi
Applications of Machine Learning in Architectural Design: A Review (Zhang, Janssen ve Wei)	2020	Makine Öğrenimi Teknikleri	Mimari tasarımda makine öğrenimi uygulamalarının incelenmesi
Applying Artificial Neural Networks to Predict User Preferences for Building Design Features (Chen ve Jin)	2020	Yapay Sinir Ağları	Kullanıcı tercihlerini tahmin etmek için yapay sinir ağlarının kullanılması
Evaluating the Impact of Deep Learning in Architecture: A Review of Methods and Applications (Akbarzadeh ve ark.)	2020	Derin Öğrenme Yöntemleri	Derin öğrenme tekniklerinin mimari tasarımın farklı yönlerindeki etkisinin değerlendirilmesi

Çizelge 2.1. (devamı) Mimaride Yapay Zekanın Kullanılmasına İlişkin Literatür Taraması

Artificial Neural Network Modelling in Urban Design: A Review (Ghaffarianhoseini ve ark.)	2019	Yapay Sinir Ağları	Kentsel tasarım alanında yapay sinir ağlarının kullanımının incelenmesi
Predictive Modeling of Energy Performance of Buildings Using Artificial Neural Networks: A Review (Tan ve ark.)	2020	Yapay Sinir Ağları	Binaların enerji performansının yapay sinir ağlarıyla tahmin edilmesinin incelenmesi
An Artificial Neural Network-Based Decision Support Model for Urban Design (Elmas ve Ergen)	2020	Yapay Sinir Ağları	Kentsel tasarım kararlarını desteklemek için yapay sinir ağları kullanımının incelenmesi
Deep Reinforcement Learning for Architectural Design Optimization (Zhang, Wang ve Jia)	2020	Derin Takviye Öğrenme	Mimari tasarım optimizasyonunda derin takviye öğrenme yöntemlerinin incelenmesi
A Generative Design Approach to Exploring High-Dimensional Design Spaces using Deep Learning (Zhu ve Gero)	2019	Derin Öğrenme Tabanlı Generatif Tasarım	Yüksek boyutlu tasarım alanlarının keşfedilmesinde derin öğrenme tabanlı generatif tasarım yöntemlerinin araştırılması
Deep Learning (Goodfellow, Bengio ve Courville)	2016	Derin Öğrenme Teknikleri	Derin öğrenme alanında kapsamlı bir inceleme
Applying Artificial Neural Networks to Support Decision-Making in Architectural Design (Oyarzun ve ark.)	2020	Yapay Sinir Ağları	Mimari tasarım karar verme sürecinde yapay sinir ağlarının kullanımının incelenmesi
Investigating the Potential of Convolutional Neural Networks for Architectural Design (O'Brien ve Sodhi)	2021	Evrişimli Sinir Ağları	Mimari tasarımda evrişimli sinir ağlarının potansiyelinin araştırılması

Çizelge 2.1. (devamı) Mimaride Yapay Zekanın Kullanılmasına İlişkin Literatür Taraması

Predicting Visual Aesthetic Scores of Building Facades Using Deep Learning (Tsai ve Huang)	2020	Derin Öğrenme Teknikleri	Bina cephesi görsellerinin estetik değerlendirmesinde derin öğrenme tekniklerinin kullanımının araştırılması
Deep Learning-Based Approach for Efficient Selection of Façade Cladding Systems (Radwan ve Afify)	2019	Derin Öğrenme Tabanlı Yaklaşım	Cephe kaplama sistemlerinin verimli bir şekilde seçilmesinde derin öğrenme tabanlı yaklaşımın incelenmesi
Using Generative Adversarial Networks (GANs) in Architectural Design: A Review (Li, Sun ve Wei)	2019	Jeneratif Karşılaştırmalı Ağlar	Mimari tasarımda GAN'ların kullanımının incelenmesi
Deep Reinforcement Learning for Optimal Space Layout Design (Zhang, Wu ve Chen)	2020	Derin Takviye Öğrenme	Optimal mekân düzeni tasarımında derin takviye öğrenme yöntemlerinin kullanılmasının incelenmesi

3. MİMARİ TASARIM

Mimari tasarım, mimarların belirli kurallar ve düşünme sanatıyla çeşitli bileşenleri bir araya getirerek planlama, tasarlama ve inşa etme sürecidir (Kalay, 1992). Bu süreç, estetik, işlevsellik, kullanıcı gereksinimleri, teknik gereklilikler ve bileşen faktörleri gibi bir dizi unsuru içerir.

Estetik, mimari tasarımın temel bileşenlerinden biridir ve tasarımın görsel ve duygusal çekiciliğini ifade eder (Lawrence, 2005). Bu, yapıların dış görünüşünü, malzeme seçimini ve renk kullanımını içerir. İşlevsellik ise tasarımın kullanıcı ihtiyaçlarını karşılayacak şekilde oluşturulmasını sağlar. Kullanıcı gereksinimleri, projenin amacına ve hedef kitlesine uygun olarak belirlenir ve tasarım sürecinde önemli bir rol oynar. Teknik gereklilikler ise yapısal dayanıklılık, enerji verimliliği ve güvenlik gibi faktörleri kapsar.

Jones, tasarım sürecinde üç temel aşamadan bahsetmektedir (Jones, 1980). Bu aşamalar şunlardır:

Analiz Aşaması: Problemin derinlemesine incelendiği ve tanımlandığı aşamadır. Bu aşamada tasarım sorununun özü anlaşılmalı ve gereksinimler belirlenir.

Sentez Aşaması: Analiz aşamasında belirlenen gereksinimlere dayanarak çözüm önerileri üretilir ve tasarımın ana hatları belirlenir.

Değerlendirme Aşaması: Oluşturulan çözüm önerileri ve tasarımın detayları incelenerek, tasarımın uygunluğu ve etkinliği değerlendirilir. Bu aşamada tasarımın hedeflerine ne kadar uygun olduğu ve tasarımın hangi ölçüde başarılı olduğu analiz edilir. (Şekil 3.1.)



Şekil 3.1. Tasarım süreci akış grafiği (Jones, 1980)

Jones'a göre, bu aşamalar tasarım sürecinin temel bileşenlerini oluşturur ve tasarım süreci boyunca tekrarlanarak tasarımın gelişimini sağlar.

Mimari tasarım süreçleri, yapıların kavramsal gelişiminden başlayarak detaylı çizimlere ve sonunda ruhsat alma sürecine kadar uzanan karmaşık bir süreçtir (Ching, 2014). Bu süreçlerde, projenin teknik, estetik ve yasal gereksinimleri karşılaması önemlidir (Gibson, 2018). Bu gereklilikleri karşılamak için, projenin ön proje çizimlerinin belirli standartlara uygun olması gerekmektedir.

Ön proje çizimleri, projenin kavramsal yapısını görselleştirmeyi amaçlayan belgelerdir ve genellikle planlar, kesitler, görünüm ve şematik çizimler içerir (Burry, 2013). Bu çalışmada çizimlerin standartlara uygunluğu, projenin teknik doğruluğunu ve estetik bütünlüğünü sağlamayı amaçlamaktadır. Ayrıca, ruhsat alma sürecinde de bu çizimlerin belirli standartlara uygun halde sunulmayı hedeflemektedir.

Standartların belirlenmesi genellikle yerel yönetmelikler, ulusal standartlar ve mesleki kuruluşların belirlediği kılavuzlar doğrultusunda gerçekleşir (Türkiye Mimarlar Odası, 2020). Örneğin, Türkiye'de mimari projeler için belirlenen standartlar ve kurallar, Türkiye Mimarlar Odası tarafından belirlenmiştir ve bu standartlar projelerin teknik, estetik ve yasal gereksinimlerini karşılamak için tasarlanmıştır.

Bu standartlar, projenin çizim aşamasında ve ruhsat alma sürecinde göz önünde bulundurulur.

Ön Proje Aşamasında, mimari projelerin içermesi gereken bilgiler ve çizim standartları belirli bir düzen ve kapsamda olmalıdır. Bu aşamada projelerin sağlaması gereken temel bilgiler şunlardır:

İhtiyaç Programına Uygunluk: Projede yer alan her bir unsur, önceden belirlenmiş ihtiyaç programına uygun olarak tasarlanmalıdır. Bu, projenin işlevselliği ve kullanıcı gereksinimlerine uygunluğu açısından önemlidir.

Çizim Standartları:

Kat Planları: Benzer katların çiziminde aynı bakış açısı kullanılmalı ve tekrar eden katlar açıklamalarla belirtilmelidir. Her paftada hakim rüzgar yönü, manzara ve kuzey yönü gösterilmelidir.

Dış Ölçüler: Blok ölçüsü, cephe hareketleri ve taşıyıcı akslar düzenlenerek dış ölçüler belirtilmelidir.

Blok Kodlaması: Bloklar kodlanarak içerdikleri ünitelerin açıklamaları verilmelidir.

Mahal Bilgileri: Her mahalle için mahal numarası, ismi ve net alanı yazılmalıdır.

Kesitler ve Dilatasyonlar: Her kat planında kesit geçirilen yerlerden kesit çizgisi ve bakış yönü gösterilmeli, dilatasyonlar belirtilmelidir.

İnşai Elemanlar: Kolonlar, perde duvarlar, pano gibi inşai elemanlar ayrı çizim tekniğiyle çizilerek detaylandırılmalıdır.

Çevre Düzenlemesi: Zemin kat planlarında çevre düzenlemesi detaylı olarak işlenmeli ve çizimleri yapılarak gösterilmelidir.

Asma Tavan ve Bacalar: Asma tavan yapılacak yerler işaretlenmeli, bacalar eksiksiz gösterilmelidir.

Çatı Planı: Çatı planında eğimler, su toplama yerleri, tesisat ve asansör çıkıntıları, bacalar ve çatıya çıkış delikleri gösterilmelidir.

Bu standartlar, projenin bütünlüğünü sağlamak ve uygulanabilirliğini artırmak için önemlidir(Türkiye Mimarlar Odası, 2020).Değerlendirme sürecinde, ön proje çizimlerinin belirli kriterlere uygunluğu incelenir. Bu kriterler arasında çizimlerin teknik doğruluğu, ölçek tutarlılığı, detay seviyesi, malzeme ve renk kullanımı, projenin

fonksiyonel gereksinimlere uygunluğu ve çevresel etkilere duyarlılık gibi unsurlar yer alır (Francis, 2012). Bu değerlendirme süreci, projenin teknik, estetik ve yasal gereksinimlerini karşılayıp karşılamadığını belirlemede önemli bir rol oynar.

Bu çalışmada, ön proje aşamasındaki proje planlarındaki değerlendirmelerde yer alacak ölçütler şunlardır:

Bakış Yönü: Planın hangi yönden bakıldığını belirtmek önemlidir. Özellikle kuzey, güney, doğu ve batı gibi yönlerin belirtilmesi planın anlaşılabilirliğini artırır.


Ölçülendirme: Plan üzerindeki her öğenin doğru ölçülerle belirtilmesi gerekir. Ölçüler, metrik sistemde (metre veya santimetre gibi) verilmelidir.

Mahal İsmi ve m²: Her mahalin ismi belirtilmeli ve ayrıca mahalin alanı (m² cinsinden) gösterilmelidir. Bu, planın hangi bölgesinin ne kadar alan kapladığını net bir şekilde ortaya koyar.

Modül ve İnşai Akslar: Proje içinde kullanılan modülasyon sistemleri ve inşai akslar (kolonlar, duvarlar, perde elemanları gibi) belirtilmelidir. Bu, projenin yapısal düzenini ve modüler yapısını gösterir.


Tefrişler: Plan üzerinde mobilyalar, ekipmanlar ve diğer iç mekan öğeleri tefriş simgeleriyle belirtilmelidir. Bu, iç mekan düzenlemesini ve kullanılacak ekipmanların konumunu gösterir.

Ön proje aşamasındaki proje planlarındaki ölçütlerin fotoğrafı, Şekil 3.2'de gösterilmiştir.



Şekil 3.2.Ön proje aşamasındaki proje planlarındaki ölçütlerin fotoğrafı

Ön proje aşamasındaki proje planlarındaki ölçütlerin planda gösterimi Şekil 3.3'de sunulmuştur.



Şekil 3.3. Ölçütlerin planda gösterimi

Ön proje çizim standartlarının uygunluğunun değerlendirilmesi, bir yapı projesinin başarılı bir şekilde ilerlemesi ve tamamlanması için kritik bir adımdır (Güner, 2018).

Mimari tasarım sürecinin tamamlanması ve uygulama aşamasına geçilmesi, genellikle tasarımcılar için büyük zorluklar ve yorgunluklar içeren bir süreçtir. Daha basit bir tasarım önerisi elde etmek bile, çeşitli tasarım alternatifleri arasında seçim yapma gerekliliği nedeniyle karmaşık hale gelebilir. Fiziksel tasarım aşamasına geçmeden önce, teknik kavramlar dışında bir tasarımın oluşturulması da oldukça zorlu bir süreçtir.

Tasarım sürecinin başında farklı kararlar arasında çelişkiler veya tutarsızlıklar varsa, tasarımın doğru şekilde ilerlemesi zorlaşabilir. Ayrıca, tasarım sürecinde teknik detaylar dışında tasarlanan her tasarım, farklı bilgi, deneyim ve hedeflere sahip olan tasarımcılar tarafından etkilenebilir. Bu durum, çeşitli tasarım alternatiflerinin değerlendirilmesini ve karşılaştırılmasını zorlaştırabilir. Tasarım sürecinin belirlenen bir süre içinde tasarım

seimlerine uygun řekilde yrtlebilmesi iin tasarım srecinin btn eř zamanlı olarak ynetilmelidir (Kalay, 1992). Bu deęerlendirme sreci, projenin teknik, estetik ve yasal gereksinimleri karřılamasını saęlar ve projenin bařarılı bir řekilde ruhsat almasına yardımcı olur.

Teknolojinin hızla gelişmesi, mimarlık alanında önemli deęişikliklere ve ilerlemelere yol açmıştır. Bu gelişmeler, mimari tasarım sürecini kökten deęiřtirmiş ve mimarların işlerini kolaylařtırmıştır. Geleneksel el becerisi ve deneyime dayalı mimari tasarım süreci, artık dijital araçlar, yapay zeka ve parametrik tasarım gibi yeni teknolojilerle desteklenmektedir. Bu teknolojik yenilikler, mimarların daha hızlı, verimli ve sürdürülebilir tasarımlar yapmalarını saęlarken aynı zamanda yaratıcılıklarını da desteklemektedir(Brown, 2022). Yapay zeka teknolojisinin mimari tasarım sürecine olan etkisi, gün getike artan bir öneme sahiptir.

Yapay zeka, bilgisayar sistemlerine insan benzeri zeka ve öğrenme yetenekleri kazandırmayı amaçlayan bir alan olarak tanımlanabilir. Bu teknoloji, mimari tasarım sürecinde önemli bir rol oynamaktadır. Bu araçlar arasında, tasarım verilerini analiz ederek optimize edilmiş çzümler sunabilen algoritmalar, mimarlara zaman tasarrufu saęlar ve daha verimli tasarımlar yapmalarına yardımcı olur(Smith & Johnson, 2023).

Ayrıca, yapay zeka destekli tasarım araçları, karmařık tasarım problemlerini çzmek iin kullanılabilir ve mimarların daha önce keřfedilmemiş tasarım çzümleri bulmalarına olanak tanır. Bu bağlamda, Smith ve Johnson (2023) çalışmaları, yapay zeka destekli tasarım araçlarının mimari tasarım sürecine olan etkisini ayrıntılı bir řekilde incelemiřtir. Çalışmalarında, algoritmaların tasarım verilerini analiz ederek mimarların daha etkili kararlar almasını saęladığını ve tasarım sürecindeki verimlilięi artırdığını belirtmişlerdir.

Yapay zeka teknolojisinin mimari tasarım sürecine olan etkisi gün getike artmaktadır. Gelecekte, yapay zeka destekli tasarım araçları daha da gelişerek, mimarların daha karmařık ve sürdürülebilir tasarımlar yapmalarına yardımcı olabilir. Ayrıca, yapay zeka sayesinde tasarımların enerji verimlilięi, malzeme kullanımı ve çevresel etkileri gibi faktörler de daha iyi optimize edilebilir. Bu konuda, Garcia ve Lee (2024) çalışmaları yapay zeka teknolojisinin gelecekteki potansiyelini ve mimariye olan katkısını ayrıntılı olarak ele almışlardır.

4. YAPAY ZEKÂ

“Intellectus” Lantince zekâ anlamında kullanılmaktadır. Zekâ kavramı genel olarak; karar verme aşamasında iyi kararlar alabilen, bir durum karşısında iyi tahmin yapabilen ve karşılaştığı durumlar karşısında kendini geliştirerek, doğru ve hızlı karar verebilmesidir. Bilgisayar alanında uzman insanlar zekâyı bilgi işleme ve çözümleme olarak tanımlarken, eğitim alanındaki uzmanlar eğitime-öğrenme, psikoloji alanındaki uzmanlar ise insan ilişkilerinin analizi olarak tanımlamaktadırlar(Altuntaş, 1998).

Yapay zekâ kavramı ise; insan beynini taklit edebilme yeteneği ile karşılaştığı problemler karşısında insan gibi çözüm sunabilen yöntemdir. İnsanların deneyim ve bilgilerinin bilgisayara öğretilmesi sayesinde öğrendiği bilgiler ile insanlar kadar iyi olmasa da çıktı verebilen bir branştır. Yapay zekâ, insan gibi düşünme yeteneğini makineler kullanarak yapabilme yeteneğine sahiptir(Sağıroğlu vd., (2003).

2016 yılında Nabyev yapay zekâyı; genel olarak, bilgisayar sistemlerine veya makinelere benzer zihinsel becerileri taklit etme veya göstermeleri için tasarlanan teknolojilere sahip bir terimdir. Bu teknolojiler, insan zihni gibi veri analizi, örüntü tanıma, öğrenme, problem çözme ve otomatik karar verme gibi bir dizi görevini yerine getirebileceği şeklinde tanımlamaktadır.

2018 yılında Li ve arkadaşları yapay zekâyı; insan ve insan benzeri türlerin zekâ sının makineler tarafından hemen hemen aynı performansı gösterebilmesidir. Yapay zekâ, insanların elde ettiği zekâyı gereklerini yapabilen makinelerin bilimi olarak yetiştirmektedir(Li vd., 2018).

Minsky'nin“Yapay zekâ, insanların elde ettiği zekâyı gereklerini yapabilen makinelerin bilimidir” (Minsky, 1968) ifadesiyle etmektedir.

2020 yılında Paksın yapay zekâyı; insanların zihin yolu ile ortaya çıkardığı fikir ve tavırların başka bir insana gerek kalmadan makinelerin yapabilme teknolojisi olarak tanımlamıştır.

2019 yılında Gunning ve arkadaşları yapay zekâyı; açıklanabilir yapay zekâ kavramı içerisinde açıklamıştır. Anlaşılabilir ve açıklanabilir yapay zekâ

kavramındakabiliyetlerin ve zihniyetlerin anlaşılır ve açıklanır olması ilkelerine sahip olması gerekmektedir. Bireylerin anlık ve gelecekteki davranış biçimlerinin nasıl olacağının açıklanması ve bu parametrelere bağlı kalması beklenmektedir. Bu bağlamda insan zekâsının çalışmasının sonucunu oluşturan düşünsel ürünün eklenmesi ile yapay zekâ sisteminin vazife, kabiliyet ve beklentilerinin bir bütünü sağlayabilme yeteneğine sahip olmasıdır. Bu sayede tıpkı insan zihni gibi makinenin yorumlama ve sonuç elde etmesi beklenebilir. Yoruma dayalı modellerin gelişiminin genelinde açıklamalar sunulurken, açıklanabilir modellerin tamamen anlaşılır olması gerektiği düşünülmektedir (Gunning, ve diğerleri, 2019, s. 2).

4.1. YAPAY ZEKA TARİHÇESİ

Yapay zekâ kavramı ve ilk etkileri geniş bir zaman dilimine yayılmıştır. İnsanların yapay zekâyâ ilişkin kazanımları ve çalışmaları binlerce yıl öncesine kadar uzanmaktadır, ancak modern yerleşik yapay zekâ araştırmaları ve ilk etkileri 20. yüzyılda başlamıştır.

1940'larda, Alan Turing ve diğer bilim insanları, bilgisayarlar üzerinde düşünen makinelerin inşa edebileceğini ortaya koydular. Bu dönemde yapay zekâ araştırmalarının ve bilgisayarlarla ilgili temel kavramların temelleri atıldı.

Yapay zekânın tarihsel gelişimi, 1950'lerden günümüze kadar uzanan bir süreci kapsar. İşte yapay zekânın önemli tarihsel geçmişi:

Dartmouth Konferansı (1956): Yapay zekâ terimi, ilk kez 1956 yılında Dartmouth Konferansı'nda düzenlenen bir konferansta ortaya atıldı. John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon gibi öncü araştırmacılar, yapay zekânın bir bilim alanı olarak kurulması üzerine tartışmalar yaptılar.

Yapay Zekâ ve Uzman Sistemler (1950'ler-1960'lar): İlk yapay zekâ çalışmaları sembolik yapay zekâ olarak bilinir. Bu dönemde, dilbilgisel kuralları ve semboller kullanarak zekâyı taklit etmeye çalışan programlar geliştirildi. Uzman sistemler de bu dönemde popüler hale geldi ve belirli bir uzmanlık alanında insan uzmanların bilgisini kullanarak kararlar verebilen sistemler tasarlandı.

Yapay Zekâ ve Makine Öğrenmesi (1980'ler-1990'lar): Yapay zekâ araştırmaları, sembolik yaklaşımdan bağlamsal yaklaşıma doğru kaymaya başladı. Makine öğrenmesi alanındaki ilerlemelerle birlikte, bilgisayarlar veri analizi yapabilir ve deneyimlerinden öğrenebilir hale geldi. Yapay sinir ağları, genetik algoritmalar ve destek vektör makineleri gibi makine öğrenmesi yöntemleri geliştirildi.

Büyük Veri ve Derin Öğrenme (2000'ler-2010'lar): Bu dönemde büyük veri kavramı ortaya çıktı. İnternet ve diğer dijital kaynaklar aracılığıyla büyük miktarda veri toplanması ve analiz edilmesi mümkün hale geldi. Derin öğrenme yöntemleri, çok katmanlı yapay sinir ağları kullanarak karmaşık veri yapılarını işleme yeteneği sağladı. Gelişmiş bilgisayar gücü ve derin öğrenme algoritmalarının ilerlemesi, görüntü ve ses tanıma, doğal dil işleme ve oyun oynama gibi alanlarda büyük başarılar elde edildi.

Kaliforniya'da düzenlenen konferansta (2009): Asimo isimli robot, bir yapay zekâ çalışmasının örneğidir. Asimo'nun özellikleri arasında yürüme, koşma, merdiven çıkma, dokuları tanıma, insanları tanıma ve etkileşimde bulunma gibi yetenekler bulunur. Sesli komutları anlayabilir ve konuşabilir. Ayrıca dokuları kameralar ve sensörler ile algılayabilen cihazlara sahiptir. Asimo robotu yapay zekâ çalışmaları yürüten bilimciler için devrimsel bir teknoloji olarak görülmektedir. Ancak Asimo kendine önceden öğretilen olaylar karşısında yanıt verebiliyor yani veri tabanına girilmemiş olaylar karşısında yanıt verememektedir. Bu sebepten ötürü programlaması yapılmayan durumlar karşısında yanıt veremeyen bir metal yığının dönüşümüdür (Koyuncu, 2015, s. 23). Günümüzde tartışması sürerken, bir teknolojik gelişmenin yapay zekâ sistemine sahip olabilmesi için makinenin tıpkı insan gibi kendine şans vererek çalışması beklenir. Yani bir gelişmenin yapay zekâ olup olmadığı programın kendi içerisinde inisiyatif alabilme imkânına sahip olması beklenmektedir.

Son yıllarda ise yapay zekâ tekniklerinin bulgularıyla birlikte yapay zekâ daha da etkili hale geldi. Bu teknikler, görüntü ve ses tanıma, otomatik çeviri, bağımsız araçlar, kişisel dijital asistanlar ve daha birçok alanda kullanılmaktadır. Yapay zekânın etkileri, günümüzde giderek artan bir şekilde birçok alanda yayılmaktadır. Örneğin, akıllı telefonlar, otomatik yapılar, kişiselleştirilmiş reklamcılık, müşteri hizmetleri ve sağlık hizmetleri gibi yapay alanlarda kullanılmaktadır.

4.2. YAPAY ZEKA TEKNİKLERİ

4.2.1. Uzman Sistemler


Yapay zekâ teknikleri arasında yer alan uzman sistemler, 1970’li yıllarda geliştirilmiştir. Ticari olarak ilk uygulamasını ise 1980’li yıllarda gerçekleştirmiştir. Uzman sistemler, herhangi bir konu hakkında uzmanlık bilgisine sahip olma faaliyeti ile çalışmaktadır. Yapay zekâ çalışmaları içerisinde yer alan uzman sistemler tekniğinde ele alınan konunun uzman kişiler tarafından çözümlenme imkânı tanımaktadır. Aynı zamanda ele alınan konunun çözüm aşamasında kullanılan geniş bilgi tabanı yelpazesine sahip olması ve tıpkı insan zekâ sının çalışma mantığı ile çalışan bir yapay zekâ tekniğidir.

Uzman sistemler, sistemleri içerisinde çeşitli algoritmaların ve deneyim odaklı çıkarım mekanizmaları da işlem görmektedir. Uzman sistemler, genellikle kural temelli bir yaklaşım kullanır. Bu sistemler, uzmanların bilgi ve deneyim modelini aktaran bir bilgi tabanına dayanmaktadır. Bilgi tabanındaki kural ve açıklamalar, çıkarma yöntemleri tarafından kullanılan ve işletim kararlarını veya çıkışlarını belirler. Sonuç olarak, uzman sistemler yapay zekâ tekniklerini kullanarak belirli bir veri üzerinde karar verme ve çözme becerileri kazandıran bilgisayar tabanlı sistemlerdir(Çoban, 2018, s. 11).

Uzman sistemler, belirli bir dağıtım alanındaki karmaşık parçaları yürütmek veya karar vermek için kullanılan etkili bir araçtır. Prolog ve Lisp gibi diller, uzman sistemlerin bölümleri için kullanılan özel programlama dilleri arasında yer alır. Prolog'un geçiş yapısı, uzman sistemlerin bilgi sunumunu kolaylaştırır. Uzman sistemlerinde, bir arşivlerde veya bilgi veritabanında kullanılan, yöneticilerin sağladığı bilgiler ve kurallar girilir. Bu bilgiler, sistem tarafından sorgulandığında belirli bir soruna veya duruma uygun cevaplar üretebilmek için kullanılır. Prolog, sorgulamaların sonuçlarını elde etmek için bu bilgi tabanını sorgular ve çıkarmalar yapar. Lisp'in biçimlendirme ve yapılandırma hesaplama becerilerini, uzman sistemlerin karmaşık bilgi tabanlarını temsil etmek ve çıkarmaları yapmak için muhafaza edilmesini sağlar. Lisp, uzman sistemlerin yapılandırması ve değerlendirme programlarını yazmak için kullanılabilir(Paksın, 2020, s. 44).Lisp dilini kullanarak AutoCAD içinde otomasyon ve özelleştirmenin nasıl gerçekleştirilebileceğini anlatan bir rehber olarak kullanılmıştır. 2013 yılında yayınlanan "AutoCAD Platform Customization: User Interface, AutoLISP, VBA, and Beyond" adlı kitapta AutoCAD'in kullanıcı arayüzü, AutoLISP, VBA (Visual

Basic for Applications) gibi programlama dilleri ve AutoCAD platformunda özelleştirmenin ötesine geçen konuları kapsar. Kitap, kullanıcıların AutoCAD'i kendi ihtiyaçlarına göre özelleştirmesine ve programlamasına yönelik pratik bilgiler sunar(Ambrosius,2013).

Uzman sistemlerin oluşumu için kapsamlı bir sisteme sahip olması gerekmektedir. Sadece belirli bir unsura bağlı kalmadan geliştirilmesi gereken bir sistemdir. Bu sebeple birden fazla uzmanın deneyimine ihtiyaç duyulmaktadır. Bu gereksinimlerin dışında çeşitli kaynaklardan elde edeceği bilgilere de ihtiyaç duyulmaktadır. Elde edilen bilgilerin, bilgi tabanı sistemine işlenmesi uzman sistemin oluşmasına olanak sağlamaktadır. Bu bilgi verilerinin sisteme işlenmesi işlemini ise ‘Bilgi Mühendisliği’ dalı aracılığı ile yapılmaktadır. Bilgi mühendisi toplanan bilgi verilerinin uzman sistemlere işleme işlemini yapan ve yapay zekâ çalışmalarına katkı sağlayan kişiler olarak bilinmektedir(İçen & Güney, 2014, s. 41).



Şekil 4.1.Uzman Sistemin Elemanları ve Bilgi Akış Diyagramı (Şahin, 2007)

Şekil 4.1.'de uzman sistem elemanlarının çalışma yapısı gösterilmiştir. Uzmanlar tarafından elde edilen bilgi ve deneyimlerin, bilgi mühendisleri tarafından bilgi tabanı işlenmesi ile bilgi tabanı oluşur. Bilgi tabanı, ele alınan problemin çözümü için geniş bir yelpaze kapsamında incelenme işlemini yapmaktadır. Bilgi tabanı, verilerin ve kuralların olduğu tabanı oluşturur. Çıkarım mekanizması, bilgi tabanının ve kurallar tabanının meydana getirmiş olduğu sorunlar için çözüm önerisinin ne zaman ve nasıl bir öneri sunacağına karar vermektedir. Kullanıcı ve çıkarım mekanizması arasındaki

iletişimi kullanıcı ara birimi tarafından gerçekleştirilmektedir (Avşar, 2020).

4.2.2. Makine Öğrenmesi

Arthur Samuel tarafından 1959 yılında dile getirilen makine öğrenmesi, bir bilgisayar veri analizini yaparak kendi üretimini geliştirmesine olanak tanıyabilen bir alan olarak tanımlandı. Makine öğrenmesini, bilgisayarların belirli yöntemlerini kullanmak için programladığı yerine, veri analizi ve deneyimle öğrenme yeteneklerine sahip olabileceğini vurguladı(Ayodele, 2010).

Makine öğrenmesi, bir bilgisayarın veri analizi yaparak deneyimlerden öğrenmesini ve belirli bir görevi gerçekleştirmek için algoritma ve istatistiksel modelleri kullanmasını sağlayan bir yapay zekâ dalıdır. Makine öğrenmesi, bilgisayarlara belirli bir algoritma yerine verilere dayalı olarak öğrenme yeteneği kazandırarak, verilerdeki desenleri tanımlamak, tahminler yapmak, sınıflandırmalar yapmak ve kararlar vermek gibi çeşitli görevleri gerçekleştirebilir. Makine öğrenmesi, bilgisayara saniyeler içerisinde milyonlarca işlemin yalın ve hızlı bir şekilde çözümlenmesini sağlayan algoritmalarıdır(Alpaydın, 2010; Aykul, 2019).

Makine öğrenmesi, matematiksel ve istatistiksel prensipleri temel alır. İşte makine öğrenmesinde kullanılan bazı matematiksel ve istatistiksel kavramlar: İstatistik, istatistiksel yöntemleri kullanarak verilerdeki desenleri belirlemek, olasılık dağılımlarını tahmin etmek ve sonuçları istatistiksel olarak değerlendirmek için istatistiksel yöntemlerden yararlanır. Lineer cebir, verileri vektör veya matris olarak temsil eder ve lineer cebir kullanarak veri manipülasyonu, boyut indirgeme ve özellik çıkarımı gibi işlemleri gerçekleştirir. Olasılık kuramı, verilerdeki olasılık dağılımlarını modellemek için olasılık kuramı kavramlarını kullanır. Optimizasyon, modelin performansını en üst düzeye çıkarmak veya hatayı en aza indirmek için optimizasyon yöntemlerini kullanır. Regresyon, regresyon analizini kullanarak verilerdeki ilişkileri modellemek ve bağımlı değişkenin değerini tahmin etmek için regresyon algoritmalarını kullanır. Sınıflandırma, verileri farklı sınıflara ayırmak için istatistiksel yöntemler ve sınıflandırma algoritmaları kullanır(Elmas, 2019; Schapire 2003).

Günümüzde fazla sayıda verinin olması ve bu verilerin işlenebilmesi için bilgisayar teknolojilerine olan ihtiyacı doğurmuştur. Bu sayede bilgisayar teknolojilerinin gelişimi

artış göstermiştir. Bilgisayar teknolojilerindeki bu gelişme makine öğrenmesi teknolojisinin de gelişmesine katkı sağlamıştır. Teknolojik gelişmelerin zamanla daha da artması yapay sinir ağları, örüntü tanıma, istatistik vb. araştırma alanları ile bağlantı kurması ile makine öğrenmesi çeşitli alanlar ile birlikte çalışmaya başlamıştır. Böylelikle makine öğrenmesi teknolojisi bilgi tabanlarında bilgiye ulaşma, robot kontrollerinin yapılması, dil geliştirme gibi sorunların çözülmesi için çalışmaya başlanmıştır(Dietterich 1997; Çoban, 2016).

2020 yılında Batta Mahesh'in yapmış olduğu çalışmada makine öğrenmesinin tanımını: bilgisayar teknolojilerini programlanmadan verilen görevi gerçekleştirmek için algoritmik ve istatistiksel sistemlerin kullanılması şeklinde yapmıştır. İnternet tarayıcıları üzerinden gerçekleştirilen bir aramada, arama motorunun en iyi sonucu vermesi ve bu sıralamayı yaparken konu ile alakalı içeriğin en üstte yer almasını sağlamak makine öğrenmesinin bir öğrenen algoritma olduğunu göstermektedir. Bu algoritmalar çeşitli amaçlara yönelik kullanılabilir. Makine öğrenmesi teknolojinin en avantajlı yönü ise bir algoritma verisinin hangi işlevde kullanıldığının öğrenilmesi ile oluşmaktadır. Çünkü öğrenmiş olduğu işlevi ihtiyaç halinde otomatik olarak kullanacaktır (Mahesh, 2020).


4.2.3. Genetik Algoritma

Genetik algoritma kavramı ilk 1967 yılında Baglev tarafından yayınlanmıştır. Fakat genetik algoritma çalışmaları ilk John Holland tarafından 1975 yılında "Adaptation in Natural and Artificial Systems" adlı yayınlanan çalışmayla birlikte yayınlandı. Bu kitap, genetik bakış açısı kavramını ve temel ilkelerini ayrıntılı bir şekilde açıklamış ve bakış açısının nasıl ele alındığına dair bir temel oluşturmuştur. Holland evrim sürecinin bakış açısını bilgisayar ortamına aktararak makine öğrenmesine katkı sağlamıştır. Yürütülen araştırmalar, geniş bir uygulama yelpazesi bulma ve çeşitli disiplinlerde kullanma imkânı sunmuştur. Genetik optimizasyon; mühendislik, yapay zekâ, ekonomi, biyoloji ve diğer birçok alanda başarılı sonuçlar elde etmek için kullanılan bir araç haline geldi. John Holland'ın 1975 yılındaki yayını, daha sonra birçok araştırmacı ve bilim insanı tarafından geliştirildi. Bugün genetik görüntüleme, evrimsel hesaplama ve yapay zekâ alanında önemli bir optimizasyon tekniği olarak kabul edilmektedir(Holland, 1975:2).

Genetik algoritma, kompleks optimizasyon sorunlarının çözülmesi için kullanılan bir teknolojidir. Bir sorunun çözülmesi için öncelikle gelişigüzel bir biçimde başlangıç çözümü belirlenir. Bu çözümlerin birbiri ile birleşerek başarımları yüksek çözümler üretmektedir. Bu sayede çözümler kendi aralarında sürekli birleşerek yeni ve başarımları yüksek çözümler aranır. Bu döngü en iyi sonucu üretinceye kadar devam etmektedir.

En iyi sonucun belirlenmesindeki kromozomlar çaprazlama ve mutasyonda evreleri sonrasında üretilen kromozom sayısı artış gösterecektir. Bu artış programın en iyi çözümünün belirlenmesi için seçilecek olan sonucun havuzdan gelme olasılığını arttırır. İyi olmayan sonuçlar da seçilebilir. Seçilen kromozomların kötü olması sonrasında gelebilecek iyi sonuçlar sayesinde de gerçekleşebilmektedir (Öztemel, 2003).

Genetik algoritma yöntemi günümüze kadar geliştirilerek günlük, iş servisleri, lojistik planlama, üretim programlama, veri madenciliği, inşaat teknolojileri, mimari vb. pek çok alanda faaliyet göstermektedir. Genetik algoritmanın çalışma mantığı genel olarak aynı şekilde ilerlemekle birlikte, çözümlenmesi istenilen sorunun kullanıcı tarafından belirlenen şemaya göre de sonuç elde edebilmektedir. Program elindeki sorun için gerekli olan adımları uygular ve çözüme ulaştırır. Bu sebeple her bir sorunun genetik algoritması kendine hasır(Şahin,2007).



Şekil 4.2. Genetik Algoritma Elemanlarının Çalışma Diyagramı (Şahin, 2007)

Şekil 4.2.'de gösterilen Genetik algoritma elemanlarının çalışma diyagramı aşağıdaki adımları içerir:

Başlangıç Popülasyonu Oluşturma: Optimizasyon sorununa uygun bir şekilde başlangıç popülasyonu oluşturulur. Popülasyon genellikle rastgele seçilen bireylerden oluşur.

Uygunluk Değerlerinin Hesaplanması: Her birey için uygunluk değeri hesaplanır. Uygunluk değeri, bireyin optimizasyon problemine ne kadar iyi uyum sağladığını gösterir. Uygunluk değeri, problem bağlamına göre belirlenir.

Seçim: Seçim operatörü kullanılarak uygunluk değerlerine dayalı olarak bireyler seçilir. Daha uygun bireylerin seçilme olasılığı daha yüksektir. Seçim işlemi, doğal seleksiyonun prensiplerine benzer şekilde gerçekleştirilir.

Çaprazlama (Crossover): Genetik algoritmaların temel bir adımıdır ve genellikle doğal seçim ve genetik çeşitliliği taklit eder. Bu süreçte, seçilen iki veya daha fazla bireyin genetik bilgileri birleştirilerek yeni bireyler oluşturulur. Çaprazlama işlemi, bireylerin genetik materyallerini belirli bir noktadan keserek ve bu kesim noktası üzerinde genetik bilgileri değiştirilerek gerçekleştirilir.

Mutasyon: Oluşturulan yeni bireyler üzerinde mutasyon işlemi gerçekleştirilir. Mutasyon, genetik materyalde rastgele değişiklikler yaparak çeşitliliği artırır. Mutasyon işlemi, bireylerin potansiyel olarak daha iyi çözümleri keşfetmesine olanak sağlar.

Yeni Popülasyonun Oluşturulması: Çaprazlama ve mutasyon işlemleri sonucunda elde edilen yeni bireyler, başlangıç popülasyonuna eklenir. Elde edilen yeni popülasyon, bir sonraki iterasyon için kullanılacak popülasyonu oluşturur.

Durma Koşulunun Sağlanıp Sağlanmadığının Kontrol Edilmesi: Belirli bir durma koşulu sağlanana kadar adımlar 2-6 tekrarlanır. Durma koşulu genellikle belirli bir iterasyon sayısı veya uygunluk değeri eşiği olarak belirlenir.

En İyi Çözümün Belirlenmesi: Son popülasyondaki bireyler arasından seçilmesi ile belirlenmektedir.

5. YAPAY SINİR AĞLARI

Yapay Sinir Ağları, insan beynini taklit edebilme özelliği gösteren bir algoritma türüdür. İnsan beyninin öğrenme yapısından esinlenerek çalışmaktadır. Yapay sinir ağında tıpkı insan beynindeki nöronlar gibi bilgi ve deneyimleri işlemektedir. Yapay sinir ağına işlenen bilgi ve deneyimler, karşısına çıkabilecek sorun veya isteklerin çözümü için işlenmektedir. İşlenen bilgilerin analiz edilerek probleme uygun çözüm üretme yöntemidir.

İnsan beyninde milyarlarca nöron bulunmaktadır. Bu nöronlar birbirine bağlanarak sinir ağlarını oluşturmaktadırlar. Yapay sinir ağları da tıpkı insan beyninde bulunan nöronları taklit ederek makinelerin analiz yapmasını ve problem karşısında çözüm üretebilmesi için geliştirilmiştir(Techopedia, 2022).

Yapay sinir ağ sisteminde tıpkı insan beyninde bulunan nöronların yapısında bulunan birbirine bağlanma noktaları ve belirli katmanları bulunmaktadır. İnsan beyninin çalışma prensibinde veriler dağınık bir şekilde beyin içerisinde bulunur. Veriler ihtiyaca yönelik hafızadan çıkarılır ve bir araya getirilerek kullanılır. Tıpkı insan beyninin çalışma prensibini kendine örnek alan yapay sinir ağı, biriktirdiği verileri ihtiyacı olduğu durumlarda işlenecek verileri bir araya getirerek işlemektedir(Maind ve Mankar, 2014).

Yapay sinir ağları tıpkı insan beyninin çalışma prensiplerini ve öğrenme yetkinliklerini simüle etmektedir. Yapay sinir ağının insan gibi düşünebilen bilgisayar tabanını kurulurken, insan beyni öğrenme ve karar verme evrelerinde nöronların birbiriyle kurduğu ilişki taklit edilir.

Yapay sinir ağları, yapay sinir hücrelerinden (veya nöronlardan) oluşur. Bu yapay sinir hücreleri, biyolojik sinir hücrelerine benzer şekilde birbirleriyle bağlantılar kurarlar. Yapay sinir hücreleri, bir hiyerarşi veya paralel şekil içinde düzenlenebilirler. Hiyerarşi çalışma mantığında hücrelerin diğerlerine bağlı olduğu ve bilginin bu bağlantılar aracılığıyla aktarıldığı anlamına gelir. Bu bağlantılar, verileri işlemek ve öğrenmek için

kullanılır. Paralel şekildeki çalışma mantığında ise, ağın aynı anda birden fazla işlemi eşzamanlı olarak gerçekleştirebileceği anlamına gelir. Bu, yapay sinir ağlarının özellikle büyük ve karmaşık verileri işlemek için etkili olmalarını sağlar. Yapay sinir hücreleri arasındaki bağlantıların her birinin bir değeri vardır. Bu değerler, hücreler arasındaki iletişimin gücünü temsil eder. Bu bağlantı değerleri, ağın öğrenme süreçleri sırasında güncellenebilir ve bilgiyi temsil etmek için kullanılır. Yapay sinir ağı, bu yapay sinir hücrelerinin bir araya gelerek oluşturduğu bir ağıdır. Bu ağ, verileri işlemek, öğrenmek ve çeşitli görevleri gerçekleştirmek için kullanılır(Öztemel, 2003).

5.1. YAPAY SİNİR AĞLARI TARİHÇESİ

Yapay sinir ağları alanında birçok disiplinde çalışmalar yürütmüş araştırmacıların çalışması sonucunda ortaya çıkmıştır. İnsan beyninin çalışma prensibini örnek alan bu yapay ağ sistemleri, öğrenme ve karar verme yeteneklerini bilgisayar sistemleri üzerinden gerçekleştirmeyi amaçlamaktadır. Yapay sinir ağ sistemlerinin gelişme süreci:

1943 McCulloch-Pitts Modeli: Birinci Dünya Savaşı sonrasında sinir hücrelerinin çalışma şekillerini anlamaya yönelik araştırmalar yapılırken, 1943 yılında Warren McCulloch ve Walter Pitts, sinir hücrelerinin basit bir matematiksel modelini tanıttılar. Bu model, sinir hücrelerinin elektriksel aktivitelerini ikili (0 ve 1) sinyallerle temsil ederek, giriş sinyallerinin ağırlıklı toplamını hesaplayarak bir çıktı üretmekteydi. Bu çalışma, yapay sinir ağlarının temelini atmıştır.

1949 Hebbian Öğrenme Kuralı: Donald Hebb, sinir ağlarının öğrenme sürecine katkıda bulunan Hebbian öğrenme kuralını geliştirdi. Bu kural, sinir hücrelerinin bağlantılarının güçlenmesi veya zayıflamasına dayanan bir öğrenme mekanizması tanımlamıştır.

1958 Perceptron(Algılayıcı): Frank Rosenblatt, ilk kez perceptron adı verilen bir yapay sinir ağı modelini tanıttı. Perceptron, girdileri ağırlıklarla çarparak bir çıkış üreten basit bir sinir ağıydı ve ağırlıkları güncellemek için öğrenme kuralını kullandı.

1986 Geri Yayılım Algoritması: Yapay sinir ağlarının popülerliği, 1986 yılında David Rumelhart, Geoffrey Hinton ve Ronald Williams tarafından geri yayılım algoritmasının tanıtılmasıyla büyük bir artış yaşadı. Geri yayılım algoritması, ağırlıkları ayarlamak için

hata geri yayılımını kullanır ve ağı eğitimi gerçekleştirir. Bu algoritma, çok katmanlı yapay sinir ağlarının eğitiminde büyük bir ilerleme sağladı ve yapay sinir ağlarının daha karmaşık problemleri çözebilme yeteneği arttı.

1989 Evrişimli Sinir Ağları (CNN) :Evrişimli sinir ağları, özellikle görüntü işleme alanında önemli bir rol oynamaktadır. Yani, LeCun, YoshuaBengio ve Geoffrey Hinton tarafından 1989 yılında tanıtıldı. Evrişimli sinir ağları, veri üzerinde konumsal desenlerin algılanmasına odaklanır ve konvolüsyon operasyonlarını kullanarak veriyi işler. CNN'ler, görüntü sınıflandırma, nesne tanıma ve diğer birçok görsel görevde olağanüstü başarı elde etmiştir.

1986-1993 Yinelemeli Sinir Ağları (RNN): Yinelemeli sinir ağları, zaman serileri, metinler ve dil modelleri gibi zamanla bağlantılı verilerin işlenmesinde kullanılır. RNN'ler, geçmiş bilginin mevcut duruma geri beslenmesine izin veren döngüler içeren yapılardır. 1986'da tanıtılan Elman ağı ve 1993'te Hopfield ağı gibi bazı RNN modelleri önemli adımlardır.


2010'lar, Derin Öğrenme ve Yapay Sinir Ağlarının Yeniden Popülerleşmesi: Derin öğrenme, yapay sinir ağlarının daha derin ve karmaşık yapılarla donatıldığı bir alanı ifade eder. Gelişmiş hesaplama gücü, büyük veri kümeleri ve daha iyi algoritmaların ortaya çıkması, derin öğrenmenin yeniden popüler hale gelmesini sağladı. Derin sinir ağları, evrişimli sinir ağları (CNN'ler) ve rekurrent sinir ağları (RNN'ler) gibi yapay sinir ağı türlerinin daha karmaşık ve etkili versiyonlarını içerir.

Bu tarihsel gelişim süreci, yapay sinir ağlarının kullanım alanlarını genişletmiş ve onları bugün gördüğümüz karmaşık problemleri çözme kapasitesine sahip bir yapay zekâ alanı haline getirmiştir. Yapay sinir ağları, görüntü ve ses tanıma, doğal dil işleme, tahmin analitiği, oyun yapay zekâsı ve daha birçok alanda başarıyla uygulanmaktadır.

5.2. BİYOLOJİK SİNİR HÜCRE YAPISI

İnsan beyninin çalışmasını sağlayan en temel unsurlardan birisi biyolojik sinir ağlarıdır. Canlıların davranışlarını ve çevre etmenlere karşı algılayabilme mekanizmasını sağlar. Biyolojik sinir ağlar veriyi öğrenme, işleme ve çözüm üretme mekanizmalarını sinir sistemlerin arasındaki iletişim ağlarını kullanarak öğrenirler. İnsan beyni, beş duyu

organı sayesinde deęişik veri alır ve bu verilerin fonksiyonuna g re iřler. Beř duyu organından gelen veriler, sinir sistemine iletilmesi ile beyne tařınır ve beyin veriler doęrultusunda oluřan kararı sinir sistemi ile v cuda ileterek eylem ger ekleřir. Bir sinir h cresi “řekil 5. 1. ’de řematik olarak g sterilmektedir.



řekil 5.1. Biyolojik sinir h cresi ve yapay sinir aęı (Maltarollo, 2013).

řekil 5.1.’de g sterildięi gibi temel bir biyolojik sinir h cresi snapsler, soma, axon ve dentrite’lerden oluřmaktadır. Sinir h creleri, v cuttaki bilgi alıřveriři ve iletiřim i in  zel olarak adapte edilmiř h crelerdir. Bu h creler arasındaki baęlantılar "sinaptik baęlantılar" olarak adlandırılır. Bu baęlantılar, fiziksel bir baęlantı olmadan, bir h creden dięerine elektrik sinyallerinin ge mesini saęlayan bořluklar veya aray zlerdir. Sinir h cresinin ana bileřenleri řunlardır:

Soma: H crenin g vdesi olarak bilinir ve gelen elektrik sinyallerini iřler.


Axon: H crenin uzun  ıkıntısıdır ve kendi elektrik sinyalini oluřturur. Bu sinyali ileterek dięer sinir h crelerine iletilmesini saęlar.

Dentritler: H crenin dięer h crelerden gelen sinyalleri almasına yardımcı olur. Sinir h creleri arasındaki iletiřim, sinaptik baęlantılarda ger ekleřir.

Bu baęlantılarda, bir sinir h cresinin axon ucu, dięer bir h crenin dentritlerine veya somasına yakın bir b lgeye gelir. İki h cre arasındaki bilgi alıřveriři, sinaptik bořluęa salınan kimyasal maddeler olan "neurotransmitter'lar" aracılıęıyla saęlanır. Neurotransmitter'lar, sinir h creleri arasındaki iletiřimi bařlatmak veya durdurmak i in kullanılır(Maltarollo, 2013).

5.3. YAPAY SİNİR AĞ ELEMANLARI

Biyolojik sinir ağı, insan veya diğer canlıların sinir hücrelerinden oluşur. Yapay sinir ağı ise bilgisayar programları veya algoritmaları tarafından simüle edilen yapay sinir hücreleri kullanır. Her iki tür sinir ağının da temel yapı taşı olarak sinir hücrelerini benzer bir şekilde kullanır ve bu nedenle benzerlik gösterirler. Yani yapay sinir ağı, biyolojik sinir ağlarının ilham aldığı bir yapısı kullanır. Yapay sinir hücreleri 5 temel proses elemanından oluşur. Şekil 5.2.'de yapay sinir ağ yapısı gösterilmiştir.



Şekil5.2. Yapay Sinir Ağ Yapısı (Şahin,2005).

- **Girdiler**

Yapay sinir ağ sinir hücrelerinin bilgilerinin öğrenmesini sağlayan girdi verileri olup bu bilgileri dış etmenlerden veya sinir hücreleri arasındaki iletişim ile elde edilebilir. Dışarıdan gelen veriler, yapay sinir ağının öğrenilmesi istenilen örneklemelere benzer veriler ile öğretilir(Özdemir,2015).

- **Ağırlıklar**

Yapay sinir ağı hücresinin verilerinin ağırlıkları girilen verinin önemini ve ağ sistemi üzerindeki etki alanının anlaşılması içindir. Ağırlık verilerinin büyük veya küçük değerlere sahip olması ağ sisteminde önemli veya önemsiz olduğu anlamına gelmemektedir. Ağ sisteminde ağırlık değerinin sıfır olması ağ sistemi için önemli veya önemsiz olabilir. Ağırlık değerlerinin eksi veya artı bir değere sahip olması ağ sistemi üzerine etkisinin pozitif veya negatif etkisini göstermektedir. Sıfır değerine sahip bir ağırlık değerinin ise ağ sistemi üzerine etkisinin olmadığı anlamını taşımaktadır.

- **Toplama Fonksiyonu**

Toplama fonksiyonu, hücreden gelen girdileri hesaplar. Girdinin hesaplanması için

farklı fonksiyonlar kullanılmaktadır. En fazla kullanılan fonksiyon ise ağırlık toplama yöntemidir. Bu yöntemle girilen verinin değeri ile ağırlık çarpılarak toplanır. Bu sayede ağırlık net girdi değeri ortaya çıkmış olur. Bu şu şekilde formülize edilmektedir.

$$NET = \sum_{i=1}^n G_i A_i$$

G sembolü girdileri, A ise ağırlıkları, n ise bir hücreye gelen toplam girdi (proses elemanı) sayısını göstermektedir. Uygulanan formül projenin modeline göre değişmektedir. Bir yapay sinir ağı modeli için uygun olan toplama fonksiyonun elde edilmesi deneme yanılma yöntemi ile gerçekleştirilir. Yapay sinir ağında bulunan proses elemanlarının toplama fonksiyonları aynı veya farklı olabilmektedir. Tasarlanan sinir ağının öngörülerine dayanarak karar verilir.

- **Aktivasyon Fonksiyonu**

Yapay sinir ağlarında aktivasyon fonksiyonları, her bir nöronun çıkışını hesaplarken kullanılan matematiksel işlevlerdir. Bu fonksiyonlar, sinir ağı katmanlarının birinden diğerine bilgi aktarırken, girdi sinyallerini dönüştürmek ve öğrenmeyi sağlamak için kullanılır. Aktivasyon fonksiyonları, yapay sinir ağlarının esas bileşenlerinden biridir ve ağırlık karmaşıklığı ve öğrenme kapasitesi üzerinde büyük bir etkiye sahiptir.


- **Hücrenin Çıktısı**

Aktivasyon fonksiyonu çıktı değeridir. Yapay sinir ağının son katmanıdır ve ağırlık tahmin veya sonuç ürettiği yerdir. Çıkış katmanının yapısı, ağırlık ne tür bir probleme çözüm getirdiğine bağlı olarak değişebilir. (Öztemel, 2003)

5.4. Yapay Sinir Ağ Sisteminin Yapısı

Bir yapay sinir ağı, sinir hücrelerinin bir araya gelmesi ile oluşmaktadır. Sinir hücrelerinin bir araya gelmesi düzensiz şekilde gerçekleşmez. Yapay sinir ağı hücreleri çoğunlukla üç katman ve katmanlar arası geçişin paralel olması ile oluşmaktadır.

Katman yapısının görseli aşağıdaki gibidir (Altaş, Gülpınar, 2012).



Şekil 5.3. Yapay sinir ağı yapısı (Yurtoğlu,2005)

5.5. YAPAY SİNİR AĞI MODELLERİ

Yapay sinir ağı modelleri, yapay zekâ alanında kullanılan güçlü öğrenme algoritmalarıdır. Yapay sinir ağları, biyolojik sinir sistemlerinden esinlenerek tasarlanmış matematiksel modellemelerdir. Bu modeller, büyük miktarda veriyi işlemek, karmaşık görevleri çözmek ve desenleri öğrenmek için kullanılırlar(Tüfekçi & Karpat, 2019).


Yapay sinir ağı modelleri, veri madenciliği, görüntü işleme, doğal dil işleme, oyun, yapay zekâ ve daha birçok uygulama alanında kullanılır. Modelin yapısı, veriye, göreve ve performans gereksinimlerine bağlı olarak uyarlanır. Eğitim süreci boyunca model, veriyi kullanarak belirli bir görevi en iyi şekilde çözmek için ağırlıkları ve sapmaları ayarlar.

Yapay sinir ağı modelleri aşağıdaki gibi dört grupta incelenebilir.

- Tek Katmanlı Algılayıcılar
- Çok Katmanlı Algılayıcılar
- İleri Beslemeli Yapay Sinir Ağları
- Geri Beslemeli Yapay Sinir Ağları

5.5.1. Tek Katmanlı Algılayıcılar (Perceptrons):

Bu grup, en temel yapay sinir ağı modellerini içerir. Tek katmanlı algılayıcılar, girdi katmanı ve bir çıkış katmanından oluşur. Genellikle basit sınıflandırma görevlerini çözmek için kullanılır. Ancak, çok karmaşık problemleri çözmek için yetersiz olabilirler(Radhamohan,2010).




Şekil 5.4. Tek Katmanlı Algılayıcılar Modeli (Öztemel, 2006)

Tek katmanlı algılayıcı modelinin çıktısının sıfır olmasının önüne geçen bir eşik girdisi bulunmaktadır. Bu eşik girdisinin değeri daima 1 değerine sahiptir. Ağ çıktısı hesaplanırken, ağırlık değeri ile eşik değerinin toplanması sonucunda elde edilen değerdir. Tek katmanlı algılayıcılar doğrusal bir fonksiyona sahip oldukları için çıktı değerleri 1 veya -1 sonucuna sahip olurlar. Sonuç çıktısı 1 değerine sahip ise birinci sınıfa -1 ise ikinci sınıfa kabul edilmektedir(Öztemel, 2006).

5.5.2. Çok Katmanlı Algılayıcılar (Multilayer Perceptrons - MLP):

MLP'ler, birden fazla gizli katman içeren ve bu katmanlardaki nöronların birbiriyle tam bağlantılı olduğu bir yapay sinir ağı türüdür. Bu katmanlar arasındaki bağlantılar, ağı daha karmaşık ve derin hale getirir. Daha karmaşık problemleri çözmek ve özellikle derin öğrenme için kullanılırlar(Haykin, 2009).

Çok katmanlı algılayıcıların bir giriş katmanı, bir veya birden fazla gizli katmanları ve bir çıkış katmanı olmak üzere birçok katmana sahiptir. Çok katmanlı algılayıcılarda giriş katmanında veri girişinin olduğu yerdir. Çıktı katmanı tercih edilen parametrelere bağlı problemin, ilgili verileri işlemesidir. Çok katmanlı algılayıcıların mimari yapısı aşağıdaki görselde gösterilmektedir.




Şekil 5.5. Çok Katmanlı Algılayıcılar Modeli (Elmas, 2003)

Yukardaki şekilde de görüldüğü gibi katman yapısında yer alan nöronların birbiri arasında bir ilişkisi bulunmamaktadır (Kisi ve Alizamir, 2018). Katmanlarda bulunan veriler, kendinden bir önceki veya kendinden bir sonraki katmanlar aracılığıyla birbirine nöron aktarımı sağlarlar. Bağlantılar sistemin parametrelerini eğitim yoluyla aktarmasıdır (Kisi vd., 2017). Gizli katmanda yer alan nöronların adedi uygulanan her proje için farklılık göstermektedir. Gizli katmanda yer alan nöronların adedi deneme yanılma yöntemi kullanılarak tespit edilmektedir. Girdi nöronlarının ayarlanmasından sonraki adımda, ağ sistemine bağlı gizli katmana ait nöronların eğitilerek çıktı nöronların elde edilmesidir.

5.5.3. İleri Beslemeli Yapay Sinir Ağları (Feedforward Neural Networks):


İleri beslemeli ağlar, verilerin yalnızca bir yönde, girdi katmanından başlayarak çıkış katmanına doğru ilerlediği ağlardır (Arıkan Kargı, 2015: 63). Bilgi bir akış gibi ilerler ve geri besleme döngüleri içermezler. Bu tür ağlar özellikle sınıflandırma ve regresyon görevlerinde yaygın olarak kullanılır (Gültepe, 2019).



Şekil5.6. İleri Beslemeli Yapay Sinir Ağ Modeli (Ballı, 2014)

5.5.4. Geri Beslemeli Yapay Sinir Ağları (Recurrent Neural Networks - RNN):

RNN'ler, sıralı verileri işlemek ve zaman içindeki bağımlılıkları modellemek için kullanılır. RNN'ler, geçmiş durumları ve bilgileri hafızalarında tutarak geri besleme döngüleri oluştururlar. Bu özellikleri sayesinde dil işleme, zaman serisi analizi ve video analizi gibi sıralı veri görevlerinde etkilidirler(Doğan, 2016).



Şekil 5.7. Geri Beslemeli Yapay Sinir Ağ Modeli (Kurnaz 2014).

Her bir grup, belirli görevleri çözmek için özelleştirilmiştir ve farklı türde problemlere uygundur. Hangi yapay sinir ağı modelinin kullanılacağı, çözülmesi gereken göreve, kullanılabilir veriye ve performans gereksinimlerine bağlı olarak değişir.

6. YÖNTEM

Bu çalışmada kullanılan model, mimari ön proje aşamasındaki projelerin plan çizim standartlarına uygunluğunun belirlenmesi için ResNet-50 ve derin öğrenme ağı (DNN) teknolojileri kullanılmıştır. Elde edilen sonuçların analizi yapılmıştır.

Uygulama projesi olarak kabul görülen mimari konut plan proje çıktılarından yararlanılmıştır. Bu konutların mimari projeleri, ön proje aşamasındaki plan çizim standartlarının çeşitli ölçütler belirlenerek girdi verisi oluşturulmuştur. Bu ölçütler ön proje aşamasında yer alan plan çizim standartlarına ait özellikler olup ilgili uzmanların projenin uygunluğunun değerlendirilmesinde göz önüne alması gereken ölçütlerdendir. Projenin analizinin yapılabilmesine sağlayan ölçütler, ön proje çizim standartlarından olan bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi özellikler olarak belirlenmiştir. Bu değerler DNN ve ResNet-50 kombinasyonu kullanarak yapay zekâ teknolojisi geliştirilmiştir. Konut planlarına ait değerlendirmede, ön proje çizim standartlarının özellikleri dikkate alınarak proje çıktısının geçerlilik ve geçersizlik yüzdeleri elde edildi. Bu konut planlarının, çizim standardını sağlayan ölçütlerin analizinin yapılması, bu planların çıktı vektörünün elde edilmesine olanak sağlamıştır.

Ağ mimarisinde yer alan geçerli ve geçersiz proje çıktılarının bulunduğu klasör girdileri test edilecek verilerin değerlendirilmesi için analiz edilmiştir. ResNet-50 ve DNN kombinasyonu projenin geçerli ve geçersiz olarak kabul edilen klasör dosyalarının eğitilmesi ile test edilecek verilerin standartların kontrol edilmesine olanak sağlamıştır. Geçerli proje klasöründe kabul görülen ön proje plan çıktısında, bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi özelliklere sahip proje çıktıları yer almaktadır. Geçersiz proje klasöründe ise ön proje standartlarında yer alan çizim ölçütlerinden bir veya daha fazlasının eksik olduğu projeler yer almaktadır. Elde edilen yapay zekâ modelinden sonra test için ayrılan test verisi klasörü ağ sistemine gösterilip analiz edilmiştir. Analiz edilen test verilerinin çıktı değerlerinin geçerli veya geçersiz proje yüzdeliği projenin ön proje standartlarında yer alan çizim ölçütlerine uygunluğu ağ sistemi tarafından sonuçlanmaktadır. Elde edilen sonuç değeri,

izim ltlerinin saėlanıp saėlanmadıėının karřılařtırılmasını yapay zekâ ynteminin performansının deėerlendirilmesi amalanmıřtır.

Konut projelerinin plan izimlerinin izim standartlarına uygunluėuna ynelik deėerler tespit edilmiř, yapay zekâ yntemi esas alınarak kullanılan ResNet -50 ve DNN kombinasyonunun belirlenen girdi vektr ltlerinin konut planlarının izim standartlarının saėlanıp saėlanmadıėının analizi yapılmıřtır.

Uygulanan yntemlerin sonunda elde edilen sonulara gre n proje konut planı izimlerinin uygunluk deėerlerinin yapay zekâ yntemi ile tahmin edilebilirlik konusunda deėerlendirme yapılmıřtır. Yapay zekâ yntemi kullanılarak proje planlarının izim standartlarına uygunluėunun deėerlendirmeleri ile benzer sonular gstermesi, bu alıřma ynteminin kullanımı ile projelerin incelenme srecini hızlandırmasına ve maliyetlerin azaltılmasına olanak saėlayacaėı dřnlmřtr.


6.1. UYGULAMA VERİLERİNİN ELDE EDİLMESİ

Bu alıřmada, Dzce niversitesi, Sanat, Tasarım ve Mimarlık Fakltesi, Mimarlık Blm 4. sınıf ėrencilerinin mimari uygulama projesi dersi kapsamında izmiř oldukları konut projelerinin ıktıları kullanılmıřtır. AutoCad dosyası olan dosyaların planları grsel haline getirilmiřtir. Proje izim dosyalarında yer alan zemin kat planı ve zemin st planları řeklinde plan bazında deėerlendirilmeye alınmıřtır. Elde edilen veri seti dosyalarında bazı ėrencilerin her kat iin ayrı plan alıřması bulunurken bazı ėrencilerin ise tek bir kat planının olduėu gzlemlenmiřtir. Bu kriterlere bakılarak eėitim verisi iin proje grsel sayısı 171 adet olarak belirlenmiřtir. Eėitim verisi proje izimlerinin grsellerinin deėerlendirilmiř olup 101 grselin geerli, 70 grselin ise geersiz olduėu bir eėitim seti oluřturuldu.

Tm konut proje planlarının n proje izim standartlarından olan bakıř yn, llendirme, mahal ismi ve m², modl ve inřai akslar, tefriřler gibi zelliklerinin olup olmaması projenin geerliliėi veya geersizliėi hakkında bilgi vermiřtir.

Veri seti, eėitim ve test verisi řeklinde gruplanmıřtır. Eėitim seti, ėrenmenin gerekleřmesi iin kullanılırken bir kısmı da test verisi olarak kullanılmıřtır. Veri seti kendi ierisinde %85'i eėitim verisi olarak ayrılırken %15'i de test verisi olarak

ayrılmıştır. Şekil 6.1.'de yer alan görsellerin solda bulunan çizim planının, çizim standartlarından geçerli olan proje planı iken sağda bulunan çizim planı ise çizim standartlarında geçersiz olarak kabul görülen plan görsellerini içermektedir.




Şekil 6.1. Konut planı görüntüleri

Konut planları uygulama öncesi veri haline gelmesi için ön işleme işlemi yapılmıştır. Ön işleme işlemleri aşağıdaki gibidir.

- 1. Adım:** İlk olarak AutoCad dosyası şeklinde olan plan dosyalarını görsel hale getirerek görüntü eğitme işlemi için aynı standarda getirmektir. Bu sayede uygulama için gerekli görseller elde edilmiştir. DWG (DraWinG) uzantılı dosyalar önce PDF (PortableDocument Format) dosyası şeklinde oluşturuldu. Daha sonra PDF dosyaları da PNG (Portable Network Graphic) veya JPEG (JointPhotographicExpertsGroup) hale getirilmiştir.
- 2. Adım:** Uygulamanın eğitilmesi için görsellerin incelenerek eğitim seti içerisinde geçerli ve geçersiz dosyası oluşturularak görseller ayrıştırıldı. Geçerli plan

görselleri dosyasında 101 adet görsel bulunurken geçersiz plan görsellerinde 70 adet görsel bulunmaktadır. Şekilde 1 de geçerli planların görseli yer alırken şekil 2 de ise geçersiz plan dosyası görselleri yer almaktadır.






Şekil 6.2. Geçerli plan görselleri



Şekil 6.3. Geçersiz plan görselleri

3. **Adım:** Eğitim seri için ön işleme adımı geçerli ve geçersiz dosyası ayrı şekilde oluşturulmuştur. Bu adımda Visual Studio Programında DNN ve ResNet-50 modeli kullanılarak görsellerin eğitilme işlemi için dosya seçimi yapılmıştır. Şekilde eğitim verisi için gerekli görsellerin klasör dosyası görüntüleyicide gösterilmiştir.



Şekil 6.4. Eğitim verisinin yüklenmesi

Ön proje plan çıktısında, bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi özelliklere sahip proje çıktı görseli 101 adet iken, belirtilen ölçütlerin bir veya daha fazlasının eksik olduğu proje görüntü sayısı ise 70 adettir. Test verisi olarak kullanılan 26 adet konut planı kullanılmıştır. Tabloda veri setine dair sayısal bilgilendirmeye yer verilmiştir.


Çizelge 6.1. Veri seti ve İçerik Bilgisi

İçerik Bilgisi	Eğitim Verisi(%85)	Test Verisi(% 15)
Uygun Kabul Görülen	101	7
Uygun Kabul Görülmeyen	70	19
Toplam Veri	171	26

3.2.Model

Bu çalışmadaki model, mimari konut plan çizimlerinin ön proje aşamasındaki çizim standartlarına uygun olup olmadığının ayırımı yapmak için Visual Studio programında Resnet-50 ve DNN (derin sinir ağı) kombinasyonu kullanılmıştır. Bu uygulamada konut planı görsellerinin eğitilmesi ve sonrasında test verilerinin analiz edilmesi için ResNet-50 ve DNN kombinasyonu kullanıldı.

Visual Studio, Microsoft'un geliştirme ortamıdır ve genellikle C++, C#, Visual Basic gibi programlama dilleriyle kullanılır. ResNet-50 ise derin öğrenme (deeplearning) için popüler bir evrişimli sinir ağı (convolutionalneuralnetwork - CNN) modelidir(He, Zhang et al. 2016). Microsoft'un geliştirdiği RestNet-50 ilk 34 katmanlı ağ mimarisi Şekil 6.5.'de gösterilmiştir.




Şekil 6.5. Microsoft RestNet-50 ağ mimarisi(He, Zhang et al. 2016)

ResNet-50, özel "kalıntı blokları" kullanır. Bu bloklar, girdiyi sonuçla toplar, girdinin doğrudan çıkışa eklenmesini sağlar. Bu, gradyanların daha iyi geriye yayılmasına yardımcı olur. ResNet-50, çok sayıda kalıntı bloğunu birleştirerek ağı daha derin hale getirir. Daha fazla derinlik, daha fazla karmaşıklık ve özelliklerin öğrenilmesi anlamına gelir. ResNet-50 içinde, 1x1 boyutlu evrişim katmanları kullanılır. Bu küçük boyutlu evrişim katmanları, özellik haritasının boyutunu değiştirmez, ancak kanal sayısını ayarlamak için kullanılır. Bu, daha fazla esneklik sağlar ve ağın daha etkili bir şekilde özellikleri çıkartmasına olanak tanır. ResNet-50'nin sonunda, tüm özellik haritası kanallarının ortalamasını almak için global ortalama havuzlama katmanı kullanılır. Bu, her özellik haritasının özetini çıkartır ve sonuçları sınıf tahminlerini üretmek için kullanılır(He, Zhang et al. 2016).

Visual Studio, ResNet-50 ve DNN (Derin Sinir Ağı) kombinasyonu, derin öğrenme modelini geliřtirmek, eğitmek ve dağıtmak için kullanılabileceğiniz bir dizi yazılım aracını birleřtirir. Bu kombinasyon, görüntü sınıflandırma, nesne tanıma veya diğerk görsel işleme görevlerini gerçekleřtirmek için güçlü bir yaklaşım sunar. Ařağıda bu kombinasyonu kullanarak projenin nasıl geliřtirildiğinin adımları verilmiřtir:

1. Visual Studio Kurulumu: Microsoft web sitesinden Visual Studio'yu indirip kurulumu yapıldı.
2. Proje Oluřturma: Visual Studio üzerinde yeni bir proje oluřturuldu. Bu proje türüne göre, Visual Basic (VB.NET) dili seğıilmiřtir.
3. Derin Öğrenme Kütüphanesi: ResNet-50 modelini kullanmak için bir derin öğrenme kütüphanesine ihtiyaç duyulmaktadır. Microsoft'un TensorFlow Kütüphanesi ile desteklenmiřtir.
4. ResNet-50 Modelinin Yüklenmesi: Derin öğrenme kütüphanesini kullanarak ResNet-50 modelini yükledi. Bu modeli önceden eğitilmiş bir şekilde indirilerek kullanıldı.
5. Veri Giriři ve İşleme: Projeye entegre edilen ResNet-50 modelini kullanarak, görüntüleri analiz etmek için verilerin hazırlanarak işlenmiřtir.
6. Sonuçların İşlenmesi ve Gösterilmesi: Modelin tahminlerini alındı. Sonuçların gösterilmesi için uygun arayüz geliřtirildi.
7. Test ve Hata Ayıklama: Kodlar test edildi.

Bu adımlar izlenerek mimari konut planlarının ön aşama standart çizim ölçütlerine uygun olup olmadığının tespit edilmiřtir. Şekil6.6.'de uygulama yöntemine ait akış diyagramı gösterilmiřtir.



Şekil 6.6. Uygulama yönteminin akış diyagramı

3.3.Yapay sinir Ağları ile Konut Planı Çizim Standartlarının Uygunluğu

Konut planı çizimlerinin ön aşama standartlarına uygunluğunun belirlenmesi için Visual Studio programında Resnet-50 ve DNN kombinasyonu kullanılmıştır. Visual Studio, Microsoft tarafından geliştirilen ve Windows işletim sistemi için özellikle yazılım geliştirme için tasarlanmış bir entegre geliştirme ortamıdır (IDE). Visual Studio'nun geliştirilme süreci oldukça karmaşıktır ve sürekli olarak yeni özellikler eklemek, hata düzeltmeleri yapmak ve kullanıcı deneyimini iyileştirmek için devam eder. Visual Studio, C#, Visual Basic (VB.NET), C++,F#, Python, JavaScript/TypeScript gibi farklı programlama dilleri ile kullanılabilir ve birçok farklı platformda yazılım geliştirmek için kullanılabilir. Konut planı çizimlerinin ön aşama standartlarının uygunluğunun tespiti için kullanılan projede Visual Basic (VB.NET) dili kullanılmıştır. TensorFlow kütüphanesi kullanılmıştır. TensorFlow, Google tarafından geliştirilen açık kaynaklı bir makine öğrenimi çerçevesidir. Visual Studio programında Microsoft'un Makine Öğrenimi çerçevesi olan ML.NET paketi de kullanılmıştır. ML.NET, .NET uygulamalarında makine öğrenimi modelleri oluşturmak ve dağıtmak için araçlar ve kütüphaneler sağlayarak, görüntü sınıflandırma, nesne tespiti ve görüntü işleme gibi

görüntü işleme görevlerine odaklanmıştır. ResNet-50 ve DNN (Derin Sinir Ağı) kombinasyonunu kullanarak görüntü sınıflandırma, özellik çıkarma işlemleri yapılmıştır.

ResNet-50 ve DNN (Derin Sinir Ağı) kullanımıyla ilgili literatürde bulunan bazı önemli kaynaklar:

KaimingHe, Xiangyu Zhang, Shaoqing Ren, Jian Sun tarafından yazılan "DeepResidual Learning for Image Recognition" adlı makale, ResNet'in temelini atmış ve derin sinir ağlarının eğitimini kolaylaştıran residual bağlantılarını tanıtmıştır. Bu makale, ResNet-50 gibi derin ağlar için temel bir kaynaktır.

Geoffrey Hinton, NitishSrivastava, Alex Krizhevsky, IlyaSutskever ve RuslanSalakhutdinov tarafından yazılan "ImprovingNeural Networks byPreventingCo-adaptation of FeatureDetectors" adlı makale, Dropout yöntemini tanıtır. Bu, ResNet-50 gibi ağların eğitiminde aşırı uyum (overfitting) sorununu azaltmaya yardımcı olabilir.


AndrejKarpathy ve LiFei-Fei tarafından yazılan "ImageNetLargeScale Visual Recognition Challenge" adlı makale, ResNet-50 gibi derin ağların büyük ölçekli görüntü tanıma görevlerindeki başarılarını anlatır.

3.4.Visual Studio Programı

Bu tez kapsamında Visual Studio programı kullanılmıştır. Visual Studio ve .NET Framework kullanılarak geliştirilen projenin gereksinimlerine ve ilgi alanlarına bağlı olarak farklı teknoloji ve kütüphanelerin seçimi aşağıda belirtilen aşamalar ile detaylandırılmıştır.

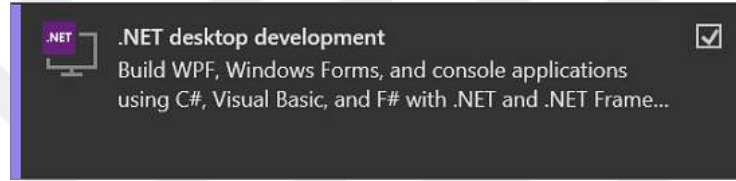
- **Visual Studio Kurulumu ve Ayarları:**

Visual Studio 2022 Community indirip kurulumu yapılmıştır.




Şekil 6.7. Visual Studio 2022 Community Kurulum

Kurulum sırasında, projenin gereksinimlerine bağlı olarak, .NET Framework geliştirme seçeneği seçilmiştir.



Şekil 6.8.NET Framework Modülü


Programın yükleme ayrıntıları bölümünde yer alan bağımsız bileşenlerden Microsoft.ML kütüphanesi proje dosyasına dahil edilmiştir.



Şekil 6.9.Microsoft.ML Kütüphanesi Seçimi

- **Proje Oluşturma**

Visual Studio'yu çalıştırıldı. Başlangıç penceresinde yeni proje oluşturma seçeneği seçildi. Projenin şablonunun seçilerek, projenin adı ve kayıt yolu belirlenerek tasarlanmaya başlanmıştır.



Şekil 6.10. Visual Studio Başlangıç Penceresi

- **Veri Hazırlama**

Düzce Üniversitesi, Sanat, Tasarım ve Mimarlık Fakültesi, Mimarlık Bölümü 4. Sınıf öğrencilerinin projelerinden hazırlanmıştır. Elde edilen verilerin projeye işlenmesi bazı adımlar uygulanmıştır. Bu adımlar aşağıda sırasıyla belirtilmiştir.

1. Adım: Proje Dosyalarının Formatı

Düzce Üniversitesi, Mimarlık Bölümü öğrencilerinden elde edilen projeler AutoCAD programında DWG formatı özelliğine sahip dosyalardı. Dosyalar Visual Studio Programına veri olarak işlenmesi için önce DWG uzantısından PDF dosyasına, PDF dosyasından ise PNG/JPEG dosyasına dönüştürüldü.


2. Adım: Proje Dosya Verilerinin Sınıflandırılması

Düzce Üniversitesi, Mimarlık Bölümü öğrencilerinden elde edilen proje planları eğitim ve test verisi olmak üzere ayrılmıştır. Eğitim verisinde yer alan projelerin, ön proje çizim standartlarından olan bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi özellikleri incelenerek geçerli veya geçersiz klasör dosyalarında sınıflandırıldı. Test verisi dosyası içerisinde ise projenin bitiminde test edilmesi istenilen planlar yer almaktadır.

- **Model Eğitimi**

Eğitim ve test verileri oluşturuldu. Visual Studio Kurulumu ve Ayarları yapılırken

Microsoft.ML kütüphanesi proje dosyasına dahil edilmiştir. Eğitim verilerini kullanarak bir ML.NET'in sunduğu çeşitli algoritma ve model seçimi yapılmıştır. Visual Studio programı ML.NET in sunduğu model oluşturucu kullanıcı ara yüzünde yer alan çözüm gezgini kısmında yer alan “.mbconfig” dosya ekranı projenin geliştirilmesi için gerekli adımların seçiminin yapıldığı paneldir. Şekilde “.mbconfig” panel ekranı gösterilmiştir.



Şekil 6.11. Çözüm Gezgini “.mbconfig”


Model oluşturmak için “.mbconfig” dosyası açılarak aşağıda yer alan adımlar izlenerek ilerlenmiştir.

- 1-Senaryo Seçimi
- 2-Eğitim Ortamının Seçilmesi
- 3- Veri
- 4- Eğitim
- 5- Değerlendirme

Bu çalışma için izlenen adımlar aşağıda detayları ile paylaşılmıştır.


1. Adım: Senaryo Seçimi

Proje verilerinin eğitilmesi sağlayan çeşitli senaryolar bulunmaktadır. Geliştirilecek projenin gereksinimlerine göre senaryo seçim işlemi yapılmaktadır. ML.NET, veri sınıflandırma, değer tahmini, görüntü sınıflandırma, öneri, nesne algılama, tahmin gibi makine öğrenmesini destekleyen senaryo modellerini barındırmaktadır. Şekil 6.12.'de senaryo seçim ekranı gösterilmiştir.



Şekil 6.12. Senaryo Seçim Ekranı


Bu çalışma için görüntü sınıflandırma senaryosu seçilmiştir.



Şekil 6.13. Görüntü Sınıflandırma Senaryosu

2. Adım: Eğitim Ortamının Seçimi


Projenin hangi makine üzerinden devam edeceğinin seçilmesi istenmektedir. Bu çalışmada Yerel (CPU) seçimi yapılmıştır. Seçimi yapılan ortamın görüntüsü Şekil 6.14.'de gösterilmiştir.



Şekil 6.14. Eğitim Ortamının Seçilmesi

3. Veri

Senaryo seçimde görüntü sınıflandırma seçeneğinin seçilmesi proje planlarının görsel olarak veri haline dönüştürülmesinden dolayı dosya biçimlerinin .png, .jpg, .jpeg, .gif. uzantısına sahip veri klasörü işlenmektedir. Bu çalışma için hazırlanan eğitim verisi klasörünün içerisinde yer alan geçerli ve geçersiz proje plan görsellerinin bulunduğu klasör dosyaları programa yüklenmiştir. Şekil6.15’de Visual Studio programında yer alan veri girişi gösterilmiştir.




Şekil 6.15. Veri Girişi

4. Eğitim

Model eğitim süreci, belirlediğiniz modeli kullanarak eğitim verileri üzerinde modeli öğrenme sürecini içerir. ML.NET, bu adımda kullanılacak birçok algoritma ve metodu sağlar. Eğitim süreci, veriye dayalı olarak modelin iç parametrelerini ayarlar ve optimize eder.

Bu çalışmada kullanılan veriler ile eğitim tamamlanmıştır. Veri setimiz için en uygun model DNN+ ResNet50 olarak belirlenmiştir. Bu model Microsoft tarafından geliştirilen bir makine öğrenmesi modelidir. Eğitim süresinin 303,12 saniyede olduğu gözlemlenmektedir. Şekilde eğitim sonuçlarının detayları gösterilmiştir.




Şekil 6.16. Eğitim Sonucu

5. Değerlendirme \ Analiz

Model değerlendirme, bir makine öğrenimi modelinin performansını ölçmek ve analiz etmek için kullanılır. Bu süreç, genellikle modelin eğitimini gerçekleştirmek için kullanılan veri kümesi ile ayrı bir test veri kümesi üzerinde değerlendirme metriklerini hesaplayarak gerçekleşir. Bu metrikler, modelin ne kadar etkili çalıştığını anlamak için kullanılır ve modelin geliştirilmesi için rehberlik sağlar.


Bu çalışmada 171 adet proje planı eğitim verisi olarak kullanılırken 26 adet proje planı ise test verisi olarak ayrılmıştır. Geliştirilen projede test verilerinin yüklenmesi ve analizinin yapılması için arayüz geliştirilmiştir. Test verisinin analizinin

değerlendirilmesi için geliştirilen arayüz Şekil 6.17.'de yer almaktadır.




Şekil 6.17. Test Verisi Analizinin Arayüzü

Analizi yapılan proje planlarının çıktıları bulgular kısmında detaylı anlatılacaktır. Test verisinin örnek olarak analiz sonucunun gösterimine dair bilgi vermesi için Şekil 6.18. ve Şekil 6.19.'da proje plan çiziminin çizim standartlarının ölçütlerini %58 kabul görürken, Şekil 6.19.'da %90 oranında kabul görmektedir.



Şekil 6.18. Test Verisinin Analizi



Şekil 6.19. Test Verisinin Analizi

7. BULGULAR VE TARTIŞMA

Bu bölümde program için kullanılan verilerin analiz işlemi yapılmaktadır. Analiz işlemi sonucunda modelin tahmin başarısının değerlendirilmesi için ön proje çizim standartları ölçütleri değerlendirilmiştir.

Derin öğrenme teknikleri kullanılarak geliştirilen algoritmaların analiz sonuçlarının doğruluğu ve etkinliği, çizim analiz programının tasarımının gerçek dünya uygulamalarına ne kadar başarılı bir şekilde uyum sağladığının değerlendirilmesi açısından büyük önem taşımaktadır. Bu sayede, elde edilen sonuçların geçerliliği, algoritmaların gerçek dünya koşullarında ne kadar etkili ve güvenilir olduğunu belirlememize olanak tanır.

Yapay zeka teknolojisi kullanılarak, veri önce eğitilerek, daha sonra modelin tahmin yetenekleri test edilmiştir. Bu bağlamda, uygulama için belirlenen bir yüzde veri eğitim seti olarak ayrılırken, geri kalan kısım test seti olarak kullanılmıştır. Elde edilen sonuçlar, uygulamanın analiz ettiği verilerle elde edilerek bu sonuçlar, test seti üzerinden değerlendirilmiştir. Bu değerlendirme, uygulamanın geçerliliğini veya geçersizliğini belirlemek için yapılmıştır.


Bu programın analiz sürecinde, önceden belirlenmiş çizim standartları, bakış açıları, ölçülendirme, mahal isimleri ve alanları (m²), modül ve inşai akslar, tefrişler gibi özellikler, ön proje aşamasında titizlikle değerlendirilmiştir. Bu değerlendirme süreci, proje çizimlerinin geçerliliğini veya geçersizliğini belirlemek amacıyla gerçekleştirilmiştir.

7.1. ÖN PROJE ÇİZİM STANDARTLARINA UYGUN OLMA DURUMU

Bu çalışmada eğitim verisi için kullanılan 171 adet verinin 70 adedi ön proje çizimlerine uygun olan projelerdir. Yapay zekâ teknolojisinin kullanılması ile gerçekleşen proje çıktılarının veri değerlerine değinilmiştir. Girdi vektöründe yer alan ölçütlerin her birine sahip olması durumunda veri çıktısı ön proje çizim standartlarına uygun olarak

kabul edilmektedir. Şekil 7.1. ile Şekil 7.26. arasında projelerin program çıktısı alınarak veri çıktılarına yer verilmiştir. Ön proje aşamasında uygulanması gereken çizim standartlarını sağlaması durumunda proje çıktısının geçerlilik yüzdesinin %75'den fazla olduğu gözlemlenmiştir. Bu değer sınırı ve kriterini sağlayan test verisi proje çıktılarına yer verilmiştir.


26 adet test verisinin programa test edilmesi ile 7 adet projenin geçerli ön proje standartları çizimlerini sağladığı görülmektedir. Bu ölçütün analiz edilmesi sonucuna göre, %98 geçerli (Şekil 7.1.), %87 geçerli (Şekil 7.2.), %97 geçerli (Şekil 7.3.), %96 geçerli (Şekil 7.4.), %99 geçerli (Şekil 7.5.), %77 geçerli (Şekil 7.6.) ve %87 geçerli (Şekil 7.7.) oranına ulaşılmıştır. Şekil 7.1. ile Şekil 7.7. arasındaki projelerin incelenmesi sonucunda, ön proje çizim standartlarına olan uygunluk, bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler gibi ölçütlerin standartlara tam uygunluk gösterdiğini ve bu önemli özellikleri etkili bir şekilde içerdiğini ortaya koymaktadır. Bu nedenle, projelerin geçerlilik oranları yüksek bir şekilde belirlenmiştir.



Şekil 7.1. Ön Proje Çizim Standartlarına Uygun Olan Proje


Yapay zekâ teknolojisi kullanılarak geliştirilen programın çıktısı, proje planının Şekil 7.1'indeki çizimlerin detaylı bir değerlendirmesi sonucunda %98 geçerlilik oranını ortaya koymuştur. Bu yüksek geçerlilik oranının temel sebebi, projenin bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar ile tefrişler gibi belirlenen

kriterleri oldukça başarılı bir şekilde karşılamış olmasıdır. Dolayısıyla, proje planının önceden belirlenmiş ölçütleri etkili bir biçimde yerine getirmesi, yapay zekâ analizi sonucunda yüksek bir geçerlilik oranı elde edilmesini sağlamıştır.




Şekil 7.2. Ön Proje Çizim Standartlarına Uygun Olan Proje

Şekil 7,2'deki proje planının incelenmesi sonucunda, ön proje çizim standartlarına uygunluğu gözlemlenmiştir. Yapay zeka teknolojisi ile geliştirilen programın çıktısında elde edilen %87 geçerlilik oranı, proje planının bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar ile tefrişler gibi belirlenen önemli ölçütleri başarılı bir şekilde karşılamasından kaynaklanmaktadır.




Şekil 7.3. Ön Proje Çizim Standartlarına Uygun Olan Proje

Şekil 7,3'teki proje planının detaylı bir incelemesi, ön proje çizim standartlarına uygunluğunu ortaya koymaktadır. Yapay zeka teknolojisi ile geliştirilen programın çıktısında elde edilen %79'luk geçerlilik oranı, proje planının bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar ile tefrişler gibi belirlenen kriterleri yerine getirme başarısını yansıtmaktadır.




Şekil 7.4. Ön Proje Çizim Standartlarına Uygun Olan Proje

Proje planının Şekil 7,4'ündeki detaylı inceleme, ön proje çizim standartlarına uygunluğunu açıkça ortaya koymaktadır. Yapay zeka teknolojisi ile geliştirilen programın çıktısında elde edilen %96 geçerlilik oranı, proje planının bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar ile tefrişler gibi belirlenen kriterleri büyük ölçüde karşılamasından kaynaklanmaktadır.



Şekil 7.5. Ön Proje Çizim Standartlarına Uygun Olan Proje


Şekil Şekil 7.5'teki proje planı, ön proje çizim standartlarına tam anlamıyla uygun bir şekilde hazırlandığına dair önemli bir başarı sergiliyor. Yapay zeka teknolojisi tarafından üretilen program çıktısı ise %99'luk geçerlilik oranıyla, projenin detaylı unsurlarını, bakış yönünden ölçülendirmeye, mahal ismi ve alan düzenlemelerinden modül ve inşai akslara kadar, belirlenen kriterlere sahip olduğunu göstermektedir.



Şekil 7.6. Ön Proje Çizim Standartlarına Uygun Olan Proje

Şekil 7,6'daki proje planı incelendiğinde, ön proje çizim standartlarına uygunluğu açıkça görülmektedir. Yapay zeka teknolojisi ile geliştirilen programın çıktısında elde

edilen %77'lik geçerlilik oranı, proje planının bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar gibi belirlenen kriterlere başarılı bir şekilde uyum sağlamasından kaynaklanmaktadır.




Şekil 7.7. Ön Proje Çizim Standartlarına Uygun Olan Proje

Şekil 7,7'deki proje planı, ön proje çizim standartlarına uygun bir şekilde tasarlanmış olduğu proje çıktısı incelendiğinde gözlemlenebilmektedir. Yapay zeka teknolojisi kullanılarak elde edilen program çıktısı, %87'lik geçerlilik oranı ile projenin bakış yönü, ölçülendirme, mahal ismi ve alan, modül ve inşai akslar gibi belirlenen kriterleri sağlamasından kaynaklıdır.

7.2. BAKIŞ YÖNÜNÜN ÖLÇÜTÜNÜN GEÇERLİ VEYA GEÇERSİZ OLMA DURUMU

Girdi vektöründe yer alan bakış yönü ölçütünün eksikliği, önemli bir standart olan proje çizim kurallarında geçerliliği etkilemesi gereken bir durumdur. Ancak, yapay zekâ teknolojisinin bakış açısı kriteri üzerinde yeterli öğrenim sağlayamaması ve diğer ölçütlerin daha etkili bir şekilde gelişmiş olması nedeniyle, proje çıktılarında bu eksiklik genellikle göz ardı edilebilmektedir. Bu durum, yapay zekâ teknolojisinin, bakış açısı ölçütünün eksikliğini tespit etme konusunda yeterince hassas olamamasından kaynaklanmaktadır. Dolayısıyla, proje çıktılarının geçerliliği, mevcut teknolojinin bu


belirli yetersizliğini görmezden gelerek kabul edilebilmektedir. Bu durum, yapay zekâ teknolojisinin geliştirilmesi sürecinde özellikle bakış açısı kriterine odaklanmanın önemini vurgulamaktadır. Gelecekteki çalışmaların, bu tür kritik ölçütleri daha etkili bir şekilde ele alarak yapay zekânın genel performansını artırmaya odaklanması önemlidir. 26 adet test verisinin programa test edilmesi ile 2 adet projenin geçerli ön proje standartlarından sadece bakış yönü ölçütüne sahip olmadığı gözlemlenmiştir. Bu ölçütün analiz edilmesi sonucuna göre, %70 geçerli (Şekil 7.8.), %61 geçerli (Şekil 7.9.), oranına ulaşılmıştır. Şekil 7.8 ile Şekil 7.9'daki projelerin detaylı analizi sonucunda, ön proje çizim standartlarında yer alan bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler ölçütlerinden bakış yönünün eksikliği tespit edilmiştir. Bu durum, projenin çıktısını değerlendiren standartlara göre geçerli olarak kabul edilmesine rağmen, aslında geçersiz olması gerektiğini göstermektedir. Bakış yönü eksikliği, proje çıktısının belirlenmiş standartlara tam olarak uymadığını ve bu nedenle geçersiz kabul edilmesi gerektiğini işaret etmektedir. Bu durum, özellikle önemli olan bakış yönü ölçütünün göz ardı edilmesi durumunda projenin genel geçerliliğini etkileyebilecek önemli bir unsurdur. Gelecekteki çalışmalarda, bu tür eksiklikleri düzeltmek ve standartlara uygunluğu artırmak için özel önlemler alınması gerekmektedir.



Şekil 7.8. Bakış Yönü Ölçütüne Sahip Olmayan Proje

Şekil 7.8'deki proje planının detaylı bir analizi, projenin çiziminde ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişlerin mevcut olduğunu ancak bakış yönünün

izilmediđini ortaya koymaktadır. Bu durum, n proje izim standartlarına gre projenin %70 oranında geerli kabul edilmesine rađmen, aslında bakıř ynnn izilmemiř olması nedeniyle geersiz kabul edilmesi gerektiđini gstermektedir. Yani, izimlerin ođu standartlara uygun olsa da, bakıř yn eksikliđi nedeniyle projenin genel geerliliđi olumsuz etkilenmektedir. Bu durum, standartlara tam uyumun sađlanabilmesi iin bakıř yn ltnn nemini vurgulamaktadır. Gelecekteki alıřmalarda, bu tr eksikliklerin tespit edilmesi veya daha iyi bir eđitim modelinin oluřturulmasının gerekli olduđu gzlemlenmiřtir.



řekil 7.9. Bakıř Yn ltne Sahip Olmayan Proje

řekil 7.9'daki proje planı incelendiđinde, sadece bakıř yn izilmemiř. Bu yzden projenin ıktısı %61 geerli kabul edilmiř, ancak bakıř ynnn eksikliđi nedeniyle aslında geersiz olması gerekmektedir. Diđer standartlara uyulmuř olabilir, fakat bakıř yn izimi nemli bir detaydır ve bu eksiklik, projenin genel geerliliđini etkiler. Gelecekte benzer hataları nlemek iin, bakıř aısı kriterinin eđitim srecine daha fazla dikkat edilmesi ve bu kriterin daha hassas bir řekilde geliřtirilmesi gerekmektedir.


7.3. LLENDİRME LTNN İZİLMEME DURUMU

Yapay zekâ teknolojisinin geliřtirilmesi iin kullanılan eđitim verileri arasında 171 rnek ve test verileri arasında 26 rnek bulunmaktadır. Deđerlendirme kriterlerinin analizi iin ise 4 farklı test verisi kullanılmıřtır. Bu ltlerin analizi sonucunda, %72 geersizlik oranına ulařıldıđı řekil 7.10., %73 geersizlik oranına ulařıldıđı řekil 7.11.,

%60 geçersizlik oranına ulaşıldığı Şekil 7.12. ve %98 geçersizlik oranına ulaşıldığı Şekil 7.13. gözlemlenmiştir.


Şekil 7.10. ile Şekil 7.13. arasındaki projelerin incelenmesi sonucunda, özellikle ön proje çizim standartlarına uygun olmayan unsurlar belirlenmiştir. Bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler gibi önemli ölçütlerin ölçülendirme aşamasında eksik olduğu tespit edilmiştir.

Ölçülendirme ölçütünün ön proje çiziminde yer almaması, projenin çizim standartlarına uygun olmadığı anlamına gelmektedir. Bununla birlikte, yapay zeka teknolojisi kullanılarak geliştirilen proje, eğitim verisinin ölçülendirme ölçütünün çizilip çizilmediğini analiz edebilen bir yetenek kazanmıştır. Bu durum, projenin geliştirilebilir ve adapte edilebilir bir yapısının olduğunu ortaya koymaktadır.




Şekil 7.10. Ölçülendirme Ölçütünün Çizilmemesinin Çıktısı

Şekil 7.10'da incelenen proje planında, ölçülendirme, mahal ismi, m², modül ve inşai akslar, tefrişlerin çizildiği ancak ölçülendirme ölçütünün çizilmediği gözlemlenmiştir. Bu durum, ön proje çizim standartlarına uymamakta ve geçersiz olarak değerlendirilmektedir. Ayrıca, geliştirilen yapay zeka teknolojisi ile elde edilen program çıktısının %72'lik bir "geçersiz" oranına sahip olması da önemli bir bulgu olarak ortaya çıkmaktadır.



Şekil 7.11. Ölçülendirme Ölçütünün Çizilmemesinin Çıktısı


Şekil 7.11’de incelenen proje planında, ölçülendirme, mahal ismi, m², modül ve inşai akslar, tefrişlerin çizildiği ancak ölçülendirme ölçütünün çizilmediği gözlemlenmiştir. Bu durum, ön proje çizim standartlarına uymamakta ve %73'lik bir "geçersiz" oranına sahip olmaktadır.



Şekil 7.12. Ölçülendirme Ölçütünün Çizilmemesinin Çıktısı

Şekil 7.12'de incelenen proje planında, bakış yönü, ölçülendirme, mahal ismi, m², modül ve inşai akslar, tefrişler gibi kritik ölçütlerin ölçülendirme aşamasında eksik olduğu tespit edilmiştir. Yapılan analiz sonucunda, geliştirilen yapay zekâ modelinin

program çıktısı %60 "geçersiz" oranını vermiştir. Bu durum, proje planının önemli ölçütlerden biri olan ölçülendirme eksikliği sebebiyle "geçersiz" sonuçlara neden olmuştur.



Şekil 7.13. Ölçülendirme Ölçütünün Çizilmemesinin Çıktısı


Şekil 7.13’de incelenen proje planında, ön proje çizim standartlarına uygun olarak ölçülendirme ölçütünün eksik olduğu gözlemlenmiştir. Ayrıca, geliştirilen yapay zeka modelinin program çıktısı %98 "geçersiz" oranını vermiştir. Bu durum, proje planının ölçülendirme ölçütü eksikliği nedeniyle oldukça yüksek bir oranla "geçersiz" sonuçlar elde etmiş olduğunu göstermektedir.

7.4. MAHAL İSMİ VE M² ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU

Yapay zekâ teknolojisinin geliştirilmesi için kullanılan 171 eğitim verisi ve 26 test verisi, ölçülendirme ölçütünün değerlendirilmesi amacıyla 4 test verisi üzerinde analiz edilmiştir. Bu analiz sonuçlarına göre elde edilen oranlar sırasıyla %75 (Şekil 7.14), %54 (Şekil 7.15), %82 (Şekil 7.16) ve %88 (Şekil 7.17) olarak belirlenmiştir.


Şekil 7.14 ile Şekil 7.17 arasındaki projelerin incelenmesi, ön proje çizim standartlarında belirtilen bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler ölçütlerinden mahal ismi ve m² ölçütünün eksik olduğunu ortaya koymuştur. Uygulama analizi sonuçlarına göre, mahal ismi ve m² ölçütlerinin çizimine

yer verilmeyen projeler, proje çizim standartlarına uymadıkları için "Geçersiz" olarak değerlendirilmektedir.




Şekil 7.14. Mahal İsmi ve m² Ölçününün Çizilmemesinin Çıktısı

Şekil 7.14'ün detaylı bir analizi, proje planındaki bakış yönü, ölçülendirme, modül ve inşai akslar ile tefrişler gibi unsurların başarılı bir şekilde çizildiğini, ancak mahal ismi ve m² ölçütlerinin çizimine dair belirgin eksikliklerin gözlemlendiğini ortaya koymaktadır. Yapay zekâ tabanlı teknolojinin uygulanmasıyla elde edilen program çıktısında, mahal ismi ve m² ölçütlerinin çizilmemesi nedeniyle %72 oranında "geçersiz" sonucuna ulaşılmıştır. Bu durum, geliştirilen yapay zekâ modelinin, özellikle mahal ismi ve m² ölçütlerini başarılı bir şekilde algılabildiğini göstermektedir.




Şekil 7.15. Mahal İsmi ve m² Ölçününün Çizilmemesinin Çıktısı

Şekil 7.15'in proje planı üzerinde yapılan incelemede, proje çiziminde bakış yönü, ölçülendirme, modül ve inşai akslar ile tefrişler gibi unsurların başarılı bir şekilde çizildiği, ancak mahal ismi ve m² ölçütünün çizilmediği gözlemlenmiştir. Proje analizi, ön proje çizim standartlarını ölçütlerini sağlamadığı bilinirken, geliştirilen yapay zekâ teknolojisi de yapılan program çıktısında %54 oranında "geçersiz" sonucunu vermiştir.



Şekil 7.16. Mahal İsmi ve m² Ölçütünün Çizilmemesinin Çıktısı

Şekil 7.16'nın proje planı üzerindeki detaylı incelemesinde, proje çiziminde bakış yönü, ölçülendirme, modül ve inşai akslar, tefrişler gibi unsurların başarıyla çizildiği, ancak mahal ismi ve m² ölçütünün belirtilmediği gözlemlenmiştir. Bu durum, geliştirilen yapay zeka teknolojisinin önceden eğitildiği veri setinden yola çıkarak, proje çizimlerinin %82 oranında geçersiz olduğu sonucuna ulaştığını göstermektedir.



Şekil 7.17. Mahal İsmi ve m² Ölçününün Çizilmemesinin Çıktısı


Şekil 7.17'nin proje planı detaylı bir şekilde incelendiğinde, proje çiziminde bakış yönü, ölçülendirme, modül ve inşai akslar, tefrişler gibi önemli unsurların başarılı bir şekilde çizildiği, ancak mahal ismi ve m² ölçütünün belirtilmediği gözlemlenmiştir. Bu bağlamda, geliştirilen yapay zekâ teknolojisinin program çıktısında %88 "geçersiz" oranını vermesi, yapay zekâ algoritmasının proje çizimlerindeki kritik eksiklikleri anlayabilme yeteneğini göstermektedir. Bu tespit, özellikle mahal ismi ve m² ölçütünün çizimindeki eksiklikleri belirleme konusunda yapay zeka modelinin yüksek doğruluk oranlarına sahip olduğunu göstermektedir. Elde edilen bu bulgular, yapay zekâ teknolojisinin proje değerlendirme süreçlerine etkili bir biçimde katkı sağlayabileceği perspektifini ortaya koymaktadır.

7.5. MODÜL VE İNŞAİ AKS ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU

Yapay zekâ teknolojisinin geliştirilmesi için toplamda 171 eğitim verisi ve 26 test verisi kullanılmıştır. Ölçülendirme ölçütünün değerlendirilmesi amacıyla 4 adet test verisi üzerinde analizler gerçekleştirilmiştir. Bu analiz sonuçlarına göre, Şekil 7.18. için %84 geçersizlik, Şekil 7.19. için %96 geçersizlik, Şekil 7.20. için %84 geçersizlik ve Şekil 7.21. için %96 geçersizlik oranları elde edilmiştir.


Şekil 7.18. ile Şekil 7.21. arasındaki projelerin incelenmesi neticesinde, ön proje çizim standartları içerisinde bulunan bakış yönü, ölçülendirme, mahal ismi ve m², modül ve

inşai akslar, tefrişler ölçütlerinden modül ve inşai akslar ölçütünün eksik olduğu gözlemlenmiştir. Uygulama analizi sonucunda, modül ve inşai akslar ölçütünün çiziminin yapılmamış olması, projelerin proje çizim standartlarına uygun olmadığı anlamına gelmektedir. Bu nedenle, bu projeler "Geçersiz" olarak nitelendirilmiştir.




Şekil 7.18. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı

Şekil 7.18'deki proje planının detaylı bir incelenmesi, bakış yönü, ölçülendirme, mahal ismi ve m², tefrişler gibi ölçütlerin başarıyla çizildiğini, ancak modül ve inşai akslar ölçütünün çizilmediğini ortaya koymaktadır. Yapay zeka teknolojisi tarafından üretilen program çıktısının değerlendirilmesi sonucunda elde edilen %84 "geçersiz" oranı, bu eksikliğin belirli bir standart veya kriteri karşılamadığını ve projenin tamamının yeterli olmadığını göstermektedir.



Şekil 7.19. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı


Şekil 7.19'daki proje çıktısının incelenmesi, önemli ölçütlerin eksik veya hatalı çizildiğini ortaya koymaktadır. Belirtilen projede, bakış yönü, ölçülendirme, mahal ismi ve m², tefrişler gibi kriterlere ilişkin sorunlar olmayabilir, ancak modül ve inşai akslar ölçütünde eksiklikler tespit edilmiştir. Yapay zeka teknolojisinin değerlendirmesi sonucunda elde edilen %96 "geçersiz" oranı, bu eksikliklerin projenin genel geçerliliğini etkilediğini ve belirlenen standartları karşılamadığını göstermektedir.



Şekil 7.20. Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı

Şekil 7.20'deki proje çıktısının analizi, çeşitli önemli ölçütlerin yer aldığı, ancak belirli bir standart veya kriterin eksik olduğu bir durumu işaret etmektedir. Bakış yönü,

ölçülendirme, mahal ismi ve m², tefrişler gibi belirli ölçütlerin çizildiği gözlemlenebilir. Ancak, modül ve inşai akslar ölçütünün çizilmemiş olması, projenin genel değerlendirilmesini olumsuz etkilemektedir. Yapay zeka teknolojisinin değerlendirmesi sonucunda elde edilen %84 "geçersiz" oranı, modül ve inşai akslar ölçütünün eksikliğinin sebebiyet verdiği gözlemlenmiştir.



Şekil 7.21.Modül ve İnşai Akslar Ölçününün Çizilmemesinin Çıktısı


Şekil 7.21'deki proje çıktısı, önemli ölçütlerin eksik veya hatalı bir biçimde çizildiği bir durumu yansıtmaktadır. Bakış yönü, ölçülendirme, mahal ismi ve m², tefrişler gibi belirli ölçütlerin incelendiği projede, modül ve inşai akslar ölçütü doğru bir şekilde uygulanmamıştır. Yapay zekâ teknolojisinin değerlendirmesi sonucunda ortaya çıkan %96 "geçersiz" oranı, projenin genelinde belirli bir standartın eksikliği nedeniyle başarısız kabul edildiğini göstermektedir.

7.6. TEFRİŞLER ÖLÇÜTÜNÜN ÇİZİLMEME DURUMU

Geliştirilen yapay zeka teknolojisi için toplamda 171 eğitim verisi ve 26 test verisi kullanıldı. Ölçülendirme ölçütünün değerlendirilmesi için ise 5 test verisi üzerinde çalışıldı. Yapılan analizler sonucunda elde edilen sonuçlar şu şekildedir: Şekil 7.22'de %99 geçersiz, Şekil 7.23'te %83 geçersiz, Şekil 7.24'te %86 geçersiz, Şekil 7.25'te %64 geçersiz ve Şekil 7.26'da %95 geçersiz oranlarına ulaşıldı.


Şekil 7.22 ile Şekil 7.26 arasındaki projelerin incelenmesi sonucunda, ön proje çizim

standartları içinde yer alan bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler ölçütlerinden tefrişler ölçütünün eksik olduğu gözlemlendi. Uygulama analizi sonuçlarına göre, tefrişler ölçütü çizimi yapılmayan projeler, proje çizim standartlarına uymadığı için "Geçersizlik" oranının daha yüksek olduğu gözlemlenmiştir.




Şekil 7.22. Tefrişler Ölçütünün Çizilmemesinin Çıktısı

Şekil 7.22'deki projelerin değerlendirilmesi sonucunda, genel bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler ölçütlerinde belirgin eksiklikler tespit edilmiştir. Bu eksiklikler, projelerin belirlenen standartlara tam anlamıyla uyum sağlayamamasına ve özellikle tefrişler ölçütünde detaylı çizim yapılmamış olmasına dayanarak %99 geçersizlik oranına ulaşmıştır. Projelerin detaylı çizim ve standartlara uyum konusunda önemli iyileştirmelere ihtiyaç duyduğu ifade edilmektedir.



Şekil 7.23. Tefrişler Ölçününün Çizilmemesinin Çıktısı

Şekil 7.23 incelendiğinde, projelerin genel değerlendirme sürecinde belirli ölçütlerde standartlara tam olarak uyum sağlayamadığı gözlemlenmiştir. Projenin genel bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler ölçütleri üzerinde yapılan analizler, projelerin belirli kriterlere yeterli ölçüde uyum sağlayamadığını ortaya koymuştur. Özellikle tefrişler ölçütünde eksiklikler ve detaylı çizimlerin yetersizliği, projelerin %83 geçersizlik oranına ulaşmasına neden olmuştur. Detaylı çizimlerin eksikliği, projelerin özellikle tefrişler ölçütünde yeterli bilgi sağlamamış olmasına işaret etmektedir.




Şekil 7.24. Tefrişler Ölçününün Çizilmemesinin Çıktısı

Şekil 7.24'ün değerlendirmesi sonucunda, projelerin belirli kriterlere tam uyum sağlamada zorlandığı ve özellikle tefrişler ölçütünde önemli eksiklikler içerdiği gözlemlenmiştir. Projelerin genel bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler ölçütleri üzerinde yapılan analizler, belirli standartlara uyum sağlama konusunda yetersiz olduğunu ortaya koymuştur. Özellikle tefrişler ölçütünde belirgin eksiklikler ve detaylı çizimlerin yetersizliği nedeniyle projelerin %86 geçersizlik oranına ulaştığı gözlemlenmiştir.



Şekil 7.25. Tefrişler Ölçününün Çizilmemesinin Çıktısı

Şekil 7.25 incelendiğinde, projeler belirli ölçütlerde standartlara tam uymakta zorlanmış ve özellikle tefrişler ölçütünde belirgin eksiklikler göstermiştir. Projelerin genel geçerlilik standartlarına tam anlamıyla uyum sağlama konusunda %64 geçersizlik oranına ulaşması, belirli kriterlere tam uyum sağlamada güçlük yaşandığını yansıtmaktadır.



Şekil 7.26.Tefrişler Ölçününün Çizilmemesinin Çıktısı

Şekil 7.26'nın değerlendirilmesi, projelerin belirli ölçütlerde standartlara tam anlamıyla uymakta zorlanması ve özellikle tefrişler ölçütünde belirgin eksiklikler taşımasıyla ilgilidir. Genel bakış yönü, ölçülendirme, mahal ismi ve alanı (m²), modül ve inşai akslar, tefrişler ölçütleri üzerinden yapılan analizler, projelerin belirlenen kriterlere yeterince uyum sağlamadığını ve özellikle tefrişler ölçütünde açık eksiklikler içerdiğini ortaya koymuştur. Bu çerçevede, projelerin %95 geçersizlik oranına ulaşılmıştır.

8. SONUÇLAR VE ÖNERİLER

Teknolojinin hızlı gelişimi, yapay zekânın mimari tasarım süreçlerine önemli katkılar sağlamasına neden olmuştur. Mimarlar, yapay zekâ algoritmalarını kullanarak tasarımlarını hızlı bir şekilde optimize edebilir, farklı senaryoları değerlendirerek yenilikçi çözümler üretebilir. Bu sayede mimari projelerin kalitesi artarken, tasarım süreçleri de daha verimli hale gelmektedir. Yapay zekâ, sadece hesaplamalı değil aynı zamanda yaratıcı bir destek aracı olarak da ön plana çıkmakta, mimarların tasarımlarını daha çeşitli ve özgün hale getirmelerine olanak tanımaktadır. Bu bağlamda, yapay zekâ destekli mimari tasarım, sektördeki profesyonellerin daha stratejik ve ileri düzeyde çalışmalarını mümkün kılarak mimari projelerin estetik ve işlevsellik açısından dengeli bir şekilde gelişmesine olanak sağlamaktadır.

Türk Mühendis ve Mimar Odaları Birliği (TMMOB) – Mimarlar Odası tarafından belirlenen Mimari Proje Çizim ve Sunuş Standartları'nda, projelerin içereceği bilgiler ve çizim standartları kapsamında önemli bir odak noktası, konut planlarının ön proje aşamasındaki çizim standartlarına ayrılmıştır. Bu standartlar, konut planlarının uygunluğunu belirlemek amacıyla geliştirilmiş olup, bu değerlendirme sürecinde yer alan yetkililerin zaman tasarrufu sağlamalarını ve doğru tespitlerde bulunmalarını desteklemeyi hedeflemektedir.

Yapay zekâ, mimari tasarım sürecinde önemli bir rol oynamaktadır. Mimarlar, yapay zekâ araçlarını kullanarak tasarımlarını daha hızlı ve etkili bir şekilde optimize edebilirler. Ayrıca, farklı senaryoları değerlendirme yeteneği sayesinde daha yenilikçi çözümler sunma potansiyeli taşırlar. Bu kullanım, mimari projelerin genel kalitesini artırarak tasarım sürecini daha etkin ve verimli hale getirme amacını gütmektedir.

Dolayısıyla, yapılan bu tür değerlendirmeler, mimari projelerin standartlara uygunluğunu belirlemede önemli bir araç olabilir. Yapay zekânın kullanımı, hem tasarım süreçlerini destekleyerek hem de daha doğru ve hızlı tespitler yapılmasını sağlayarak önemli bir katkı sağlamaktadır.

Bu tez çalışması, DNN ve Resnet-50 modeli kullanılarak Visual Studio ortamında geliştirilen yapay zekâ teknolojisi ile konut proje planlarının ön proje aşamasındaki çizim standartlarına uygunluğunu değerlendirmektedir. Düzce Üniversitesi, Sanat,

Tasarım ve Mimarlık Fakültesi – Mimarlık Bölümü öğrencilerinden elde edilen 171 eğitim ve 26 test verisi kullanılarak gerçekleştirilen bu çalışmada, veri setinin %85'i eğitim, %15'i ise test amacıyla ayrılmıştır.

Mimarlar Odası birliği tarafından belirlenen Mimari Proje Çizim ve Sunuş Standartları'ndaki ölçütlerden bakış yönü, ölçülendirme, mahal ismi ve m², modül ve inşai akslar, tefrişler seçilerek her bir ölçütün çizim standartlarına uygunluğu ön proje aşamasında analiz edilmiştir. Çizelge 8.1'de, ölçütlerin varlığına göre çizim standartlarının geçerlilik durumu ayrıntılı bir şekilde gösterilmiştir.

Çizelge 8.1. Ölçütlerin olup/olmaması göre geçerlilik/geçersizlik yüzdesi

Uygun \ Eksik Ölçütler	Ölçütler Tam	Ölçütler Eksik	Test Edilen Veri Sayısı	En Yüksek Geçerlilik Yüzdesi	En Düşük Geçerlilik Yüzdesi	En Yüksek Geçersizlik Yüzdesi	En Düşük Geçersizlik Yüzdesi
Uygun	✓	✗	7	%99	%77	%23	%1
Bakış Yönü	✗	✓	2	%70	%61	%39	%30
Ölçülendirme	✗	✓	4	%40	%2	%98	%60
Mahal İsmi ve m ²	✗	✓	4	%46	%12	%88	%54
Modül ve İnşai Akslar	✗	✓	4	%16	%4	%96	%84
Tefrişler	✗	✓	5	%36	%1	%99	%64

Elde edilen çalışma sonuçlarına göre, 26 adet proje görseli üzerinde yapılan testlerde, 7 adet plan görseli tamamıyla çizim ölçütlerini karşılamaktadır ve bu planların geçerlilik yüzdeleri %99 ile %77 arasında değişmektedir. Ancak, bakış yönü ölçütünün eksik olması durumunda, proje planlarının geçersiz kategorisinde olması beklenirken, 2 adet proje planının geçerlilik yüzdeleri diğerlerinden daha yüksek çıkmıştır.

Ölçülendirme ölçütüne sahip olmayan 4 adet test verisinin geçersizlik yüzdeleri %98 ile %60 arasında değişmektedir. Mahal ismi ve m² ölçütüne sahip olmayan 4 adet test verisinin geçersizlik yüzdeleri ise %88 ile %54 arasında değişmektedir. Modül ve inşai akslar ölçütüne sahip olmayan 4 adet test verisinin geçersizlik yüzdeleri ise %96 ile

%84 arasında değişmektedir. Tefrişler ölçütüne sahip olmayan 5 adet verinin geçersizlik yüzdeleri ise %99 ile %64 arasında değişmektedir. Bu bulgular, test verilerinde belirli ölçütlerin eksikliğinin geçersizlik oranlarını etkilediği göstermektedir.

Projenin geliştirme aşamasında, yapay zekâ tabanlı programın performansının incelenmesi sonucunda, genel olarak birçok ölçütte başarılı olduğu ancak özellikle bakış yönü ölçütünde belirgin eksikliklerin tespit edildiği gözlemlenmiştir. Proje planları gibi belirli kriterlerde yapay zekânın etkili bir şekilde işlediği saptanmış olmasına rağmen, özellikle bakış yönü ölçütünde başarısızlık yaşanması, insan müdahalesinin hala kritik bir öneme sahip olduğunu vurgulamaktadır.

Bu durumda, projenin ilerleyen aşamalarında yapay zekânın başarılı olduğu ölçütleri kullanmak, zaman tasarrufu sağlamak ve insan müdahalesinin gerçekten gerekli olduğu noktalara odaklanmak, akılcı bir strateji olarak değerlendirilebilir. Örneğin, yapay zekâ tarafından doğru bir şekilde değerlendirilebilen standart çizim ölçütleri otomatikleştirilebilirken, bakış yönü gibi karmaşık ölçütler için daha iyi bir insan anlayışına ihtiyaç duyulan durumlar için manuel bir süreç devrede tutulabilir. Bu yaklaşım, proje verimliliğini artırırken hala insan uzmanlığının gerektiği kritik noktalara odaklanmayı sağlayabilir.

Bu projenin gelecekteki çalışmalarında, yapay zekânın mimari tasarım süreçlerine daha derinlemesine entegre edilmesi ve belirlenen standartların güncellenmesi üzerine odaklanılması planlanmaktadır. Aynı zamanda, kullanıcı geri bildirimlerine dayanarak yapay zekânın öğrenme yeteneklerinin geliştirilmesi de önemli bir öncelik olarak değerlendirilmektedir.

Farklı ülkelerin ve bölgelerin mimari tasarım standartlarını belirleyen yönergelerin detaylı bir şekilde incelenmesi ve bu standartlara uygunluğun yapay zekâ kullanılarak nasıl değerlendirilebileceğini araştırmak amacıyla, yapay zekâ algoritmalarının belirli standartlara özgü özellikleri ve kriterleri hızlı ve etkili bir biçimde analiz edebilme kapasitesi değerlendirilmektedir. Bu analizlerin elde ettiği sonuçlara dayanarak, mimari tasarım projelerinde standartlara uygunluğun artırılması için öneriler geliştirmek hedeflenmektedir.

Mimarlık alanında yapay zekâ kullanımının gelişimi için ilk adım, sektördeki profesyonellerin yapay zekâ konusundaki bilgi düzeylerini artırmak amacıyla eğitim programları ve farkındalık artırıcı etkinlikler düzenlemektir. Bu çabalar, sektördeki bireylerin yapay zekâ ile ilgili temel kavramları anlamalarına ve potansiyel uygulama alanlarını tanımalarına yardımcı olabilir. Daha sonra, farklı uzman gruplarını bir araya getiren bir işbirliği ağı kurulabilir. Mimarlar, yazılım geliştiricileri ve yapay zekâ uzmanları arasındaki bu işbirliği, sektördeki yenilikleri hızlandırabilir ve disiplinler arası bir yaklaşımın gelişimine daha da fazlakatkı sağlayabilir.

Mimarlık alanında yapay zeka kullanımının gelişimi, eğitimde öğrencileri hazırlayan önemli bir ders gibi olabilir. Bu ders, öğrencilere mimarlık tasarım sürecinde yapay zeka araçlarını nasıl kullanacaklarını, veri analizi ve simülasyon yeteneklerini nasıl geliştireceklerini öğretir. Ayrıca, yapay zeka destekli tasarımın mimarlık pratiği üzerindeki etkilerini ve gelecekteki gelişimleri de ele alabilir. Bu dersin amacı, öğrencilere mimarlıkta yapay zeka kullanımının temel kavramlarını ve tekniklerini öğretmek, onları sektördeki yeniliklerle uyumlu hale getirmek ve tasarım sürecinde verimliliği artırmaktır. Aynı zamanda, öğrencilere farklı yapay zeka araçları ve uygulamalarını keşfetme fırsatı vererek yaratıcılıklarını artırabilir ve inovasyona teşvik edebilir. Bu ders, mimarlık öğrencilerinin geleceğin teknoloji odaklı mimarlık pratiğine hazırlanmasına yardımcı olabilir.

Belediyeler, mimari projelerin çıktılarının doğruluğunu ve uygunluğunu kontrol etmek için yapay zeka destekli bir kontrol sistemi kullanabilirler. Bu sistem, proje belgelerinin ve çizimlerinin belirlenen kriterlere ne ölçüde uyduğunu otomatik olarak analiz edebilir. Örneğin, çizimlerde belirli bir aşamaya gelindiğinde (örneğin, tasarım geliştirme aşaması tamamlandığında), belediye sistem üzerinden belirlenen yüzdeyi girer ve sistem otomatik olarak projenin uygunluğunu kontrol eder. Bu kontrol sistemi, belediyelerin denetim süreçlerini daha verimli hale getirebilir, insan hatası riskini azaltabilir ve süreçlerin daha hızlı tamamlanmasını sağlayabilir. Ayrıca, yapay zeka destekli bu kontrol sistemi, standartlara uygunluğu otomatik olarak değerlendirerek denetim sürecini daha objektif hale getirebilir.

Yapay zeka destekli bir kontrol sistemi kullanmak, belediyede çalışan iş gücünü azaltabilir. Özellikle rutin denetim ve uygunluk kontrolleri için bu tür bir sistem, insanların harcadığı zamanı ve emeği azaltabilir. Belediye çalışanları, yapay zeka tarafından otomatik olarak yapılan ön denetimlerin sonuçlarını daha hızlı ve verimli bir şekilde değerlendirebilirler. Bu sayede, daha fazla zamanlarını daha karmaşık veya özel durumlar için harcayabilirler.

Ayrıca, yapay zeka destekli bir kontrol sistemi sayesinde belediyeler, denetim süreçlerini daha etkin yönetebilir ve denetimlerin daha kapsamlı ve güvenilir olmasını sağlayabilir. Bu da proje onay süreçlerinin hızlanmasına ve daha düşük maliyetlerle yönetilmesine olanak tanır. Dolayısıyla, iş gücü azaltımı yanında daha verimli ve etkin bir denetim süreci de sağlanabilir.

Bu çalışmada belirli sınırlılıklar bulunmaktadır:

Veri Kaynağı: Veri seti sadece Düzce Üniversitesi, Sanat, Tasarım ve Mimarlık Fakültesi – Mimarlık Bölümü öğrencilerinin proje çizimlerinden elde edilmiştir. Bu durum, genel geçerlilik açısından sınırlılık oluşturabilir ve sonuçların genelleştirilebilirliğini etkileyecektir.

Veri Seti Büyüklüğü: Veri setinin artırılması, sonuçların güvenilirliğini ve genelleştirilebilirliğini artırır. Daha büyük bir veri seti, modelin daha geniş bir perspektiften öğrenmesine olanak tanımaktadır.

Ön İşleme ve Model Seçimi: Çalışmada kullanılan ön işleme yöntemleri ve ResNet-50 modeli özel olarak belirlenmiştir. Farklı ön işleme teknikleri veya model seçimleri kullanıldığında sonuçlar değişebilmektedir.

Eğitim ve Test Veri Oranı: Veri seti %85 eğitim verisi ve %15 test verisi olarak ayrılmıştır. Bu oranlar değiştirildiğinde veya farklı veri bölümleri kullanıldığında sonuçlar farklılık gösterebilmektedir.

Çalışma Alanı Sınırlılıkları: Çalışma, sadece mimari uygulama proje çizimleri üzerine odaklanmıştır. Diğer mimari belgeler veya farklı aşamalardaki çizimler ele alınmamıştır. Bu sınırlılıklar çalışmanın kapsamını ve sonuçlarının genelleştirilebilirliğini etkileyebilmektedir.

Teknolojik Sınırlılık: Kullanılan bilgisayarın teknolojik yetenekleri büyük veri setlerini işlemek için yetersiz olabilmekte, bu da analizlerin kapsamını ve veri işleme hızını etkileyebilmektedir.

Çalışmanın sonuçları yorumlanırken bu sınırlılıkların dikkate alınması önemlidir.



9. KAYNAKLAR

- Ahmad, S., Yabar, H., & de Oliveira e Silva, E. (2021). Deep Learning for Building Systems Design Optimization: A Review. *Automation in Construction*, 128, 103760.
- Ahn, C., Park, C., & Jeong, Y. (2020). Deep Learning Applications for Building Performance Prediction: A Review. *Automation in Construction*, 113, 103150.
- Akbarzadeh, M., Moradpour, S., Mohajeri, N., & Fatahi, B. (2020). Evaluating the Impact of Deep Learning in Architecture: A Review of Methods and Applications. *Architectural Science Review*, 63(4), 348-367.
- Alpaydın, E. (2010). *Introduction to Machine Learning*. The MIT Press: Cambridge, Massachusetts; London, England.
- Altaş, D., & Gülpınar, V. (2012). Karar ağaçları ve yapay sinir ağlarının sınıflandırma performanslarının karşılaştırılması: Avrupa Birliği örneği. *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 14(1), 1-22.
- Altuntaş, E., & Çelik, T. (1998). "Yapay zekânın tarihçesi." İstanbul.
- Ambrosius, L. C. (2013). AutoCAD Platform Customization: User Interface, AutoLISP, VBA, and Beyond. Sybex.
- Arıkan Kargı, V. S. (2015). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*. Ekin Yayınevi: Bursa.
- Avşar, V. (2020, Haziran 17). "Uzman Sistemlerde Bilgi Sunma Yöntemleri." www.volkanavsar.com. Erişim Tarihi: [04.07.2022].
- Ayodele, T. O. (2010). *Machine Learning Overview*. INTECH Open Access Publisher.
- Balaban, O., Torunoğlu, D., & Ünsal, C. (2020). Deep Learning-Based Indoor Comfort Prediction in Buildings. *Building and Environment*, 181, 107025.
- Ballı, Müzeyyen Tuğba (2014). "Yapay Sinir Ağları İle Talep Tahmin Ve Gıda Sektöründe Uygulanması", Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Balta, M. (1999). "Mimari Tasarım Sürecinde Bilgisayar Desteği." Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Bayboğan, B. Ç. (2013). *Tip İmar Yönetmeliğine Uygun Vaziyet Planı Üreten Bir Yapay Zeka Destek Sistemi*. Doktora Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

- Baykan, M. O. (2010). *Architectural Design Process: A Practical Guide*. Istanbul: XYZ Publications.
- BeiranvandPour, A., & Yitmen, İ. (2020). Predicting Wayfinding Performance in Complex Indoor Environments: A Deep Learning Approach. *Frontiers of Architectural Research*, 9(4), 664-678.
- Bibel, W. (2014). Artificial Intelligence in a Historical Perspective. *AI Communications*, 87-102.
- Bingöl, K., Er Akan, A., Örmecioğlu, H. T., & Er, A. (2020). Depreme dayanıklı mimari tasarımda yapay zeka uygulamaları: Derin öğrenme ve görüntü işleme yöntemi ile düzensiz taşıyıcı sistem tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 2197-2210.
- Brown, A. (2022). The Impact of Technological Advancements on Architectural Design. *Journal of Architecture and Technology*, 10(2), 45-60.
- Brown, A. B. (2022). The Impact of Artificial Intelligence on Architectural Design Processes. *Journal of Architectural Technology*, 15(2), 45-58.
- Burry, J. (2013). *The New Mathematics of Architecture*. Thames & Hudson.
- Canbeyli, Y., & Yavuz, A. Ö. (2018). Mimarlıkta Yenilikçi Tasarım Yaklaşımları Olarak: Üretken Biçimlendirme Yaklaşımları. *SETSCI Conference Indexing System*, Sayı 2, Ankara, ss. 323-326.
- Chen, X., & Jin, X. (2020). Applying Artificial Neural Networks to Predict User Preferences for Building Design Features. *Automation in Construction*, 116, 103187.
- Chen, Y., & Chen, Y. (2018). Machine Learning Techniques for Sustainable Architecture Design. *Sustainability*, 10(11), 4068.
- Ching, F. D. K. (2014). *Architecture: Form, Space, and Order*.
- Cekmis, A. (2016). Fuzzy logic in architectural site planning design. *12th International Conference on Application of Fuzzy Systems and Soft Computing (ICAFFS)*, Vienna, Austria, s. 176-182.
- Çerçi, A. E. (2022). *Mimari Konum Planı Ön Tasarımında Bir Yapay Zeka Uygulaması*. Yüksek Lisans Tezi. Toros Üniversitesi, Fen Bilimleri Enstitüsü.
- Çoban, T. (2018). Sinemada Yapay Zekâ. Ordu: *Ordu Üniversitesi Sosyal Bilimler Enstitüsü*.
- Derix, C., & Miranda, P. (Eds.). (2019). *Architectural Design and Digital Paradigms*, Proceedings of the 5th International Conference on the Architectural Design and

- Digital Paradigms(pp. 1-488). Springer.
- Dietterich, T. G. (1997). "Machine-learning research." AI Magazine, 18(4), 97.
- Doğan, O. (2016). *Yapay Sinir Ağları*.
- Elmas, Ç. (2003). *Yapay Sinir Ağları*. Ankara: Seçkin Yayıncılık.
- Elmas, S., & Ergen, E. (2020). An Artificial Neural Network-Based Decision Support Model for Urban Design. *Automation in Construction*, 111, 103057.
- Elmas, Ş. Ş. (2019). "Sosyal medya mesajlarının veri madenciliği yöntemi ile duygu analizi (Sivas ili örneği)." Yüksek Lisans Tezi, Sivas Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas, 5-29.
- Garcia, C., & Lee, J. (2024). Future trends in AI-supported design tools in architecture. *International Journal of Architectural Innovation*, 8(3), 112-130.
- Geoffrey E. Hinton, Nitish Srivastava, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov: *Improving neural networks by preventing co-adaptation of feature detectors*. CoRR abs/1207.0580 (2012).
- Ghaffarianhoseini, A., Ghaffarianhoseini, A., AlWaer, H., & Shahrestani, M. (2019). "Artificial Neural Network Modelling in Urban Design: A Review." *Sustainable Cities and Society*, 45, 348-359.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Alabama: Addison Wesley Publishing Company.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gunning, D., Stefik, M., Choi, J., Mille, T., Stumpf, S., & Yang, G.-Z. (2019, Aralık 19). "XAI—Explainable Artificial Intelligence." *Science Robotics*. <https://www.science.org/journal/scirobotics>. Erişim Tarihi: [09.12.2022].
- Gültepe, Y. (2019). "Makine Öğrenemsi Algoritmaları İle Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme." *Avrupa Bilim Ve Teknoloji Dergisi*, 16, 8-15.
- Güner, S. (2018). *Mimari Proje Çizim Teknikleri*. Beta Yayınevi.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. NJ: Pearson Education Inc.
- He, K., X. Zhang, S. Ren, & J. Sun (2015). "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification." *Proceedings of the IEEE international conference on computer vision*.
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor: The University of Michigan Press.

- İçen, D., & Güney, S. (2014). Uzman Sistemler ve İstatistik. *İstatistikçiler Dergisi*, 37-45.
- İşler, B., & Kılıç, M. Y. (2020). Eğitimde Yapay Zekâ Kullanımı Ve Gelişimi. *Yeni Medya Elektronik Dergi*, 1-11.
- Francis, P. (2012). *Urban Open Space: Designing for User Needs*. John Wiley & Sons.
- Jones, J. C. (1980). *Design Methods*. John Wiley & Sons Ltd, New York.
- Jones, L. K. (2021). Balancing creativity and AI in architectural design. *Journal of Design and Technology*, 7(1), 27-36.
- He, K., X. Zhang, S. Ren, and J. Sun (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, 37(9), 1904–1916.
- Huang, W., & Zheng, H. (2018). Architectural drawings recognition and generation through machine learning. In: *Proceedings of the 38th Annual Conference of the Association for Computer Aided Design in Architecture (ACADIA)*, Mexico, 2018, s. 156–16.
- Kalay, Y. (1992). *Evaluating and predicting design performance* (Cilt 1). Canada: WileyInterscience; 1st edition (April 9, 1992).
- Kalay, Y. E. (1992). The Impact of Information Technology on Design Methods, *Products and Practices*. *Design Studies*, 13(2), 125-140.
- Kamara, J. M., Anumba, C. J., & Evbuomwan, N. F. O. (2000). Establishing and Processing Client Requirements-A Key Aspect Concurrent Engineering in Construction. *Engineering, Construction and Architectural Management*, 7(1), ss. 15-28.
- Kisi, O., ve Alizamir, M. (2018). Modelling Reference Evapotranspiration Using a New Wavelet Conjunction Heuristic Method: Wavelet Extreme Learning Machine vs Wavelet Neural Networks. *Agricultural and Forest Meteorology*, 263, 41-48. doi: 10.1016/j.agrformet.2018.08.007.
- Kisi, O., Alizamir, M., ve Zounemat-Kermani, M. (2017). Modeling Groundwater Fluctuations by Three Different Evolutionary Neural Network Techniques Using Hydroclimatic Data. *Natural Hazards*, 87(1), 367-381. doi: 10.1007/s11069-017-2767-9.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- Kwon, S. J. (2011). *Artificial Neural Networks*. Nova Science Publishers, Inc.

- Kwon, S., Cho, Y. K., & Park, M. (2021). Deep Learning for Urban Design: A Review. *Journal of Urban Planning and Development*, 147(4), 04021017.
- Larosa, D. T. (2005). *Discovering Knowledge In Data*, 1st Edition. John Wiley & Sons, New Jersey.
- Lawrence, R. J. (2005). *Aesthetics and Architecture*. New York: Routledge.
- Li, L., Lin, Y., Zheng, N., Wang F., Liu Y., Cao, D., Wang, K., & Huang, W. (2018). "Artificial intelligence test: a case study of intelligent vehicles." *Springer Science+Business Media B.V.*
- Li, Y., Sun, L., & Wei, X. (2019). Using Generative Adversarial Networks (GANs) in Architectural Design: A Review. *Frontiers of Architectural Research*, 8(4), 621-632.
- Liu, X., Xie, H., Yang, J., & Liu, Y. (2020). Deep Learning-Based Multi-Objective Optimization for Building Envelope Design. *Energy and Buildings*, 213, 109898.
- Liu, Y., Wu, C., Chen, Q., & Wu, S. (2021). Deep Learning-Based 3D Reconstruction for Architectural Heritage: A Review. *Journal of Cultural Heritage*, 53, 8-18.
- Lu, Y., Sun, X., & Yao, J. (2019). A Deep Learning Approach for Performance-Driven Architectural Design Exploration. *Automation in Construction*, 105, 102843.
- Mahendra, S. (2019). "Automation — Future of Cybersecurity." Artificial Intelligence +. Erişim Tarihi: [03.07.2023].
- Mahesh, B. (2020). Machine learning algorithms - a review. *International Journal of Science and Research (IJSR)*, 9, 381–386.
- Maltarollo, V. G., Honório, K. M., & Da Silva, A. B. F. (2013). *Applications of Artificial Neural Networks in Chemical Problems*. London: Intechopen.
- Mekawy, M. A., Ismail, A. M., & Elghamrawy, S. M. (2021). Deep Learning for Building Envelope Design: A Review. *International Journal of Architectural Computing*, 1-21.
- MO İstanbul (2015, 26 Ekim). Mimari Proje Çizim ve Sunuş Standartları. [Online] Erişim Tarihi: 20.09.2023, <https://www.mimarist.org/mimari-proje-cizim-ve-sunus-standartlari/>
- Nabiyev, V.V. (2016). *Yapay Zekâ: Problemler, Yöntemler, Algoritmalar*. Ankara: Seçkin Yayıncılık.
- Nguyen, D. T., Reiter, S., & König, R. (2021). Artificial Intelligence in Architecture: A Systematic Review. *Advanced Engineering Informatics*, 49, 101291.
- O'Brien, W., & Sodhi, R. (2021). Investigating the Potential of Convolutional Neural Networks for Architectural Design. *Design Studies*, 77, 100971.

- Oyarzun, D., Cavieres, A., & Hernandez, J. (2020). Applying Artificial Neural Networks to Support Decision-Making in Architectural Design. *Frontiers in Built Environment*, 6, 45.
- Özdemir, İ. (2015). "Fen Ve Teknoloji Öğretmenlerinin Mesleki Tükenmişliğini Etkileyen Değişkenlerin Yapay Sinir Ağı İle Öngörüsü (Zonguldak İl Örneği)." *Doktora tezi*, İlköğretim, Ahi Evran Üniversitesi, Kırşehir, Türkiye.
- Öztemel, E. (2006). *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul.
- Paksın, B. (2020). *Görsel Sanatlarda Yapay Zekâ ve Yaratıcılık İlişkisi*. İzmir: Dokuz Eylül Üniversitesi Güzel Sanatlar Enstitüsü.
- Quan, S., Park, J., Economou, A., & Lee, S. (2019). Artificial intelligence-aided design: Smart Design for sustainable city development. *EPB: Urban Analytics and City Science*, 46(8), 1581-1599.
- Radhamohan, R.S. (2010). Automatic Semiconductor Wafer Map Defect Signature Detection Using a Neural Network Classifier. *Master Thesis*, The University Of Texas At Austin in Partial Fulfillment of the Requirements for the Degree of Master Of Science In Engineering, Texas.
- Radwan, A., & Afify, H. (2019). Deep Learning-Based Approach for Efficient Selection of Façade Cladding Systems. *Automation in Construction*, 101, 71-85.
- Routledge. Gibson, I. (2018). *The Architectural Design Process*. Routledge.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). "Imagenet large scale visual recognition challenge." *International journal of computer vision*, 115, 211-252.
- Sağiroğlu, Ş., Beşdok, E., & Erler, M. (2003). Mühendislikte Yapay Zekâ Uygulamaları-I / Yapay Sinir Ağları. *Ufuk Kitap Kütüphanesi Yayıncılık*, Kayseri.
- Smith, T., & Johnson, R. (2023). The role of AI in optimizing architectural design solutions. *Journal of Architectural Engineering*, 10(4), 87-102.
- Sonali. B. Maind, P. W. (2014). Research Paper on Basics of Artificial Neural Network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 1, 96-100.
- Şahin, M. (2007). "Karakter Tanıma." *Yüksek Lisans Tezi*, Haliç Üniversitesi Fen Bilimler Enstitüsü, İstanbul.
- Tan, F. (2019). Temsilden Simülasyona: Mimarlıkta Yapı Enformasyon Modelleme Etkisi. *Yayımlanmamış Doktora Tezi*, İstanbul Teknik Üniversitesi.
- Tan, M., Adeli, H., & Tasgetiren, M. F. (2020). "Predictive Modeling of Energy Performance of Buildings Using Artificial Neural Networks: A Review."

- Techopedia. (2022, Nisan 30). Artificial Neural Network (ANN). [Online]. Erişim Tarihi: Mayıs 27, 2023, <https://www.techopedia.com/definition/5967/artificial-neural-network-ann>
- Tsai, C. W., & Huang, C. S. (2020). Predicting Visual Aesthetic Scores of Building Facades Using Deep Learning. *Automation in Construction*, 113, 103158.
- Turner, M. (2021). Ethical considerations in the use of AI in architecture. *Journal of Ethical Design*, 5(2), 65-78.
- Tüfekçi, M., & Karpat, F. (2019). *Derin öğrenme mimarilerinden konvolüsyonel sinir ağları (cnn) üzerinde görüntü işleme-sınıflandırma kabiliyetinin artırılmasına yönelik yapılan çalışmaların incelenmesi*. International Conference on Human-Computer Interaction, Optimization and Robotic Applications, 28–31.
- Türkiye Mimarlar Odası. (2020). *Mimari Projelerde Çizim Standartları ve Kuralları*.
- Yurtoğlu, H. (2005). "Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği." *Uzmanlık tezi*, Devlet Planlama Teşkilatı, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara, Türkiye.
- Wang, L. (2019). On the concepts of artificial intelligence and innovative design in product design. *IOP Conf. Series: Materials Science and Engineering*, 573.
- Wei, Y., Bai, Y., Zhang, B., & Zhang, J. (2021). Generative Design for Building Layouts Using Deep Learning: A Review. *Journal of Computing in Civil Engineering*, 35(4), 04021025.
- Zekić, S., & Ognjanović, I. (2021). Deep Learning and Artificial Intelligence in Architectural Design: A Review. *International Journal of Artificial Intelligence in Architecture, Design, and Construction*, 1(1), 1-16.
- Zhang, C., Yu, R., Xiong, J., & Wang, C. (2019). A Review of Deep Learning Techniques for 3D Reconstruction in Architectural Applications. *Automation in Construction*, 106, 102882.
- Zhang, J., Zhang, Y., Li, Y., & Liu, Y. (2021). Generative Design in Architectural Layout Planning Using Machine Learning: A Review. *Archives of Computational Methods in Engineering*, 28(3), 1049-1066.
- Zhang, W., Wang, J., & Jia, X. (2020). Deep Reinforcement Learning for Architectural Design Optimization. *Automation in Construction*, 119, 103342.
- Zhang, X., Wu, P., & Chen, B. (2020). Deep Reinforcement Learning for Optimal Space Layout Design. *Automation in Construction*, 112, 103107.
- Zhang, Y., Janssen, P., & Wei, S. (2020). Applications of Machine Learning in

Architectural Design: A Review. *Advanced Engineering Informatics*, 45, 101113.

Zheng, H. (2018). Drawing with Bots: Human-Computer Collaborative Drawing Experiments. *Artificial Intelligence in Architectural Design*, s. 128-131. Beijing: *The Association for Computer-Aided Architectural Design Research in Asia (CAADRIA)*, Hong Kong.

Zhu, Z., & Gero, J. S. (2019). A Generative Design Approach to Exploring High-Dimensional Design Spaces using Deep Learning. *Computer-Aided Design*, 114, 44-57.



10.EKLER

10.1. EK 1:PROGRAM BAŞLAMA KODU

```
namespace WinFormsApp1
{
    internal static class Program
    {
        ///<summary>
        ///The main entry point for the application.
        ///</summary>
        [STAThread]
        static void Main()
        {
            // To customize application configurations such as set high DPI settings or default font,
            // see https://aka.ms/applicationconfiguration.
            ApplicationConfiguration.Initialize();
            Application.Run(new Form1());
        }
    }
}
```

10.2. EK 2: KÜTÜPHANE EKLEME KODU

```
<ProjectSdk="Microsoft.NET.Sdk">
  <PropertyGroup>
    <OutputType>Exe</OutputType>
    <TargetFramework>net6.0</TargetFramework>
    <ImplicitUsings>enable</ImplicitUsings>
    <Nullable>enable</Nullable>
  </PropertyGroup>
  <ItemGroup>
    <PackageReferenceInclude="Microsoft.ML"Version="1.7.1" />
    <PackageReferenceInclude="Microsoft.ML.Vision"Version="1.7.1" />
    <PackageReferenceInclude="SciSharp.TensorFlow.Redist"Version="2.3.1" />
  </ItemGroup>
  <ItemGroupLabel="MLModel1">
    <NoneInclude="MLModel1.consumption.cs">
      <DependentUpon>MLModel1.mbconfig</DependentUpon>
    </None>
    <NoneInclude="MLModel1.training.cs">
      <DependentUpon>MLModel1.mbconfig</DependentUpon>
    </None>
    <NoneInclude="MLModel1.zip">
      <DependentUpon>MLModel1.mbconfig</DependentUpon>
      <CopyToOutputDirectory>PreserveNewest</CopyToOutputDirectory>
    </None>
  </ItemGroup>
</Project>
```

10.3. EK 3: ARAYÜZ KODU

```
using System;
using System.Collections.Generic;
using System.Linq;
using System.Text;
using System.Threading.Tasks;
using System.Windows.Forms;

namespace Veri
{
    internal class Objekt
    {
        internal Form Form { get; set; }
        internal Label[][] Label { get; set; }
        internal GroupBox[] GroupBox { get; set; }
        internal TextBox TextBox { get; set; }
        internal PictureBox PictureBox { get; set; }
        internal Button[] Button { get; set; }
    }

    internal class Value
    {
        internal static void Fonksiyon(Objekt objekt)
        {
            objekt.Label = new Label[2][];
            objekt.Label[0] = new Label[1];
            objekt.Label[1] = new Label[2];
            objekt.GroupBox = new GroupBox[3];
            objekt.Button = new Button[2];
            objekt.PictureBox = new PictureBox();
            objekt.TextBox = new TextBox();
            objekt.GroupBox[0] = new GroupBox();
            objekt.GroupBox[1] = new GroupBox();
            objekt.GroupBox[2] = new GroupBox();
            objekt.Button[0] = new Button();
            objekt.Button[1] = new Button();
            objekt.Label[0][0] = new Label();
            objekt.Label[1][0] = new Label();
            objekt.Label[1][1] = new Label();

            objekt.GroupBox[0].Controls.Add(objekt.TextBox);
            objekt.GroupBox[0].Controls.AddRange(objekt.Label[0]);
            objekt.GroupBox[0].Controls.AddRange(objekt.Button);
            objekt.GroupBox[1].Controls.Add(objekt.PictureBox);
            objekt.GroupBox[2].Controls.AddRange(objekt.Label[1]);

            objekt.Button[0].Text = "Dosya Sec";
            objekt.Button[1].Text = "Analiz Et";
            objekt.Label[0][0].Text = "Resim Yolu :";
            objekt.GroupBox[0].Text = "Test Verisi";
            objekt.GroupBox[1].Text = "Imar Planı";
            objekt.GroupBox[2].Text = "Analiz Sonucu";

            objekt.PictureBox.SizeMode = PictureBoxSizeMode.StretchImage;
            objekt.Label[0][0].AutoSize = true;

            int Üst_Uzaklık = 30;
            int Sol_Uzaklık = 23;
            int Yükseklik = 30;
            int Aralık = 23;
```

```

Obje.PictureBox.Height = 500;
Obje.PictureBox.Width = 500;
Obje.Label[1][0].Width = 300;
Obje.Label[1][1].Width = 300;
Obje.Button[0].Width = 100;
Obje.Button[1].Width = 100;

Obje.PictureBox.Left = Sol_Uzaklık;
Obje.PictureBox.Top = Üst_Uzaklık;
Obje.Label[0][0].Top = Üst_Uzaklık;
Obje.Label[0][0].Height = Yükseklik;
Obje.Label[0][0].Left = Sol_Uzaklık;
Obje.Label[1][0].Top = Üst_Uzaklık;
Obje.Label[1][0].Height = Yükseklik;
Obje.Label[1][0].Left = Sol_Uzaklık;
Obje.Label[1][1].Height = Yükseklik;
Obje.Label[1][1].Left = Sol_Uzaklık;
Obje.Button[0].Top = Üst_Uzaklık - 4;
Obje.Button[0].Height = Yükseklik;
Obje.Button[1].Top = Üst_Uzaklık - 4;
Obje.Button[1].Height = Yükseklik;
Obje.TextBox.Top = Üst_Uzaklık - 2;
Obje.TextBox.Height = Yükseklik;
Obje.GroupBox[0].Top = Üst_Uzaklık;
Obje.GroupBox[0].Left = Sol_Uzaklık;
Obje.GroupBox[1].Left = Sol_Uzaklık;

Obje.GroupBox[0].Height = Obje.Label[0][0].Bottom + Aralık;
Obje.GroupBox[1].Top = Obje.GroupBox[0].Bottom + Aralık;
Obje.GroupBox[1].Height = Obje.PictureBox.Bottom + Aralık;
Obje.GroupBox[1].Width = Obje.PictureBox.Right + Aralık;
Obje.GroupBox[2].Width = Obje.Label[1][0].Right + Aralık;
Obje.GroupBox[2].Left = Obje.GroupBox[1].Right + Aralık;
Obje.GroupBox[2].Top = Obje.GroupBox[0].Bottom + Aralık;
Obje.Label[1][1].Top = Obje.Label[1][0].Bottom + Aralık;

Obje.GroupBox[2].Height = Obje.GroupBox[1].Height;
Obje.TextBox.Left = Obje.Label[0][0].Right;

Obje.Form.Controls.Add(Obje.GroupBox[0]);
}
}
}

```

10.4. EK 4: ANALİZ KODU

```
using MLModel1_ConsoleApp2;
using Veri;

namespace Forms
{
    public class Grafik
    {
        public static OpenFileDialog OpenFileDialog = new OpenFileDialog();

        public static void Funcion(Form form)
        {
            Objekte Objekte = new Objekte();
            Objekte.Form = form;

            Value.Funcion(Objekte);

            Objekte.Form.Width = Objekte.GroupBox[2].Right + 23 + 23;
            Objekte.GroupBox[0].Width = Objekte.Form.Width - (23 * 2) - 23;
            Objekte.TextBox.Width = Objekte.GroupBox[0].Width - Objekte.Label[0][0].Width - Objekte.Button[0].Width -
            Objekte.Button[1].Width - (23 * 3);
            Objekte.Button[0].Left = Objekte.TextBox.Right + 12;
            Objekte.Button[1].Left = Objekte.Button[0].Right + 12;

            Objekte.Button[0].Click += (s, e) => OpenFileDialog.ShowDialog();
            Objekte.Button[1].Click += (s, e) => Analiz_Et(Objekte);
            OpenFileDialog.FileOk += (s, e) => Dosya(Objekte);
        }

        internal static void Dosya(Objekte Objekte)
        {
            Objekte.TextBox.Text = Convert.ToString(OpenFileDialog.FileName);
            Objekte.PictureBox.Image = Image.FromFile(Objekte.TextBox.Text);

            Objekte.Form.Controls.Add(Objekte.GroupBox[1]);
            Objekte.Form.Height = Objekte.GroupBox[1].Bottom + 70;
        }

        internal static void Analiz_Et(Objekte Objekte)
        {
            var imageBytes = File.ReadAllBytes(Objekte.TextBox.Text);

            MLModel1.ModelInput sampleData = new MLModel1.ModelInput()
            {
                ImageSource = imageBytes,
            };

            var result = MLModel1.Predict(sampleData);

            Objekte.Label[1][0].Text = "Gecersiz Olma olasılığı =" + result.Score[0].ToString();
            Objekte.Label[1][1].Text = "Gecerli Olma olasılığı =" + result.Score[1].ToString();
            Objekte.Form.Controls.Add(Objekte.GroupBox[2]);
        }
    }
}
```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Seservan BARIN EKİN

Yabancı Dili : İngilizce

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Y. Lisans	Mimarlık Anabilim Dalı	Düzce Üniversitesi	2024
Lisans	Mimarlık	İstanbul Gelişim Üniversitesi	2020
Lise	Matematik- Fen	Selami Değer Anadolu Lisesi	2014

YAYINLAR

Diğer Yayınlar

Seservan Barın, Aleyna Köseoğlu, Ali Fatih Uysal.(2018).*Kentsel Dönüşüm Alanlarında Akıllı Şehir Uygulamalarının Dezavantajlı Gruplar Açısından İrdelenmesi: Gaziosmanpaşa Örneği*. Akıllı Ulaşım Sistemleri Konferansı.

Tezden Çıkan Yayın

Seservan Barın Ekin, Nuray Benli Yıldız.(2023).*Yapay Zekâ Uygulamalarının Mimari Tasarım Sürecine Faydasının Örnekler Üzerinden İncelenmesi*. Mimarlık, Planlama ve Tasarımda Öncü ve Çağdaş Çalışmalar, Bölüm 1, ss. 5-27, Duvar Yayınları, Ankara.