

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MİMARLIK
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MİMARLIKTA MAKİNE ÖĞRENMESİ VE KULLANIMININ
2007-2023 YILLARI ARASINDA YAPILAN ÇALIŞMALAR
ÜZERİNDEN DEĞERLENDİRİLMESİ

BEYZA TOPUZ

KOCAELİ 2024

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MİMARLIK
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MİMARLIKTAKİ MAKİNE ÖĞRENMESİ VE KULLANIMININ
2007-2023 YILLARI ARASINDA YAPILAN ÇALIŞMALAR
ÜZERİNDEN DEĞERLENDİRİLMESİ

BEYZA TOPUZ

Prof. Dr. Neşe ÇAKICI ALP

Danışman, Kocaeli Üniversitesi

.....

Doç. Dr. Sonay AYYILDIZ

Jüri Üyesi, Kocaeli Üniversitesi

.....

Doç. Dr. Orkan Zeynel GÜZELCİ

Jüri Üyesi, İstanbul Teknik Üniversitesi

.....

Tezin Savunulduğu Tarih: 24.06.2024

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
 - Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
 - Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
 - Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
 - Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
 - Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,
- beyan ederim.

☒ Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler tarafından no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

Beyza TOPUZ

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı, danışmanımın isim hakkı saklı kalmak koşuluyla ve her iki tarafın bilgisi dâhilinde bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan **“Lisanüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.

☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.

☒ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

.....

Beyza TOPUZ

ÖNSÖZ VE TEŞEKKÜR

Yapılan tez çalışmasında, günümüzde birçok meslek alanında yer edinen yapay zeka teknolojilerinden olan makine öğrenmesinin mimarlık mesleğinde kullanımını ele alınmaktadır. Bu çalışmada, mimarlığın hangi alt alanlarında makine öğrenmesi kullanıldığı ve bu alt alanlardaki problemlerin çözümü için hangi makine öğrenmesi modelleri ile araç ve tekniklerinin kullanıldığını belirleyebilmek adına kapsamlı bir sistematik araştırma gerçekleştirilmiştir.

Lisans ve yüksek lisans eğitimim boyunca zaman ve mekan fark etmeksizin beni destekleyen, zor zamanlarımda beni motive ederek yol gösteren, bilgisini ve tecrübelerini benimle paylaşmaktan mutluluk duyan, başarıları ile kendime örnek aldığım ve çok sevdiğim tez danışmanım kıymetli Prof. Dr. Neşe ÇAKICI ALP'e teşekkürlerimi sunarım.

Tez savunmama katılarak kritik noktalarda getirdikleri eleştiriler ile tezimin son şeklini almasını sağlayan değerli hocalarım Doç. Dr. Sonay AYYILDIZ'a ve Doç. Dr. Orkan Zeynel GÜZELCİ'ye teşekkürlerimi sunarım. Ayrıca tez sürecinin tüm güzelliklerini ve zorluklarını beraber geçirdiğim sevgili arkadaşlarıma çok teşekkür ederim.

Hayatım boyunca yaşadığım zor zamanları, başarıları ve mutlulukları benimle paylaşarak her anımda yanımda duran ve evlatları olmaktan gurur duyduğum canım annem Dilek TOPUZ'a ve canım babam İbrahim TOPUZ'a en özel ve anlamlı teşekkürlerimi ediyorum.

Haziran – 2024

Beyza TOPUZ

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vi
TABLolar DİZİNİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ.....	viii
ÖZET.....	xi
ABSTRACT	xii
1. GİRİŞ.....	1
1.1. Amaç ve Kapsam.....	2
1.2. Yöntem ve İçerik	3
2. YAPAY ZEKA TEKNOLOJİLERİ	4
3. MAKİNE ÖĞRENMESİ.....	7
3.1. Makine Öğrenmesi ile İlgili Temel Kavramlar.....	7
3.2. Makine Öğrenmesi Modelleri.....	9
3.3. Makine Öğrenmesi Yöntemleri ve Kullanılan Algoritmalar	11
3.3.1. Denetimli Makine Öğrenmesi	12
3.3.2. Denetimsiz Makine Öğrenmesi	13
3.3.3. Yarı Denetimli Makine Öğrenmesi	15
3.3.4. Pekiştirmeli (Takviyeli) Makine Öğrenmesi.....	16
3.3.5. Derin Öğrenme Modeli	16
4. METODOLOJİ.....	20
4.1. Araştırma Soruları	20
4.2. Literatür Araştırma Kriterlerinin Oluşturulması.....	21
4.2.1. Akademik Arama ve Yayınlanma Platformları.....	21
4.3. İlgili Çalışmaların Seçilmesi ve Detaylı İncelenmesi.....	22
4.4. Mimarlıkta Makine Öğrenmesi Kullanımının Değerlendirilmesi	22
5. ANALİZLER.....	23
5.1. Literatürdeki Makine Öğrenmesi ile İlgili Seçilen Makalelerin İncelenmesi	23
5.2. Mimarlıkta Makine Öğrenmesi ile İlgili Literatürün İncelenmesi	25
5.3. Araştırma Sorularının Cevaplandırılması	60
5.3.1. Makine Öğrenmesi Kullanılan Mimarlık Alanları (AS1)	61
5.3.2. Mimarlıkta Kullanılan Makine Öğrenmesi Modelleri (AS2).....	63
5.3.3. Mimarlıkta Kullanılan Makine Öğrenmesi Araç ve Teknikleri (AS3)	65
5.3.3.1.Mimarlıkta Kullanılan Yazılımlar ve Makine Öğrenmesi Algoritmaları.....	66
5.3.3.2.Mimarlıkta Kullanılan Programlama Kütüphaneleri	68
5.3.3.3.Mimarlıkta Kullanılan Programlama Dilleri ve Makine Öğrenmesi Algoritmaları	70
5.3.3.4.Mimarlıkta Kullanılan Programlama Platformları ve Makine Öğrenmesi Algoritmaları	75
6. TARTIŞMA.....	77
7. SONUÇLAR VE ÖNERİLER	84
KAYNAKLAR.....	86

KİŞİSEL YAYIN VE ESERLER.....	102
ÖZGEÇMİŞ.....	103



ŞEKİLLER DİZİNİ

Şekil 3.1.	Denetimli makine öğrenmesi çalışma prensibi	12
Şekil 3.2.	Denetimsiz makine öğrenmesi çalışma prensibi	14
Şekil 3.3.	Yarı denetimli makine öğrenmesi çalışma prensibi	15
Şekil 3.4.	Pekiştirmeli makine öğrenmesi çalışma prensibi	16
Şekil 3.5.	Derin öğrenme modelinin çalışma prensibi.....	17
Şekil 3.6.	Yapay zeka ile makine öğrenmesi ve yöntemleri ilişkisi	18
Şekil 3.7.	Makine öğrenmesi yöntemleri ve yöntemlerde kullanılan algoritmalar ilişkisi	19
Şekil 4.1.	Tez çalışmasının metodolojisi	20
Şekil 5.1.	Makalelerin yayınlandığı yılların dağılımı	23
Şekil 5.2.	Yayın türlerinin dergi ve konferansa göre dağılımı	24
Şekil 5.3.	Çalışma sayısı ile akademik arama ve yayınlanma platformları dağılımı	25
Şekil 5.4.	Çalışmaların yapıldığı ülkeler grafiği	25
Şekil 5.5.	İncelenen 86 makaledeki mimarlığın alt alan nicelikleri	61
Şekil 5.6.	Çalışmalarda kullanılan makine öğrenmesi modelleri	63
Şekil 5.7.	Çalışma alanları ve kullanılan makine öğrenmesi modelleri	64
Şekil 5.8.	Çalışmalarda kullanılan makine öğrenmesi araç ve teknikleri.....	65
Şekil 5.9.	Çalışmalarda kullanılan yazılımlar ve makine öğrenmesi algoritmaları	67
Şekil 5.10.	Çalışmalarda kullanılan programlama kütüphaneleri.....	69
Şekil 5.11.	Çalışmalarda kullanılan programlama dilleri ve makine öğrenmesi algoritmaları	70
Şekil 5.12.	PYTHON programlama dili kullanan çalışmalar	72
Şekil 5.13.	MATLAB programlama dili kullanan çalışmalar	73
Şekil 5.14.	C# programlama dili kullanan çalışmalar	74
Şekil 5.15.	R programlama dili kullanan çalışmalar	75
Şekil 5.16.	Çalışmalarda kullanılan programlama platformları	76
Şekil 6.1.	Makine öğrenmesi modelleri ile mimarlık alt alanları eşleştirmesi	79
Şekil 6.2.	Çalışmalarda kullanılan makine öğrenmesi algoritmaları.....	82
Şekil 6.3.	Makine öğrenmesi araç ve teknikleri ile makine öğrenmesi modelleri ilişkisi.....	83

TABLÖLAR DİZİNİ

Tablo 4.1.	Araştırma soruları.....	21
Tablo 4.2.	Dahil etme ve hariç tutma kriterleri	22
Tablo 5.1.	Çalışma numarası ve referans eşleştirilmesi	60
Tablo 5.2.	Çalışma numaraları ve mimarlığın alt alanları ilişkisi	62
Tablo 6.1.	Makine öğrenmesi modellerinin özellikleri	78
Tablo 6.2.	Yazılımların kullanım alanlarına göre sınıflandırılması	81
Tablo 6.3.	Makine öğrenmesi araç ve teknikleri ile makine öğrenmesi modellerinin özellikleri.....	83



SİMGELER VE KISALTMALAR DİZİNİ

%	: Yüzde işareti
R^2	: Determinasyon katsayısı

Kısaltmalar

ABR	: AdaBoost Regressor (AdaBoost Regresyon)
AHP	: Analytic Hierarchy Process Method (Analitik Hiyerarşi Süreci Yöntemi)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
BIM	: Building Information Modelling (Yapı Bilgi Modellemesi)
BPNN	: Backpropagation Neural Network (Geri Yayılım Sinir Ağı)
CAAD	: Computer-Aided Architectural Design (Bilgisayar Destekli Mimarlık Tasarımı)
CAD	: Computer-Aided Design (Bilgisayar Destekli Tasarım)
CAE	: Computer-Aided Engineering (Bilgisayar Destekli Mühendislik)
CAM	: Computer-Aided Manufacturing (Bilgisayar Destekli Üretim)
CBML	: Component-Based Machine Learning (Bileşen Tabanlı Makine Öğrenimi)
CCA	: Canonical Correlation Analysis (Kanonik Korelasyon Analizi)
CFD	: Computational Fluid Dynamics (Hesaplamalı Akışkanlar Dinamiği)
CIAC	: Constructive Interactive Activation and Competition (Yapıcı Etkileşimli Aktivasyon ve Rekabet)
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağı)
Conv	: Convolutional Layer (Evrişim Katmanı)
Conv-MPN	: Convolutional Message Passing Networks (Evrişimli Mesaj Aktaran Sinir Ağları)
DBSCAN	: Density-Based Spatial Clustering Of Applications With Noise (Gürültülü Yoğunluk Tabanlı Uzaysal Kümeleme)
DCNN	: Deep Convolutional Neural Network (Derin Evrişimli Sinir Ağı)
DES	: Differential Evolution Strategy (Farklılaşan Evrim Stratejisi)
DGCNN	: Deep Graph Convolutional Neural Network (Derin Grafik Evrişimli Sinir Ağı)
DNN	: Deep Neural Network (Derin Sinir Ağı)
DT	: Decision Trees (Karar Ağaçları)
DTR	: Decision Trees Regressor (Karar Ağaçları Regresyonu)
ELM	: The Extreme Learning Machine (Aşırı Öğrenme Makinesi)
ETR	: Extra Tree Regressor (Ekstra Ağaç Regresyonu)
ERT	: Extremely Randomized Trees (Aşırı Derecede Rastgele Ağaçlar)
Faster-RCNN	: Faster Region-based Convolutional Neural Network (Hızlı Bölge Tabanlı Evrişimli Sinir Ağı)
FCM	: Fuzzy C-means (Bulanık C-Ortalamlar)
FIS	: Fuzzy Inference Systems (Bulanık Çıkarım Sistemleri)
FPN	: Feature Pyramid Network (Özellik Piramit Ağı)
GA	: Genetic Algorithms (Genetik Algoritmalar)
GAN	: Generative Adversarial Network (Üretken Çekişmeli Ağ)

GB	: Gradient Boosting (Gradyan Artırma)
GBR	: Gradient Boosting Regressor (Gradyan Artırma Regresyonu)
GENLINE	: Generalized Linear Model (Genelleştirilmiş Doğrusal Model)
GMM	: Gaussian Mixture Model (Gaussian Karışım Modeli)
GNN	: Graph Neural Network (Grafik Sinir Ağı)
GPR	: Gaussian Process Regression (Gaussian Süreç Regresyonu)
GRNN	: General Regression Neural Network (Genel Regresyon Sinir Ağı)
K-NN	: K-Nearest Neighbor (K-En Yakın Komşu)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
Mask R-CNN	: Mask Region-based Convolutional Neural Network (Maske Bölge Tabanlı Evrişimli Sinir Ağı)
MCD method	: Method of Characterization Decomposition (Karakterizasyon Ayrıştırma Yöntemi)
ML	: Makine Öğrenmesi
MLP	: Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
MLP ANN	: Multi Layer Perceptron Artificial Neural Network (Çok Katmanlı Algılayıcı Yapay Sinir Ağı)
MLR	: Multiple Linear Regression (Çoklu Doğrusal Regresyon)
MOO	: Multi Objective Optimization (Çok Amaçlı Optimizasyon)
MOPSO	: Multi Objective Particle Swarm Optimization (Çok Amaçlı Parçacık Sürü Optimizasyonu)
MRF	: Markov Random Field (Markov Rastgele Alanı)
MSHD method	: Method of Spatial Homogenization Decomposition (Uzaysal Homojenleştirme Ayrıştırma Yöntemi)
MTL	: Multi Task Learning (Çoklu Görev Öğrenimi)
NSGA	: Non-dominated Sorting Genetic Algorithm (Hakim Olmayan Sıralama Genetik Algoritması)
OLS	: Orthogonal Least Squares (Ortogonal En Küçük Kareler)
PCA	: Principal Components Analysis (Temel Bileşenler Analizi)
PSO	: Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
RANSAC	: Random Sample Consensus (Rastgele Örnek Uygunluğu)
RBFN	: Radial Basis Function Network (Radyal Taban Fonksiyon Ağı)
RBFNN	: Radial Basis Function Neural Network (Radyal Taban Fonksiyon Sinir Ağı)
ReLu	: Rectified Linear Unit (Düzeltilmiş Doğrusal Birim)
ResNet	: Residual Network (Artık Ağ)
RF	: Random Forest (Rastgele Orman)
RFR	: Random Forest Regressor (Rastgele Orman Regresyonu)
RPN	: Region Proposal Network (Bölge Öneri Ağı)
SA	: Simulated Annealing (Simüle Edilmiş Tavlama)
SADM	: Sensitivity Analysis-Based Decision Making (Duyarlılık Analizi Tabanlı Karar Verme)
SASTIM	: Self-Adaptive Sparse Trans Form Module (Öz Uyarlamalı Seyrek Dönüşüm Modülü)
SCB	: Structured Convolution Block (Yapısal Evrişim Bloğu)
SHAP	: SHapley Additive exPlanations (SHapley Katkı Açıklamaları)
SIFT	: Scale-Invariant Feature Transform (Ölçek Benzeri Özellik Dönüşümü)
SVC	: Support Vector Classifier (Destek Vektör Sınıflandırıcı)

SVM	: Support Vector Machine (Destek Vektör Makinesi)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
t-SNE	: t-distributed Stochastic Neighbor Embedding (t-dağılımlı Stokastik Komşuluk Gömme)
WGAN	: Wasserstein Generative Adversarial Network (Wasserstein Üretken Çekişmeli Ağ)
XGB	: Extreme Gradient Boosting (Aşırı Gradyan Artırma)
YOLO	: You Only Look Once (Bir Kere Bakma)



MİMARLIKTAKİ MAKİNE ÖĞRENMESİ VE KULLANIMININ 2007-2023 YILLARI ARASINDA YAPILAN ÇALIŞMALAR ÜZERİNDEN DEĞERLENDİRİLMESİ

ÖZET

Gelişen yazılım ve bilişim teknolojileri birçok meslekte olduğu gibi mimarlık mesleğinde de önemli bir araç haline gelmiştir. Geleneksel çizim yöntemlerinden bilgisayar destekli ortamlara geçiş, Bilgisayar Destekli Tasarım (CAD), Bilgisayar Destekli Mühendislik (CAE) ve Bilgisayar Destekli Üretim (CAM) teknolojilerinin tasarımdan üretime kadarki tüm süreçlerde bir dönüşüm gerçekleştirmiştir. Bu teknolojilere ek olarak, yapay zekanın mimari tasarım sürecine entegre edilebilmesi için mimarlık mesleğinin farklı alt alanlarındaki çalışmaların giderek arttığı bilinmektedir. Bu tez çalışmasında ise yapay zekanın bir alt teknolojisi olan makine öğrenmesinin mimarlıkta kullanımını araştırmak ve incelemek üzere dört aşamalı metodolojiye sahip bir literatür taraması gerçekleştirilmiştir. 2007'den 2023'e kadar olan dönemi kapsayan dokuz büyük akademik arama ve yayınlama platformu sistematik olarak incelenmiştir ve sonuçta 232 çalışmalık bir havuzdan 86 ilgili çalışma seçilmiştir. Seçim işlemi yapılırken araştırma kriterleri ile dahil etme ve hariç tutma kriterlerine uygun olan çalışmalar dikkate alınmıştır. Seçilen çalışmaların, makine öğrenmesinin mimarlık mesleğinde hangi alanlardaki sorunları ele aldığı, sorunları ele alırken hangi makine öğrenmesi modellerinin seçildiği ve problemlerin çözümü için hangi yazılımlar, programlama kütüphaneleri, programlama dilleri, programlama platformları ve algoritmalarının kullanıldığına ilişkin oluşturulan üç araştırma sorusuna verdikleri yanıtlar detaylı olarak analiz edilmiştir. Analiz sonucunda 22 farklı mimari alt alanda makine öğrenmesi kullanıldığı, bu alt alanlardaki problemlerin çözümü için 9 farklı makine öğrenmesi modeli, 36 farklı yazılım, 33 farklı makine öğrenmesi kütüphanesi, 4 farklı programlama dili, 8 farklı makine öğrenmesi platformu ve 113 farklı makine öğrenmesi algoritması kullanıldığı tespit edilmiştir. Mimarlıkta makine öğrenmesi kullanımının, literatürden seçilen 86 çalışma üzerinden değerlendirilmesi yapılarak gelecekteki çalışmalar için öneriler sunulmuştur.

Anahtar Kelimeler: Makine Öğrenmesi Araç ve Teknikleri, Makine Öğrenmesi Modelleri, Mimarlık Alt Alanları, Mimarlıkta Makine Öğrenmesi, Sistematik İnceleme.

ASSESSING THE INTEGRATION OF MACHINE LEARNING IN ARCHITECTURAL PRACTICE: A REVIEW OF RESEARCH FROM 2007 TO 2023

ABSTRACT

The advancement of software and information technologies has become a significant asset in the field of architecture, like many other professions. The shift from traditional drawing techniques to computer-aided environments has revolutionized all stages from design to production through Computer-Aided Design (CAD), Computer-Aided Engineering (CAE), and Computer-Aided Manufacturing (CAM) technologies. Furthermore, research in various sub-disciplines of architecture is increasingly focusing on integrating artificial intelligence (AI) into the design process. This thesis employs a four-stage literature review methodology to explore the application of machine learning, a subset of AI, in architecture. A comprehensive examination of nine major academic search and publishing platforms covering the years 2007 to 2023 yielded 86 relevant studies out of 232 initially identified. The selection was based on specific research and inclusion-exclusion criteria. The selected studies were analyzed to answer three research questions: the architectural problems addressed by machine learning, the machine learning models used, and the software, programming libraries, languages, platforms, and algorithms employed. The analysis revealed that machine learning has been applied in 22 different architectural sub-fields, utilizing 9 different machine learning models, 36 different software tools, 33 machine learning libraries, 4 programming languages, 8 machine learning platforms, and 113 algorithms. The evaluation of these 86 studies highlights the current use of machine learning in architecture and provides recommendations for future research.

Keywords: Machine Learning Tools and Techniques, Machine Learning Models, Architecture Subfields, Machine Learning in Architecture, Systematic Review.

1. GİRİŞ

Bilgisayar ve yazılım teknolojilerinin çeşitli profesyonel alanlara entegre edilmesi ile bilgiye erişim ve bilgiyi işleme yeteneği büyük ölçüde geliştirilmiştir. Bu ilerleme, bilgisayarların mimarlık da dahil olmak üzere hemen hemen her disiplinde bir araç olarak kullanılmasına yol açmıştır. Birçok farklı disiplinde kullanılmaya başlanılan bilgisayarların tasarım, üretim ve mühendislik alanlarına dahil edilmesi ile Bilgisayar Destekli Tasarım (CAD), Bilgisayar Destekli Üretim (CAM) ve Bilgisayar Destekli Mühendislik (CAE) sistemleri ortaya çıkmıştır.

CAD sistemi, bir tasarımın oluşturulmasına, değiştirilmesine, analizine veya optimizasyonuna yardımcı olmak için bilgisayarların kullanılmasını gerektiren sistem olarak tanımlanmıştır (Sarkar ve diğ., 2008). Bu sistemlerde, eskiz, tasarım, modelleme, uygulama ve animasyon aşamalarından oluşan tasarımın tüm süreçlerinde bilgisayarların araç olarak kullanıldığı görülmektedir (Aydoğan, 2006). Kullanıcıların bilgisayarlara verdiği komutlarla şekiller ve semboller kullanarak veriler görselleştirebilir ve bu görseller üzerinde büyültme, döndürme, renklendirme gibi görevler kullanılarak istenildiği gibi değişiklikler yapılabilmektedir (Keskinel, 1985).

CAM sistemi, üretim fonksiyonları olan planlama ve programladan süreç izleme ve kontrolüne kadarki tüm üretim süreçlerinde bilgisayar teknolojilerinin kullanılması şeklinde tanımlanmaktadır (Painter ve diğ., 1994; Lee-Post, 2003). Kullanıcıların bilgisayar destekli olarak tasarladıkları bilgi tabanlı modellerin strüktürel veya mekanik ihtiyaçlarına göre düzenlenmesi ve üretim yapılacak hale getirilmesi ile tasarımların uygulamaları çeşitli makineler kullanılarak fabrika ortamında gerçekleştirilmektedir (Akipek, 2004).

CAE sistemi, bilgisayar destekli oluşturulan tasarımların performans simülasyonları ve güvenilirlik değerlendirmeleri yapılması ile tasarım çözümlerinin oluşturulması, doğrulanması ve optimize edilmesi şeklinde tanımlanmaktadır (Kwon ve Kwon, 2019; Chang, 2014). Sıcaklık, gerinim, ısı transferi, elektrik alanları gibi mühendislik hesaplamaları gerektiren karmaşık denklemlerin çözümlenebilmesi için bilgisayar destekli analiz ve simülasyon programlarından yararlanılarak tasarımların geometrik, fiziksel ve çevresel özellikleri modellenebilmektedir (Bahman ve Iannuzzo, 2018).

Daha önce elle çizime dayanan geleneksel mimari tasarım sürecine bilgisayarların dahil edilmesi ile birlikte CAD sistemleri ile bilgisayarlar hem görselleştirme aracı olarak hem de hesaplamalı bir tasarım ortamı olarak kullanılmaya başlanılmıştır (Akipek ve İncoğlu, 2007). Dijital ortamlarda üç boyutlu tasarlanan modellerin mühendislik analizleri için CAE sistemlerinden yararlanılmaktadır (Vergunova ve Blinova, 2018). Tasarımları ve analizleri tamamlanan modelin 3D yazıcılar, CNC makineler vb. üretim ekipmanları için gerekli hazırlıkların yapılabilmesi ve üretimin takibi için CAM sistemlerinden yararlanılmaktadır (Afify ve Abd Elghaffar, 2007). Mimarlık mesleğinde görüldüğü üzere tasarım, analiz ve üretimden oluşan tüm mimari süreçlerde bilgisayar teknolojilerinden yararlanılmaktadır.

CAD, CAE ve CAM sistemlerine ek olarak yapay zeka teknolojilerinin gelişmesi ile bilgisayarlar insanlar gibi düşünebilir ve hareket edebilir hale gelmiştir, bu da sorunların anlaşılmasına ve çözülmesine olanak tanımaktadır (Nabiyev, 2012). Yapay zekanın bir alt teknolojisi olan makine öğrenimi, bilgisayar destekli makinelerdeki sorunları çözmek için verilerin kullanılmasını içermekte ve öğrenme modeli geliştirilmektedir (Atalay ve Çelik, 2017). Makine öğrenmesi algoritmaları, verilerin toplanması ve analiz edilmesi sayesinde geçmiş deneyimlerine dayanarak kararlar alabilme ve en doğru çözümleri üretebilme yeteneğine sahiptir. Makine öğrenmesi algoritmalarının sorunu etkili bir şekilde çözebilmesi için, soruna ilişkin veri setindeki özelliklerin doğru seçilmesi ve yeterli sayıda olması önemli bir kriterdir. Makine öğrenmesi bilim ve tıp, otomatik, mühendislik, satış ve pazarlama, inşaat, mimarlık gibi çeşitli meslek alanlarında yaygın olarak kullanılmaktadır (Sammut ve Webb, 2011).

1.1. Amaç ve Kapsam

Gelişen bilgisayar ve yapay zeka teknolojileri ile üretilen makineler, insan gibi düşünebilmesi, yorum yapabilmesi, sorunlara çözüm üretebilmesi sayesinde birçok meslek alanında kullanılır hale gelmiştir.

Bilgisayar teknolojilerinden olan bilgisayar destekli tasarım, üretim ve mühendislik sistemleri, mimarlık mesleğinde hem bir araç olarak hem de sayısal hesaplamalardan oluşan bir tasarım ortamı olarak kullanılmaktadır. Yapay zeka teknolojilerinin mimarlık mesleği ile entegre edilebilmesi için ilgili çalışmaların giderek arttığı görülmektedir.

Bu kapsamda yapılan tez çalışmasının amacı, yapay zeka teknolojilerinden biri olan makine öğrenmesinin mimarlık mesleğinde kullanımını analiz edebilmek adına sistematik bir araştırma gerçekleştirmektir. Dört aşamadan oluşan araştırma metodolojisi kullanılarak mimarlık mesleğinde makine öğrenmesi kullanımına ilişkin 2007-2023 yılları arasında yapılan çalışmaların belirlenmesi ile tez çalışmasının sınırları belirlenmiştir. Sistematik araştırma sonucunda elde edilen çalışmaların kapsamlı analiz edilmesi ile mimarlık ve makine öğrenmesi ilişkisi değerlendirilmiştir.

1.2. Yöntem ve İçerik

Bu tez çalışmasında, üç araştırma sorusu oluşturulup makine öğrenmesinin mimarlıkta kullanımını incelemek ve analiz etmek amaçlanmaktadır. Giriş kısmından sonra yapay zeka ve makine öğrenmesi hakkında temel bilgilendirme bölümleri yer almaktadır. Ardından tez çalışmasının çalışma metodolojisi açıklanmıştır. Dört aşamalı çalışma metodolojisi, belirli araştırma kriterlerinin oluşturulması, dahil etme ve hariç tutma kriterlerine göre ilgili çalışmaların seçilmesi, 2007 ile 2023 yıllarını kapsayan dokuz büyük akademik arama ve yayınlama platformundan seçilen çalışmaların detaylı analizlerinin gerçekleştirilmesi ve araştırma sorularına verdikleri yanıtlar üzerinden mimarlıkta makine öğrenmesi kullanımının değerlendirilmesi şeklindedir.

Çalışma metodolojisinde oluşturulan üç araştırma sorusu ile mimarlık mesleğinin hangi alanlarında ve hangi problemlerine makine öğrenmesi ile çözüm aranmış olduğu, bu problemlere çözüm aranırken hangi makine öğrenmesi modellerinin kullanıldığı ve hangi yazılımlar, programlama kütüphaneleri, programlama dilleri, programlama platformları ve makine öğrenmesi algoritmalarının kullanıldığı tespit edilmiş olup alluvial ve chord grafik türleri ile görselleştirilerek analiz edilmiştir. Mimarlık mesleğinin alt alanlarında ele alınan problemlerin çözümü için makine öğrenmesi kullanılan çalışmaların, bilgisayar teknolojileri olan CAD, CAM ve CAE sistemleri ile eşleştirilmesi yapılarak bilgisayar ve yapay zeka teknolojilerinin ilişkisi belirlenmiştir. Bu tez çalışmasının sonuçları ile mimarlık alanında makine öğreniminin kullanımına odaklanan gelecekteki araştırmalar için referans olacak bilgiler sağlaması beklenmektedir.

2. YAPAY ZEKA TEKNOLOJİLERİ

Literatürde "Artificial Intelligence" olarak adlandırılan yapay zeka, bir insan bedenin fizyolojik ve nörolojik sisteminin çalışma prensiplerini temel alarak insan gibi davranabilen, düşünebilen, karar verebilen, tecrübe edinebilen ve tüm bu özelliklerin bilgisayar bilimleri kullanılarak hesaplamalı makine ortamlarına aktarılması şeklinde tanımlanabilir. Turing'in (1950) çalışmasında, makinelerin düşünebilir olup olmadığı sorusu tartışılmakla beraber insana özgü niteliklerin makinelere aktarılabilme düşüncesi geliştirilmiştir. 1956 yılında John McCarthy tarafından ilk kez kullanılan yapay zeka kavramı, akıllı makinelerin ve özellikle akıllı bilgisayar programlarının yapımıyla ilgilenen bilim ve mühendislik alanı şeklinde tanımlanmıştır (Güven ve diğ., 2024). Russell ve Norvig (2010) tarafından yapılan çalışmada ise yapay zekaya yönelik yaklaşımlar, insan gibi düşünmek "thinking humanly", insan gibi davranmak "acting humanly", rasyonel düşünmek "thinking rationally", rasyonel davranmak "acting rationally" şeklinde dört kategoride ele alınmıştır.

Yapay zeka teknolojileri üzerinde yapılan çalışmalar geçmişten günümüze giderek artması ile birlikte yapay zeka uygulamaları da artmaktadır. Öztemel'in (2020) yapmış olduğu çalışmada,

- Yorum yapabiliyor, problem çözebiliyor, ilişki kurabiliyor karar verebiliyor (uzman sistemler).
- Öğrenebiliyor (yapay sinir ağları ve diğer makine öğrenmesi teknikleri).
- Bildiğimiz bilgisayarların çözemediği karmaşık problemlere çözümler üretebiliyor (genetik algoritmalar).
- Kelimeleri anlayabiliyor. Kelimelere göre işlem yapabiliyor (bulanık önermeler mantığı).
- Merdiven çıkabiliyor, top oynayabiliyor, sorulara cevap verebiliyor, haberleşebiliyor... (zeki etmenler)
- Metinleri okuyabilir, anlamlandırabilir, öğretebilir (doğal dil işleme).
- Algılayabiliyor, önceliklendirebiliyor, odaklanabiliyor (bilgisayar görme)

yapay zekanın yeteneklerine göre uzman sistemler, makine öğrenmesi ve yapay sinir ağları, genetik algoritmalar, bulanık önermeler mantığı, zeki etmenler, doğal dil işleme, bilgisayar görmesi şeklinde yapay zeka uygulamaları ele alınmıştır.

Uzman Sistemler, bir problemin çözümü için bir uzmanın bilgi ve yeteneklerini referans alarak çıkarım yapabilen yapay zeka alt alanıdır (İnce ve diğ., 2020). Uzmanlık sistemlerinde karar mekanizması, bilgi tabanı ve ara yüz olmak üzere üç kısımdan oluşan

bir mimariye sahiptir (Önder, 2003). Temel çalışma prensibinde kullanıcılar tarafından uzman sistemlere durum bilgisi verilmesi ve geri dönüş olarak uzman tavsiyesi alınması şeklinde karşılıklı bir iletişim mevcuttur (İçen ve Günay, 2014).

Makine Öğrenmesi, bir problemin çözümü için o probleme ait veriler kullanarak öğrenme gerçekleştirilen ve öğrendiklerine göre problemleri çözebilen sistemlerdir. Makine öğrenmesinde öğrenme ve test aşaması şeklinde iki aşamadan oluşmakla beraber temel olarak veri girişi, ön işleme, özellik çıkarma-seçim, eğitim ve test süreçlerine sahiptir (Kokkotis ve diğ., 2020). Nesne tanıma, sınıflandırma, analiz, tıbbi teşhis gibi farklı uygulama alanlarında makine öğrenmesi kullanılmaktadır (Shinde ve Şah, 2018).

Yapay Sinir Ağları, insanın nörolojik sisteminin çalışma prensibi temel alınarak oluşturulan ve bilgilerin sinir ağları üzerinden birbirlerine aktarılması ile öğrenebilme, genelleme yapabilme, değişkenlerle çalışabilme vb. özelliklerine sahip olan yapay zeka alt alanıdır (Ataseven, 2013). Giriş katmanı, saklı katman ve çıkış katmanından oluşan mimariye sahip olup bu katmanlar arası bağlantıyı sinir hücreleri ile sağlanmaktadır (Şen, 2004). Yapay sinir ağları sınıflandırma, tanıma, tahmin optimizasyon gibi matematiksel hesaplamalar için kullanılmaktadır (Başoğlu ve Bulut, 2017).

Genetik Algoritmalar, insan genetiğinde yer alan kromozom, gen, aktarım, kodlanma, çaprazlanma, populasyon gibi özellikleri referans alarak problemleri çözmeye çalışan yapay zeka sistemleridir (İşçi ve Korukoğlu, 2003). Temel çalışma prensibi uygunluk fonksiyonu ve başlangıç popülasyonu oluşturarak ve değerler hesaplaması yapılarak sonuca ulaşılmazsa elitizm, seçim, çaprazlama ve mutasyon işlemlerinin yapılması ile en uygun sonuca ulaşılması şeklindedir (Döşoğlu ve diğ., 2009). Genellikle optimizasyon, sınıflandırma ve endüstriyel uygulamalarda genetik algoritmalar kullanılmaktadır (Bozüyük ve diğ., 2005).

Bulanık Önergeler Mantığı, net sonuçları olmayan belirsiz durumlarda bilgileri işleyerek karar vermeyi kolaylaştıran yapay zeka sistemleridir (Öztemel, 2003). Temel çalışma prensibi bulanıklaştırma, çıkarım sistemi ve bulanık çıktının sayısal değerlere göre durulaştırma işlemi şeklindedir (Abdel-Aleem ve diğ., 2017). Otomatik kontrol sistemleri, bilgi sistemleri, görüntü tanıma ve optimizasyon uygulama alanlarında bulanık önergeler mantığı kullanılmaktadır (Altaş, 1999).

Zeki Etmenler, bir problemi çözümleyebilmek için çevresinde gelişen durumları takip edip bilgi toplayarak çevresiyle ilişki kurabilen ve bazı durumlarda bağımsız çalışabilen yapay zeka sistemleridir (Ergün, 2012). Temel çalışma prensibi, çevre ile etkileşim, mesajları algılama, kavrama ve mesaja uygun cevap veren eylem birimlerinden oluşmaktadır (Aydın, 1997). Endüstriyel, ticari, tıbbi uygulamalarda ve eğlence sektöründe zeki etmenler kullanılmaktadır (Bekleriç, 2003).

Doğal Dil İşleme, sesli veya metinsel şekildeki insan dillerinin makinelerin anlayabildiği ve işleyebildiği yapay zeka sistemleridir (Dayan ve Yılmaz, 2022). Doğal dil işleme kelime bilimi ile kelimelerin anlamlarının anlaşılması, söz dizimsel ile cümledeki kelimelerin sıralanması, anlamsal ile cümlelerin anlaşılması ve söylev ile konuşma sırasındaki kelimelerin anlamlarının anlaşılmasından oluşan çalışma kriterlerinden oluşmaktadır (Seker, 2015).

Bilgisayar Görmesi, görüntülerin anlaşıldığı, anlamlandırıldığı, işlendiği ve analiz edilerek görüntülerden sonuçların çıkarıldığı yapay zeka sistemleridir (URL-1). Temel çalışma prensibi görüntü elde etme, görüntü işleme ile görüntü analizi ve karar verme şeklinde üç aşamadan oluşmaktadır (Mahmoodpour ve diğ., 2019). Robot ve otonom araçların kontrolleri, video gözetimi ve denetimi, görüntü veri tabanlarının organizasyonu, nesne modelleme gibi endüstriyel ve bilimsel uygulamalarda kullanılmaktadır (Danuser, 2011).

Faklı özelliklere sahip olduğu görülen yapay zeka uygulamalarının, imalat sektöründe üretim hatlarında robotların ve otomatik sistemlerin çalıştırılmasında, sağlık sektöründe hastalıkların teşhisinde, radyolojik görüntüleme ve analizlerinde, finans ve bankacılık sektöründe müşteri taleplerine göre kişisel hizmetlerin oluşturulmasında, satış ve pazarlama sektöründe kullanıcı deneyiminin analizi ile kişiye özel stratejiler geliştirilmesinde kullanılarak farklı meslek alanlarında farklı kullanımlarının olduğu görülmektedir (Ustalar ve diğ. 2023).

Bu tez çalışmasında ise yapay zeka uygulamalarından biri olan makine öğrenmesinin mimarlık mesleğinde kullanımı ve makine öğrenmesi ile problemlere çözüm üretilirken kullanılan makine öğrenmesi modelleri ile araç ve tekniklerinin neler olduğu konuyla ilişkili çalışmalar üzerinden değerlendirilmesi amaçlanmaktadır.

3. MAKİNE ÖĞRENMESİ

Literatürde “Machine Learning” olarak adlandırılan makine öğrenmesi, yapay zekanın insanın öğrenme süreçlerini taklit etmesi ve doğruluk performansını arttırması için veri ve algoritmalar kullanan yapay zeka ve bilgisayar bilimi dalıdır (URL-2). Makine öğrenmesi (ML) kavramını ilk kez kullanan Samuel (1959) bilgisayarlara programlama yapmadan bile öğrenme becerisi veren bilgisayar bilimi alanıdır şeklinde tanımlamıştır. Makine öğrenmesini Mitchell (1997) bilgisayar programlarının bir görevdeki performansı deneyimlerinden elde ettikleri arttıkça artmaktadır şeklinde, Atalay ve Çelik (2017) bir problemi ona özel veriyi referans alarak modelleyen bilgisayar algoritmaları olarak, Awad ve Khanna (2015) ise veriler ve bilgiler arasındaki ilişkiyi sistemli bir şekilde algoritmalar kullanarak analiz eden yapay zeka dalı şeklinde ifade ederek farklı tanımlamalar yapılmıştır.

Gelişen yapay zeka ile makine öğrenmesinin farklı meslek disiplinlerde farklı kullanım alanlarında araç olarak kullanıldığı görülmektedir. Her meslek alanında farklı problemler oluşabilmekte ve oluşan problemleri çözümleyebilmek adına her probleme özel makine öğrenmesi modelleri geliştirilebilmektedir. Bunun nedeni ise makine öğrenmesinin temel çalışma mantığıdır. Makine öğrenmesinin çalışma prensibi; bir problemin belirlenmesi, o probleme dair özel bir veri setinin oluşturulması, problem türüne göre uygun öğrenme modelinin seçilmesi, model eğitimi, analiz, yineleme ve değerlendirme şeklindedir (Murdoch ve diğ., 2019). Makine öğrenmesi çalışma sisteminde veri setinin doğru ve yeterli şekilde seçilmiş olması, makine öğrenmesi modelinin yüksek başarı elde etmesi için önemlidir. Problemi tanımlayacak veriye ait özniteliklerin anlaşılır ve ayırt edici özelliklerinin yeterli olması algoritmanın başarısını etkileyen bir diğer unsurdur. Aksi durumunda aynı özniteliklerle oluşturulmuş veri setleri ile algoritmanın öğrenmesinde istenilen sonuca ulaşamamaktadır.

3.1. Makine Öğrenmesi ile İlgili Temel Kavramlar

Makine öğrenmesi model oluşturulmasında problemin tanımlanması ve model sonuçlarının elde edilmesi için geçen sürede sıkça kullanılan temel kavramlar, modelin çalışma prensibinin anlaşılması için önemlidir.

Veri (Data), makine öğrenmesi modellerinde problemi çözümleyebilmek adına o problemi temsil eden tüm bilgiler şeklinde tanımlanmaktadır (Malhotra ve diğ., 2023). Probleme dair veriler ses, görüntü, metin, sayısal türlerde olabilmektedir (Koyuncu ve Sert, 2013). Bazı makine öğrenmesi modellerinde verilerin daha anlaşılır olması istenildiğinde veriyi tanımlamaya yönelik özelliklerin etiketlenmesi işlemi ile “Etiketli Veri” veya “Etiketsiz Veri” oluşturulmaktadır (Bilgin, 2017).

Öznitelik (Feature), makine öğrenmesi modelinde kullanılacak verilerin tanımlanması için kullanılan her bir özellik özniteliktir. Modelden istenilen verimi alabilmek için özniteliklerin birbirinden farklı özelliklere sahip olması, veri setini doğru ifade etmesi ve yeterli sayıda olması önemli bir noktadır (Vatansever ve diğ., 2021; Kaynar ve diğ., 2018).

Veri Seti (Data Set), bir problemi çözümleyebilmek veya analiz edebilmek adına konu ile ilişkilendirilmiş verilerin bir araya getirilmesi ile veri setleri oluşturulmaktadır. Modellerde istenilen başarıya ulaşmak için veri setlerine ait parametrelerin problemlerle olan ilişkisi dikkate alınmalıdır (Alan ve Karabatak, 2020). Modelin doğru performansı verebilmesi için veri setlerinin eğitim, doğrulama ve test olmak üzere üç farklı alt kümeye bölünmesi ile modelin eğitilmesi, ayarlanması ve değerlendirilmesi sağlanmaktadır (Escobar ve Morales-Menendez, 2024).

Algoritmalar (Algorithms), bir problem çözülebilmesi için o problemin gereksinimlerine göre oluşturulan matematiksel işlemler şeklinde tanımlanmaktadır (Tungut, 2022). Bir algoritma en fazla bir hesaplama görevini yapmakla beraber birden fazla görevi aynı anda gerçekleştiremediği için amaçlarına göre sınıflandırılmaktadır (Yang, 2019). Burada önemli olan problemi iyi tanımlamak ve o problemin çözümüne ulaştırabilecek uygun algoritmaların seçilmesidir.

Model (Model), makine öğrenmesinde ele alınan problemi çözmeye yönelik algoritmaların bir araya gelmesi ile girdisi ve çıktısı olan matematiksel hesaplamalar yapabilen bir yapıdır. Modeller, verilerin toplanması ve hazırlanması, özellik seçimi, algoritma seçimi, model ve parametre seçimi, eğitim ve değerlendirme şeklinde bileşenlerden oluşmaktadır (Alzubi ve diğ., 2018).

Görev (Task), makine öğrenmesinin bir problemi çözmek için veya istenilen sonuca ulaşmak için mevcut verilere dayanan çıkarım türüdür (URL-3). Makine öğrenmesi algoritmasının özellikler ve hedef değişkenle ne yapılması gerektiğini görevler belirlemektedir (Vieira ve diğ., 2020).

Model Eğitimi (Training), algoritmaların, model için kullanılan verilerle beslenmesi ile problemi çözebilmesi için gerekli olan adımları öğrenmesidir (Ersöz ve Çınar, 2021). Seçilen öğrenme yöntemine bağlı olarak model eğitimleri etiketli veya etiketsiz veriler kullanılarak gerçekleştirilmektedir (Gökalp, 2022). Model değerlendirmesi için veri setleri eğitim, doğrulama ve test için ayrıldığı için model eğitimi sırasında test veri setleri gizli tutulup yalnızca eğitim veri seti kullanılmalıdır (Kalita ve diğ., 2024).

Test (Testing), modelin doğruluğunu ve performansını ölçmek için ayrılan verilerin bir kısmı, eğitim sürecinden sonra modelde kullanılarak model test edilmektedir (Akay, 2018). Test için ayrılan, eğitilen algoritmanın daha önce görmediği ama benzer nitelikteki veri setleri ile test aşaması gerçekleştirilerek modelin çalışma performansı ölçülmektedir (Aksoy, 2021).

Aşırı Uydurma (Overfitting)- Az Uydurma (Underfitting), modelin eğitim için kullanılan verilere bağımlı olması sebebi ile eğitim setine aşırı uyum göstermesi test verisinde istenilen sonucu verememesi aşırı uydurma, modelin eğitim için kullanılan verilerin özelliklerini yakalayamaması sonucu uyum sağlayamaması ve test verisinde istenilen sonucun alınamaması az uydurmadır (Zhang ve diğ., 2019). Model karmaşıklığı, yetersiz eğitim verileri, veri gürültüsü, hiperparametreler ve test verilerinden bilgi sızması modelin aşırı uydurmasına, yetersiz model karmaşıklığı, yetersiz eğitim, zayıf veri kalitesi ve uygunsuz özellik seçimi modelin az uydurmasına neden olmaktadır (Escobar ve Menendez, 2024)

3.2. Makine Öğrenmesi Modelleri

Makine öğrenmesinin temel çalışma prensibi problemlerin tanımlandıktan sonra problemlere özel çözüm modelleri geliştirilmesidir. Problemlerde istenilen görev ne ise ona bağlı olarak uygun modellerin seçilmesi önemlidir.

Tahmin (Prediction), geçmiş veriler kullanılarak gelecekteki bir değeri tahmin etmek için kullanılan modellerdir (Rebala ve diğ., 2019). Modellerde eğitim veri setleri ile öğrenme sağlanıp test veri setleri ile tahmin gerçekleştirilmektedir. Buna bağlı olarak tahminlerde daha iyi başarı sağlanabilmesi için eğitim veri setlerinin geniş tutulması önemli bir kriter olmaktadır (Çevik ve Kayakuş, 2020).

Optimizasyon (Optimization), bir probleme ait parametrelerin sayısal ve analitik olarak hesaplanması ile problemin çözümü için gerekli olan en optimal çözüme ulaştıran modellerdir (Dwivedi ve Srivastava, 2023). Çalışma sırasında çıkabilecek hataların en aza indirgenmesi için optimizasyon modelleri kullanılmaktadır (Seyyarer ve diğ., 2020). Rastgele aramalar ve ızgara aramaları, evrimsel optimizasyon, bayes optimizasyonu makine öğreniminde temel olarak kullanılan yöntemlerdir (URL-4).

Analiz (Analysis), verilerin anlaşılması, depolanması ve yorumlanması gibi işlemlerle veriler hakkında bilgi edinilen modellerdir (Meshram, 2024). Verilerin analiz edilmeden önce eksik veriler, uç değerler ve ölçeklendirme gibi ön işleme sürecinden geçirilmesi ile verilerle ilgili sorunları gidermek için hazırlık yapılması daha doğru ve verimli sonuç alınmasını sağlamaktadır (Şahinaslan ve diğ., 2023; Özdemir ve Örsli, 2019).

Değerlendirme (Evaluation) öğrenme sisteminin performansını ölçmek, diğerleriyle karşılaştırmak için basit ve kullanışlı yollar sunan modellerdir (Japkowicz, 2006). Değerlendirme yapılırken istatistiksel veya performansı ve etkinliği ölçmek için kullanılan niceliksel önlemler olarak tanımlanan değerlendirme metrikleri önemli bir parametredir (URL-5). Karışıklık matrisi, kesinlik, geri çağırma, hatırlamak, özgüllük, F1 puanı, ROC eğrisi, ortalama kare hatası, R^2 önemli değerlendirme metriklerindendir (URL-6).

Bilgi Çıkarımı (Knowledge Extraction), varlıklar, varlıkların ilişkisi ve varlıkların nitelikleri gibi yapılandırılmış bilgilerin, yapılandırılmamış veya yarı yapılandırılmış bilgilerden ayrıldığı modellerdir (Sarawagi, 2008). İstenilen bilgileri temsil eden bir örnek dizisinden bir alt dizi çıkarmak şeklinde de tanımlanmaktadır (Tang ve diğ., 2008). Adlandırılmış varlık tanıma, ilişki çıkarma, olay çıkarma ve tam bilgi çıkarma şeklinde dört farklı bilgi çıkarma türü vardır (Mol ve Kumar, 2022).

Nesne Tanıma (Object Recognition), genellikle görüntü ve video verilerinden, öznelilik çıkarımı, seçimi ve tanımlama gibi işlemler yapılarak nesnenin seçilmesi için kullanılan modellerdir (Daş ve diğ., 2019). Yüz, şekil, renk, metin vb. nesne sınıfına ait olan görüntüdeki belirli nesneyi veya özelliği tespit etmek şeklinde de tanımlanmaktadır (Karayaneva ve Hintea, 2018). Nesne tanıma görüntü sınıflandırması, etiketleme, nesne algılama ve segmentasyondan oluşan 4 sürece sahiptir (URL-7).

Sınıflandırma (Classification), etiketli verileri bir veya daha fazla kategoriye (sınıfa) ayırmak için kullanılan modellerdir (Rebala ve diğ., 2019). Fonksiyonun girdi-çıkı ilişkisi dikkate alınarak vektörü çeşitli sınıflardan biri ile eşleştiren bir fonksiyonun öğrenmesi şeklinde de tanımlanmaktadır (Osisanwo ve diğ., 2017). Verilen problem setinde bulunan verilere ait nitelik veya özellikler, doğru sınıflandırma yapılabilmesi için yardımcı olabilecek önemli parametrelerdir (Sen ve diğ., 2019)

Görüntü İşleme (Image Processing), görüntü verilerinin, filtreleme ve iyileştirme gibi işlemlerin yapılarak sayısallaştırıldığı modellerdir (Chellappa ve Rosenfeld, 2003). Görüntü işleme segmentasyon, özellik çıkarılma ve sınıflandırma yapıma şeklinde üç aşamadan oluşmaktadır (Rodellar ve diğ., 2018; Belsare ve Musrif, 2012). Görüntülerin, savunma ve güvenlik, tıp, mimarlık gibi farklı kullanım alanlarına göre uygun algoritmaların kullanılarak işlenilmesi önemli olmaktadır (Samtaş ve Gülesin, 2011).

Kümeleme (Clustering), veri kümesi içindeki verileri ortak özelliklerine göre gruplandırmak için kullanılan modellerdir (Rebala ve diğ., 2019). Sınıf etikeleri olmadan verilerin benzerliğine göre gruplandırılmasıdır (Rodriguez ve diğ., 2019). Kümeleme modelleri özellik seçimi veya çıkarma, kümeleme algoritması tasarımı veya seçimi, küme doğrulaması, yorumlama işlemlerinden oluşmaktadır (Xu ve Wunsch, 2005).

3.3. Makine Öğrenmesi Yöntemleri ve Kullanılan Algoritmalar


Makine öğrenmesinde modeller geliştirilirken problemlerin çözümü için farklı yöntemlere ihtiyaç duyulmaktadır. Burada önemli olan nokta problemi doğru tanımlayabilmek ve çözüme gidilen yolda kullanılacak yöntemleri iyi seçmektir. Girdi olarak kullanılan verilerin analizlerinin yapılması ile yeni veriler üzerinden bir tahminde bulunulması ya da sahip olunan verilerin etiketlenmesi ile verilere belirli bir sınıf ataması

yapılarak sınıflandırma işleminin yapılması veya girdi olarak kullanılan veri setlerindeki verileri inceleyerek aynı niteliklere sahip verilerin etiketlenme işlemi yapılmadan gruplandırma amacı ile kümeleme işlemi gerçekleştirilmesi gibi, problemlerin tanımlaması ve problemlerin çözümü için en uygun modeller ile yöntemlerin seçilmesi makine öğrenmesinin temel çalışma prensiplerindendir.

Makine öğrenmesi modellerinde yapılması istenilen görevlere uygun olarak alt başlıklarda detaylı olarak anlatılan denetimli makine öğrenmesi (supervised machine learning), denetimsiz makine öğrenmesi (unsupervised machine learning), yarı denetimli makine öğrenmesi (semi-supervised machine learning), pekiştirmeli (takviyeli) makine öğrenmesi (reinforcement machine learning) ve derin öğrenme (deep learning) yöntemleri arasından seçilmelidir.

3.3.1. Denetimli Makine Öğrenmesi

Denetimli öğrenme modelinde bir gözetmen tarafından, istenilen sonuca bağlı olarak eğitim veri setindeki verilerin sahip olduğu özelliklerin etiketlenmesi ile öğrenme gerçekleştirilmektedir (Şekil 3.1).



Şekil 3.1. Denetimli makine öğrenmesi çalışma prensibi (Uyarlama URL-8)

Algoritmanın tahmin etmeyi öğreneceği şey olan hedef değişkeni (etiketler) ve algoritmanın girdisi olan verileri içeren özellik kümesi ile yapılacak olan görev denetimli öğrenmenin temelini oluşturmaktadır (Vieiral ve diğ., 2020). Denetimli makine öğrenmesi modelinde temel amaç, verilerin kategorik değerlerini tahmin etmek veya sürekli değerleri tahmin etmektir (Maleki ve diğ., 2020). Buna bağlı olarak verilen

görevlere ilişkin kullanılan algoritmalar, sınıflandırma ve regresyon olmak üzere iki kategoride ele alınmaktadır (Kumar ve Singh, 2022).

Sınıflandırma (Classification), önceden sınıfları tanımlanmış verilerin özelliklerine göre kategorilendirme işlemi olup, kategoriler hedef ve etiketler olarak adlandırılmaktadır (Mustapha ve diğ., 2024). Hedef iki farklı değere sahip ise ikili sınıflandırma, hedef birden fazla değere sahip ise çoklu sınıflandırma şeklinde ayırım yapılabilmektedir (Pargent ve diğ., 2023). Doğruluk, F1 puanı, AUC ROC, karışıklık matrisi, hatırlama ve kesinlik gibi metrikler sınıflandırma performansını ölçmek için kullanılan önemli metriklerdendir (Tiwari, 2022).

Sınıflandırma işlemi için genellikle Naïve Bayes Classifier, Decision Trees (DT), Random Forest (RF), Adaboost Classifier, Support Vector Machine (SVM), Neural Network (NN), Probabilistic Neural Network, K-Nearest Neighbor (K-NN) Classifier algoritmaları kullanılmaktadır (Kumar ve Singh, 2022).


Regresyon (Regression), bir özelliğe bağlı veya bağımsız olan değişkenleri bağımsız değişken olarak, değeri bağımsız özelliklere bağlı olarak belirlenen değişkenler ise bağımlı değişken olarak nitelendirilmekle beraber, bu iki değişken arasındaki ilişkiyi anlamak için algoritmaların kullanıldığı denetimli öğrenmedir (Tiwari, 2022; Wang ve diğ., 2023). Bağımsız değişken sayısı tek ise tek değişkenli regresyon, birden fazla değişken varsa çoklu regresyon işlemleri yapılmakta ve girdi olarak kullanılan sürekli değişken verilerinin, doğrusal veya doğrusal olmayan diğer değişkenlerle eşleştirilerek tahmin edilmesi ile doğrusal regresyon ve eğrisel regresyon işlemleri yapılmaktadır (Yergök ve Acı, 2019; Arslan, 2008).

Regresyon işlemi için genellikle Linear Regression, Logistic Regression Algorithm, Support Vector Regression (SVR), Ensemble Method, Decision Trees, Gaussian Process Regression (GPR) algoritmaları kullanılmaktadır (Solyali, 2020).

3.3.2. Denetimsiz Makine Öğrenmesi

Denetimsiz öğrenme modelinde girdi olarak kullanılan verilerin herhangi bir etiketleme işlemi ve gözetmen olmaksızın sahip olduğu özelliklerin yorumlanması ile öğrenme gerçekleştirilmektedir (Şekil 3.2). Eğitim sırasında etiketli veriler kullanılmadığı için

çıktıya odaklanılmaz, verilerin arasındaki ilişkilere bağlı işlev çıkarılmaya çalışılmaktadır (Tiwari, 2022). Veri türleri, boyutlulukları, örnek sayıları ve kullanım amaçları denetimsiz öğrenme başarısını etkileyen önemli parametrelerdir (Kalita ve diğ., 2024). Denetimsiz makine öğrenmesi modelinde, verilen görevlere ilişkin kullanılan algoritmalar, kümeleme ve boyutluluk azaltımı olmak üzere iki kategoride ele alınmaktadır (Vieiral ve diğ., 2020).



Şekil 3.2. Denetimsiz makine öğrenmesi çalışma prensibi (Uyarlama URL-9)

Kümeleme (Clustering), girdi olarak kullanılan verilerin özellikleri ile benzer olanlarının kümelendiği ve gözlemler arasında eşit dağılımlı alt grupların tespit edildiği öğrenme modelidir (Hatipoğlu ve diğ., 2024). Etiketleme işlemi olmadan verilerin grup içi benzerlik veya farklılıklar dikkate alınarak gruplama işlemleri yapılmaktadır (Kalita ve diğ., 2024). Kümeleme tekniklerini, veri nesneleri hiyerarşik bir şekilde seviyelere bölünmesi ile hiyerarşik kümeleme, hiyerarşik yapı olmaksızın iç içe geçmiş gruplar halinde düzenlenmesi ile bölümsel kümeleme şeklinde iki farklı alt kategoride ele alınmaktadır (Ezugwu ve diğ., 2022).

Kümeleme işlemi için genellikle K-Means Algorithm, Hierarchical Clustering, Gaussian Mixture Model (GMM), Density-Based Spatial Clustering Of Applications With Noise (DBSCAN) algoritmaları kullanılmaktadır (Neg, ve Chawla, 2021).


Boyutluluk Azaltımı (Dimensionality Reduction), veri kümesindeki özelliklerin çok yüksek ve karmaşık olduğu durumlarda, veri giriş sayısında boyut azaltma işlemi yapılarak öğrenme gerçekleştirilmektedir (Wang ve diğ., 2023). Yüksek boyutlu veriler, boyutluluk laneti, aşırı uydurma ve ağır hesaplama yüklerine sebep olduğundan modelin

performansının iyileştirilmesi için boyutluluk azaltma işlemi önemli olmaktadır (Srivastava ve diğ., 2024). Gereksiz ve ilgisiz özelliklerin veri setinden kaldırılması ile özellik çıkarımı işlemi ve verilen soruna göre giriş verilerinden uygun olanların ayrılması ile özellik seçimi işlemi boyutluluk azaltmada önemli parametrelerdir (Ayesha ve diğ., 2020). Boyutluluk azaltımı, doğrusal ve doğrusal olmayan şeklinde iki farklı alt kategoride ele alınmaktadır (Maaten ve diğ., 2009).

Boyut azaltma işlemi için genellikle Factor Analysis, Principal Components Analysis (PCA), Independent Components Analysis algoritmaları kullanılmaktadır (Artoni ve diğ., 2018).

3.3.3. Yarı Denetimli Makine Öğrenmesi

Bu öğrenme modelinde girdi olarak kullanılan verilerin bazılarının etiketli bazılarının etiketsiz olduğu hem denetimli öğrenme hem de denetimsiz öğrenme modellerinin çalışma prensiplerini taşıyarak öğrenme gerçekleştirilmektedir (Şekil 3.3). Öğrenmenin temel çalışma prensibi, etiketli verilerin az, etiketsiz verilerin çok sayıda olduğu örneklerin bulunduğu durumlarda modelin performansını arttırmaktır (Maleki ve diğ., 2020). Modeli eğitmek için etiketli veri setleri kullanıldıktan sonra eğitilmiş model ile etiketlenmemiş verilerden oluşan veri setlerini eğitmek için kullanılmaktadır (Kalita ve diğ., 2024).




Şekil 3.3. Yarı denetimli makine öğrenmesi çalışma prensibi (Uyarlama URL-9)

Yarı denetimli makine öğrenmesi modelinde genellikle Generative Mixture Models, Self-Training, Co-Training, Transductive SVM, Gaussian Processes, Graph-Based Methods,

Markov Random Field (MRF), Gaussian Random Fields, Tree-Based Bayes, Metric-Based Model Selection algoritmaları kullanılmaktadır (Zhu, 2005).

3.3.4. Pekiştirmeli (Takviyeli) Makine Öğrenmesi

Pekiştirmeli öğrenme modelinde girdi olarak kullanılan verilerin bir ajan tarafından belirli bir keşif ortamında en iyi eyleme karşılık gelen durumlarının değerlendirilmesi ile öğrenme gerçekleştirilmektedir (Şekil 3.4). Bu öğrenme modelinde bir ödül sistemi geliştirilerek, makinelerin deneme yanılma yoluyla etkileşimli ortamda en iyi eylemi yapmayı öğrenmesi ve deneyimi optimize etmeye çalışan bir sistem amaçlanmaktadır (Mustapha ve diğ., 2024; Katanya, 2021).




Şekil 3.4. Pekiştirmeli makine öğrenmesi çalışma prensibi (Uyarlama URL-9)

Pekiştirmeli öğrenme modelinde genellikle Q-Learning, DQN, Actor-Critic, Policy Gradient Algorithm, Deep Deterministic Policy Gradient (DDPG), I2A Algorithm, World Models Algorithm, Trust Region Policy Optimization (TRPO), Proximal Policy Optimization (PPO) Monte Carlo (MC), Temporal-Difference (TD) Methods algoritmaları kullanılmaktadır (Zhang ve Yu, 2020).

3.3.5. Derin Öğrenme Modeli

Yapay zekanın bir alt alanı olan makine öğrenmesi çalışma prensibinin daha detaylı olarak işlendiği ve yapay sinir ağları kullanılarak öğrenme modelinin gerçekleştirildiği derin öğrenmenin çalışma prensibi Şekil 3.5'te gösterilmiştir.



Şekil 3.5. Derin öğrenme modelinin çalışma prensibi (Uyarlama URL-10)


Yapay sinir ağları, bir insanın nörolojik sisteminde bulunan nöronlar ve nöronların birbiri ile ilişkisini referans alarak girdi katmanı, gizli katman ve çıkış katmanı olmak üzere üç temel katmandan oluşmaktadır ve derin öğrenmenin temelinde yapay sinir ağları kullanılmaktadır (Zhang ve diğ., 2024). Yapay sinir ağları küçük veriler için kullanılırken derin öğrenme daha büyük ve karmaşık verilerin kullanımında tercih edilmektedir (Zhang ve diğ., 2018). Derin öğrenmede “derin” terimi, büyük ve karmaşık verilerin kullanılarak öğrenmenin gerçekleştirilmesi için veri özellikleri arasında ilişki kurulan gizli katmanların fazla olması sebebi ile gizli katmanların oluşturduğu derin ağı ifade etmektedir (Mustapha ve diğ., 2024; Jakhar ve Kaur, 2020). Gizli katman sayısının fazla olması derin öğrenmenin yapay sinir ağlarından farklılaştığı önemli bir nokta olmaktadır.

Derin öğrenme modelinde kullanılan algoritmalar discriminative learning (supervised), generative learning (unsupervised) ve hybrid learning (others) olmak üzere üç kategoride ele alınmaktadır (Sarker, 2021).

Ayrımcı veya Denetimli Öğrenme (Discriminative Learning- Supervised): Denetimli öğrenme modelinin çalışma prensibi temel alınarak etiketli veriler üzerinden sınıflandırma uygulamalarında kullanılan derin öğrenme modelidir (Sarker, 2021). Bu öğrenme modelinde genellikle Deep Brief Network (DBN), Deep Neural Network (DNN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Multi Layer Perceptron (MLP) algoritmaları kullanılmaktadır (Guo ve diğ., 2016; Liu ve Lang, 2019; Sarker, 2021).


Üretken veya Denetimsiz Öğrenme (Generative Learning- Unsupervised): Denetimsiz öğrenme modelinin çalışma prensibi temel alınarak verilerin etiketlenme işlemi yapılmadan öğrenmenin gerçekleştiği derin öğrenme modelidir (Sarker, 2021). Bu öğrenme modelinde genellikle Generative Adversarial Network (GAN), Autoencoder (AE), Restricted Boltzmann Machine (RBM), Self-Organizing Map (SOM) algoritmaları kullanılmaktadır (Guo ve diğ., 2016; Sarker, 2021).

Hibrit Öğrenme (Hybrid Learning- Others): Hem denetimli hem denetimsiz öğrenme modellerinin çalışma prensipleri temel alınması ile birden fazla modelin bir arada kullanılarak öğrenme modelinin gerçekleştirildiği derin öğrenme modelidir (Sarker, 2021). Bu öğrenme modelinde genellikle Model_1 (CNN+LSTM), Model_2 (GAN+CNN), Model_3 (AE+SVM), Deep Transfer Learning (DTL), Deep Reinforcement Learning (DRL) algoritmaları kullanılmaktadır (Sarker, 2021).



Şekil 3.6. Yapay zeka ile makine öğrenmesi ve yöntemleri ilişkisi (Uyarlama URL-11)


Yapılan araştırmalar sonucunda elde edilen bilgiler doğrultusunda yapay zeka, yapay zekanın bir alt alanı olan makine öğrenmesi ile makine öğrenmesinin denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme, pekiştirmeli öğrenme ve derin öğrenme yöntemlerinin birbirleri ile ilişkileri Şekil 3.6’da ifade edilmiştir. Literatürde makine öğrenmesinde kullanım amaçlarına göre birden fazla algoritma kullanıldığı tespit edilmiştir. Yarı denetimli öğrenmede, takviyeli öğrenmede, denetimli öğrenmede sınıflandırma ve regresyon, denetimsiz öğrenmede kümeleme ve boyutluluk azaltımı, derin öğrenmede ayırmacı veya denetimli, üretken veya denetimsiz ve hibrit olmak üzere alt alanlarında kullanılan algoritmalar Şekil.3.7’de gösterilmiştir.



Şekil 3.7. Makine öğrenmesi yöntemleri ve yöntemlerde kullanılan algoritmalar ilişkisi

4. METODOLOJİ

Mimarlıkta makine öğrenimi kullanımına ilişkin yapılan bu tez çalışmasının dört aşamalı metodolojisi Şekil 4.1’de özetlenmiştir. Çalışmanın ilk aşamasında tez konusunun belirlenerek konu ile ilgili yapılacak olan literatür taramasının araştırma soruları oluşturulmuştur. İkinci aşamada literatür taramasının kriterleri belirlenmiştir. Araştırma konusuyla ilgili anahtar kelimeler belirlenerek, 2007 ile 2023 yılları arasında mimarlık, mühendislik ve bilişim teknolojileri ile ilgili dokuz büyük akademik arama ve yayınlanma platformlarında ilgili çalışmaların araştırması yapılmıştır. Çalışmaların başlıkları, anahtar kelimeleri, özetleri ve metodolojileri temel alınarak kapsamlı bir tarama gerçekleştirilmiştir. Üçüncü aşamada ise yapılan literatür taraması sonucunda elde edilen çalışmaların, belirlenen dahil etme ve hariç tutma kriterlerini karşılayıp karşılamadıkları göz önünde bulundurularak seçim işlemi yapılmıştır. Literatürden seçilen çalışmaların araştırma sorularına verdikleri cevaplar incelenmiştir. Dördüncü ve son bölümde ise mimarlıkta makine öğrenmesinin kullanımının literatürdeki çalışmalar üzerinden değerlendirilmesi yapılmıştır.



Şekil 4.1. Tez çalışmasının metodolojisi

4.1. Araştırma Soruları

Makine öğrenmesinin mimarlıkla ilişkisini araştırmak bu tez çalışmasının temel hedefidir. Mimarlık mesleğinde birden fazla alt disiplin bulunmaktadır. Bu nedenle makine öğrenmesinin hangi alt disiplinlerde kullanıldığı ve bu disiplinlerde ele alınan problemlere çözüm aranırken hangi makine öğrenmesi modelleri ile araç ve teknikleri kullanıldığını belirlemek adına üç araştırma sorusu (AS) formüle edilerek Tablo 4.1’de listelenmiştir.

Tablo 4.1. Araştırma soruları

<u>KOD</u>	<u>Araştırma Soruları</u>
AS1	Literatürde makine öğrenimi kullanılarak mimarlığın hangi alt alanları incelendi ve bu alt alanlarda hangi sorunlar ele alındı?
AS2	Mimarlıkta ele alınan sorunların çözümü için makine öğrenmesinin hangi modelleri kullanılmıştır?
AS3	Mimarlık alanında belirlenen sorunların çözümü için literatürde hangi programlama dilleri, yazılımlar, makine öğrenimi platformları, programlama kütüphaneleri ve makine öğrenimi algoritmaları kullanılmıştır?

4.2. Literatür Araştırma Kriterlerinin Oluşturulması

Literatür taraması yapılmadan önce mimarlıkta makine öğrenmesi kullanımına ilişkin anahtar kelimeler oluşturulmuştur. Konu ile ilgili, (“Machine Learning” YA DA “ML” VE “Architectural Design”), (“Machine Learning VE Architecture”), (“Artificial Intelligence VE Machine Learning”), (“Artificial Intelligence VE Machine Learning VE Architectural Design”), (“Machine Learning VE Architecture VE Building”), (“Machine Learning VE Deep Learning” VE “Architectural Design”) ve (“Machine Learning VE Architecture VE Building VE Design VE Architect”) anahtar kelimeleri belirlenmiştir.

4.2.1. Akademik Arama ve Yayınlanma Platformları

Konu ile ilgili belirlenen anahtar kelimeleri kullanarak, Academia, Google Scholar, Multidisciplinary Digital Publishing Institute (MDPI), ResearchGate, SAGE Journals, ScienceDirect, Springer Link, Tandfonline ve Emerald Publishing Limited olmak üzere dokuz büyük akademik arama ve yayınlanma platformlarında, 2007 ile 2023 yılları arasındaki mimarlık disiplinde makine öğrenmesi kullanımına yönelik yapılan çalışmalar araştırılmıştır. Literatür taraması araştırma konusu ile ilgili hakemli makaleler, kitap bölümleri, konferans bildirileri, üniversite tez çalışmaları gibi belirli yayın türleri üzerinden gerçekleştirilmiştir.

4.3. İlgili Çalışmaların Seçilmesi ve Detaylı İncelenmesi

Arama kriterleri dikkate alınarak literatür taraması tamamlandıktan sonra, oluşturulan dahil etme-hariç tutma kriterlerine göre ulaşılan çalışmaların başlıkları, anahtar kelimeleri, özetleri ve metodolojileri dikkate alınarak seçim işlemi gerçekleştirilmiştir. Oluşturulan dahil etme ve hariç tutma ölçütleri Tablo 4.2’de listelenmiştir.

Tablo 4.2. Dahil etme ve hariç tutma kriterleri

Dahil etme kriterleri	Hariç tutma kriterleri
Mimarlık ve mimarlık ile ilgili diğer mesleki alt alanlarını konu edinmesi	Mimarlık mesleği ile ilgili olmaması
Makine öğrenmesi ile mimarlık arasındaki ilişkinin net bir şekilde açıklanması	Makine öğrenmesi ile mimarlık arasındaki ilişkinin açıkça belirtilmemesi
Araştırma makalesi (research papers) olması	Derleme makale (review papers) olması
İngilizce dilinde yazılmış olması	İngilizce dilinde yazılmamış olması
Kullanılan makine öğrenmesi metodolojisinin açıkça belirtilmesi	Kullanılan makine öğrenmesi metodolojisinin açıklanmaması

Literatür taraması sonucunda arama kriterlerini karşılayan 232 çalışmaya ulaşılmıştır. Seçim işlemi üç aşamadan oluşmaktadır. İlk aşamada incelenen 232 çalışmanın 44’ü mimarlık mesleği ile net ilişki kurulmadığı gerekçesiyle elenmiştir. İkinci aşamada ise 188 çalışmadan 30’u İngilizce dili dışında yazıldığı ve derleme makalesi olduğundan dahil edilmemiştir. Üçüncü aşamada ise kullanılan makine öğrenmesi metodolojisinin açıkça ifade edilmemesinden dolayı 72 çalışma değerlendirilme dışı bırakılmıştır. Seçim işlemi tamamlandıktan sonra kalan 86 makalenin içeriği, araştırmanın başında formüle edilen araştırma sorularına (AS) verdikleri yanıtlar üzerinden analiz edilmiştir. Seçilen makalelerin analizleri tablolar, çubuk grafikler, pasta grafikleri, alluvial ve chord diyagramlar kullanılarak görselleştirilmiştir.

4.4. Mimarlıkta Makine Öğrenmesi Kullanımının Değerlendirilmesi


Tez çalışmasının son aşamasında, arama kriterleri ile dahil etme ve hariç tutma kriterleri dikkate alınarak elde edilen 86 makalenin araştırma sorularına verdikleri yanıtlar doğrultusunda mimarlıkta makine öğrenmesi kullanımının literatür üzerinden değerlendirilmesi yapılmıştır.

5. ANALİZLER

Tez çalışmasının bu bölümünde ilk olarak arama kriterleri ile dahil etme ve hariç tutma kriterlerine uygun olan 86 çalışmanın yayınlanma yılları, yayın türleri, yayınlandıkları dergi ve konferans isimleri, yayınlandıkları akademik arama ve yayınlanma platformları, çalışmaların yapıldığı ülkeler hakkında elde edilen bilgiler analiz edilmiştir. Daha sonra 86 çalışmada mimarlıkta hangi problemleri ele alındığı ve bu problemlere makine öğrenmesi ile nasıl çözümler arandığına dair özet bilgiler yer almaktadır. Son olarak ise araştırmanın başında oluşturulan üç araştırma sorusuna 86 çalışmanın vermiş olduğu yanıtların detaylı analizleri yapılmıştır.

5.1. Literatürdeki Makine Öğrenmesi ile İlgili Seçilen Makalelerin İncelenmesi

86 çalışmanın yayınlanma yılları 2007 (2 yayın), 2013 (1 yayın), 2015 (1 yayın), 2016 (1 yayın), 2017 (3 yayın), 2018 (5 yayın), 2019 (9 yayın), 2020 (9 yayın), 2021 (12 yayın), 2022 (20 yayın) ve 2023 (23 yayın) şeklinde Şekil 5.1’de gösterilmiştir. Makine öğrenmesinin gelişmesi ile mimarlıkta makine öğrenmesi kullanımının literatürdeki çalışmalar üzerinden değerlendirilerek yıllara göre arttığı sonucuna varılmaktadır.




Şekil 5.1. Makalelerin yayınlandığı yılların dağılımı

86 çalışma makale ve bildiri olmak üzere iki yayın türünde sınıflandırılmıştır. 86 çalışmanın 65’i (%76) makale olarak, 21’i (%24) bildiri olarak yayınlanmıştır.


65 çalışma, Automation in Construction (15 makale), Building and Environment (13 makale), Energy and Buildings (6 makale), Journal of Building Engineering (6 makale), International Journal of Architectural Computing (3 makale), Sustainable Cities and Society (3 makale), Construction Innovation (2 makale), Advanced Engineering Informatics (1 makale), Ain Shams Engineering Journal (1 makale), Alexandria Engineering Journal (1 makale), Building Simulation (1 makale), Cities (1 makale), Computer-Aided Civil and Infrastructure Engineering (1 makale), Energies (1 makale), Engineering Structures (1 makale), Estoa (1 makale), Expert Systems With Applications (1 makale), Journal of Cultural Heritage (1 makale), Materials & Design (1 makale), Open House International (1 makale), Periodica Polytechnica Architecture (1 makale), Simulation (1 makale), Sustainability (1 makale), International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering (1 makale) dergilerinde yayınlanmıştır.

21 çalışma, eCAADe – SIGraDi (13 bildiri), The International Conference on Computational Design and Robotic Fabrication (4 bildiri), CAAD Futures (2 bildiri), ACADIA (1 bildiri), Modelling Behaviour (1 bildiri) konferanslarında yayınlanmıştır. Çalışmaların yayınlandıkları dergiler ve konferansların isimleri ile çalışma sayılarının ilişkisi Şekil 5.2’ de gösterilmiştir.




Şekil 5.2. Yayın türlerinin dergi ve konferansa göre dağılımı

Çalışmaların seçim işlemi yapıldıktan sonra geriye kalan çalışmaların sayısı ve yayımlandıkları Emerald Publishing Limited, Google Scholar, MDPI, Research Gate, SAGE Journals, Science Direct, Springer Link akademik arama ve yayınlanma platformlarının ilişkisi Şekil 5.3'te gösterilmiştir.



Şekil 5.3. Çalışma sayısı ile akademik arama ve yayınlanma platformları dağılımı

86 çalışmanın hangi ülkelerde yapıldığına dair ilişkin veriler Şekil 5.4'te gösterilmiştir. Ülke seçimi, çalışmaların sorumlu yazarının belirli bir üniversiteyle olan ilişkisine göre yapılmıştır. Sonuçlara göre Çin, ABD ve Türkiye mimarlıkta makine öğrenmesi kullanımına ilişkin en çok çalışma yayınlanan ülkelerin başında yer almaktadır.



Şekil 5.4. Çalışmaların yapıldığı ülkeler grafiği

5.2. Mimarlıkta Makine Öğrenmesi ile İlgili Literatürün İncelenmesi

Literatürdeki mimarlık mesleğinde makine öğrenmesinin kullanımına dair ulaşılan 232 çalışmadan, arama kriterleri ile dahil etme ve hariç tutma kriterlerine göre seçim işlemi sonucunda 86 çalışmanın kriterlere uygun olduğu görülmüştür.

Bu bölümde 86 çalışmanın kısa özeti, mimarlık mesleğinin hangi alt alanlardaki problemleri ele aldıkları ve bu problemlere makine öğrenmesi ile nasıl bir çözüm geliştirdikleri, çözümler için hangi yazılımlar, programlama kütüphaneleri, programlama dilleri, makine öğrenmesi platformları ile makine öğrenmesi algoritmaları kullandıkları kapsamlı bir şekilde ele alınmıştır. 86 çalışmada geliştirilen makine öğrenmesi modellerinin göstermiş olduğu başarı performansları ile ele alınan problemlerin çözümünde sonuç olarak neler elde ettiklerine dair bilgiler 2007 yılından başlayarak 2023 yılına kadar kronolojik şekilde aşağıda anlatılmaktadır.

Aggarwal (2007) tarafından yapılan çalışmada, tek takviyeli kırışteki donatı hesabını tahmin eden bir model geliştirilmiştir. Neural Net, Support Vector Machine, Tree Based Models ve Linear Regression kullanılarak makine öğrenmesi tahmin modeli oluşturulmuştur. Bir kırışin derinlik uzunluk gibi özellikleri ve çelik gereksinimleri dikkate alınarak geliştirilen makine öğrenmesi modelinin çalışma başarısının değerlendirilmesi için eğitim aşamasında kullanılan veri setinden bağımsız bir veri seti ile model doğrulanmıştır. Çalışmada Lineer Regresyon, SVM ve Tree Based modeller sinir ağlarına göre daha başarılı tahminlerde bulunduğu tespit edilmiştir.

Peng ve Gero (2007) tarafından yapılan çalışmada, bilgisayar destekli mekan tasarımlarında makine öğrenmesi algoritmalarıyla optimizasyonların sağlanmasını amaçlamaktadır. MATLAB programlama dilinde Constructive Interactive Activation and Competition (CIAC) kullanılarak model oluşturulmuştur. Modelin bilgisayar destekli bir tasarım aracının kullanım deneyimleri ile çevreyle etkileşim kurarak yeni kavramlar öğrendiği ve tasarım sürecinin optimizasyonunu sağladığı görülmüştür.

Wilkinson ve diğ. (2013) ise çalışmalarında yüksek binaların yapı formları gereği oluşabilecek rüzgar basıncının erken tasarım sürecinde öngörülmesini hedeflemektedir. Parametrik tasarlanan yüksek bina formları Generative Components yazılımı kullanılarak hazırlanmıştır. Oluşturulan yüksek bina formlarının rüzgar basıncı için, ANSYS CFX yazılımı üzerinden eğitilmiş makine öğrenmesi algoritmaları olan Random Forest, Artificial Neural Network (ANN), K-Nearest Neighbor kullanılarak tahmin modeli geliştirilmiştir. Hesaplamalı akışkanlar dinamiği (CFD) simülasyonlarının makine öğrenmesi ile rüzgar basıncı tahminini gerçekleştirebildiğini fakat bazı tahmin

hatalarının olmasına rağmen yüksek binalara yönelik erken aşama konsept tasarımı için kabul edilebilir doğrulukta sonuçlar elde edildiği görülmüştür.

Krijnen ve Tamke'nin (2015) araştırmasında, Yapı Bilgi Modellemesi (BIM) tarafından oluşturulan modellerdeki yapı elemanlarının özellikleri ve birbiri ile ilişkisinin makine öğrenmesi ile değerlendirilmesi hedeflenmektedir. Bu kapsamda BIM verileri, makine öğrenmesi yazılım kütüphaneleri olan IfcOpenShell ve PYTHONOCC kullanılarak PYTHON programlama dilinde işlenmiştir. Denetimsiz Makine Öğrenmesi kullanılarak yapılan denemede Scikit-Learn kütüphanesi ve Denetimli Makine Öğrenmesi kullanılarak yapılan denemede ise PyBrain kütüphanesi kullanılmıştır. Denetimsiz öğrenme modeli ile BIM modellerindeki geometrik formların anormallik özelliklerini tespit edilerek yapı elemanlarının yanlış sınıflandırılması önlenmiştir. Denetimli öğrenme modeli ile BIM modellerindeki kat planlarını işlevlerine göre sınıflandırılması yapılmıştır.

Mao ve diğ. (2016) tarafından yapılan çalışmada, ofis binalarının yıllık elektrik kullanımını ölçen enerji tahmin modeli oluşturulmuştur. EnergyPlus yazılımı kullanılarak binanın modellenmesi ve enerji simülasyon analizleri yapılmıştır. Makine öğrenmesi algoritması olan Support Vector Regression, Radial Basis Function Network (RBFN) ve Genetic Algorithm (GA) kullanılarak model oluşturulmuştur. Oluşturulan modelin gerçek ofis binasının ölçülen verileriyle değerlendirilmesi yapılmıştır. Tahmin edilen ve ölçülen değerler arasında farkın %10'un altında olduğu bu sebeple geliştirilen model ile binaların enerji performansı değerlendirilmesinde yardımcı olabileceği sonucuna varılmıştır.

Takizawa ve Furuta (2017), kentin farklı bakış açılarından elde edilen görüntülerinin insanlar üzerindeki etkisinin değerlendirilmesi için mekânsal analiz ve tahmin modeli önermiştir. Kentin modellenerek görüntüler elde edilmesi için Unity oyun geliştirme yazılımı kullanılmıştır. Bu görüntüler, PYTHON programlama dilinde derin öğrenme kütüphanesi olan Chainer kullanılarak, Deep Convolutional Neural Network (DCNN), AlexNet ve GoogLeNet algoritmaları ile öğrenme modeli ile işlenmiştir. GoogleNet, AlexNet'ten daha verimli sınıflandırma gerçekleştirdiği, renk ve dokusal bilgilerin geometrik bilgilerle eşleştirilmesinin DCNN algoritması ile gerçekleştirilerek mekansal değerlendirmeler yapılabileceği sonucuna varılmıştır.

Muehlbauer ve diğ. (2017) tarafından yapılan çalışmada, üretken tasarım için bir kontrol sistemi geliştirmek ve mimari tasarım süreçlerinde ve karar vermede yardımcı bir çerçeve önerileri geliştirilmiştir. Önerilen çerçevede makine öğrenmesi, nesne tanıma ve özellik çıkarımı için OpenCV kütüphanesinde bulunan Scale-Invariant Feature Transform (SIFT) algoritması kullanılmıştır. Sınıflandırma işlemi için ise Naïve Bayes algoritması kullanılmıştır. Binaların tasarım süreçlerinin optimize edilmesinde, karmaşık kriterler arasındaki ilişkiler değerlendirilip karar verme süreçlerinin desteklenmesinde makine öğrenmesinin kullanılabileceği sonucu elde edilmiştir.

Chatzikonstantinou ve Sariyildiz'in (2017) çalışmasında, bir yapının cephe performansını enerji performansı ve gün ışığı konforu olarak iki farklı şekilde incelenmiş olup cephe verimliliğini arttırmak hedeflenmiştir. Parametrik cephe modellemesi için Rhinoceros, enerji analizleri için ise Radiance ve EnergyPlus yazılımları, optimizasyon ve sinir ağı eğitimi için CIDEA platformu kullanılmıştır. Makine öğrenmesi algoritmalarından Radial Basis Function Network, Orthogonal Least Squares (OLS), Non-dominated Sorting Genetic Algorithm-II (NSGA-II), Multi Objective Optimization (MOO) kullanılarak model geliştirilmiştir. Pencere boyutu, konumu, dış duvarla pencere ilişkisi, gölgeleme cihazının boyutları ve konumu, malzeme özellikleri gibi değişkenlerinin makine öğrenmesi modelinin performansını etkileyen önemli parametreler olduğu ve geliştirilen model ile sürdürülebilir bina tasarımlarında karmaşık ortamlarda çıkan problemleri optimize ederek çözümlenebileceği doğrulanmıştır.

As ve diğ. (2018), mekanların özellikleri ve birbiri ile ilişkisinin kavramsal organizasyonunu kavrayan, tasarım kriterlerine göre değerlendirip tasarımcının istediği farklı mekânsal organizasyon seçenekleri sunan bir model geliştirmiştir. REVIT programı ile tasarlanan BIM verileri PYTHON programlama dilinde, Deep Neural Network ve Generative Adversarial Network makine öğrenmesi algoritmaları kullanılarak model oluşturulmuştur. DNN algoritmalarının kavramlardan bilgiler çıkararak tasarımları değerlendirdiği ve yeni mekan tasarımı için işlev odaklı kompozisyonlar ürettiği, GAN algoritmalarının ise eğitim setinde görülmeyen yeni tasarım varyasyonları üretebildiği sonuçları görülmüştür.

Tamke ve diğ. (2018) tarafından yapılan çalışmada, makine öğrenimi karmaşık form tasarım ve imalat sürecindeki uygulamaları üzerinden değerlendirilmiştir. Rhino-

Grasshopper yazılımında tasarlanan formlar TensorFlow platformunda işlenerek, Artificial Neural Network ve Optimizasyon algoritmaları kullanılan denetimli makine öğrenmesi modeli geliştirilmiştir. Karmaşık geometrilerin şekillerini kategorilendirmede ve yapısal yüklerin optimizasyonunda ANN algoritmaları verimli olacağı ve makine öğrenmesinin hem tasarım hem de üretim süreçlerinde etkili rol aldığı görülmüştür.

Singaravel ve diğ. (2018) ise sürdürülebilir bir bina tasarımında binanın ısıtma ve soğutma enerji talebini analiz eden makine öğrenmesi modeli önermektedir. Binanın enerji simülasyonları için EnergyPlus yazılımı kullanılmıştır. Derin öğrenme modeli Keras kütüphanesi kullanılarak PYTHON programlama dilinde TensorFlow platformunda oluşturulmuştur. Derin öğrenme modelinde Artificial Neural Network, Component-Based Machine Learning (CBML), Long Short-Term Memory, Multi Task Learning (MTL) algoritmaları kullanılarak model oluşturulmuştur. LSTM algoritmasının ANN algoritmasına kıyasla eğitim süresinin daha uzun sürdüğü fakat daha yüksek tahmin doğruluğu elde edildiği, ısıtma ML modeli için öğrenilen özelliklerin soğutma ML modelinin geliştirilmesinde de kullanılarak öğrenilen özellikler sayesinde benzer modellerde benzer tahmin doğruluklarının elde edilebileceği sonuçlarına varılmıştır.

Bloch ve Sacks (2018) tarafından yapılan çalışmada, BIM tabanlı modellemelerde mekanların sınıflandırılmasının makine öğrenmesi ile zenginleştirilmesi hedeflenmektedir. AZURE platformunda BIM verileri işlenerek Artificial Neural Network algoritmaları kullanılan denetimli bir makine öğrenmesi modeli geliştirilmiştir. Veri setinde toplam 150 alan bulunan %70'i eğitim için %30'u model değerlendirilmesi için ayrılarak çok sınıflı bir sinir ağı kullanılmıştır. Yapı nesnelerinin kendi özellikleri ve diğer nesnelerle mekânsal ve topolojik ilişkisi modelin oda tiplerinin sınıflandırma başarısını etkileyen ana unsurlar olduğu sonucuna varılmıştır. Doğrulama eğitim seti ile %82 doğru oranı ile konutlardaki oda tiplerinin makine öğrenmesi ile sınıflandırılması sağlanmıştır.

Huang ve Zheng'in (2018) çalışmasında, mimari çizimlerin makine öğrenmesi algoritmaları ile tanınması ve yeni çizimler oluşturulması hedeflenmiştir. PYTHON programlama dilinde PyTorch kütüphanesi kullanılarak Generative Adversarial Network, Rectified Linear Unit (ReLU) aktivasyon fonksiyonu, Pix2Pix ve Residual Network (ResNet) algoritmaları ile model oluşturulmuştur. Toplamda 115 mimari kat planı

görüntüsünün 100 tanesi eğitim veri seti olarak kullanılmış olup farklı işlevlere ait alanların farklı renklerle etiketleme işlemleri gerçekleştirilerek eğitim tamamlanmıştır. 15 görüntü ise test seti için ayrılarak modelin çalışma performansı test edilmiştir. Test sonucunda ise etiketleme bilgilerinin doğru detayda yapıldığı sürece ve yeterli derin ağlara sahip bir modelin eğitim süresinin arttırıldığı takdirde mekanları doğru tanıyabileceği ve yeni tasarımlar geliştirilebileceği görülmüştür.

Brown ve Mueller (2019) tarafından yapılan çalışmada, erken tasarım aşamasında parametrik tasarımların performansını etkileyebilecek değişkenlerin kafes kirişi üzerinden makine öğrenmesi algoritmaları ile tespit edilmesini hedeflemektedir. Parametrik kiriş tasarımı için Rhino-Grasshopper yazılımı, gün ışığı simülasyonları için DIVA yazılımı seçilmiştir. MATLAB ve R programlama dilleri kullanılarak Canonical Correlation Analysis (CCA) ve Principal Components Analysis algoritmaları ile model geliştirilmiştir. Farklı kiriş derinliğine karşılık gelen değişkenlere sahip farklı boyutlardaki veri kümelerinden CCA'nın PCA'ya göre daha anlamlı ilişkiler çıkardığı, PCA'nın ise anlamlı geometrik değişiklikler sunmasada optimal tasarımların belirlenmesinde performansı iyileştirme yönünde etkili olabileceği görülmüştür.

Feng ve diğ. (2019) ise, parametrik tasarım ve makine öğrenmesi algoritmalarının erken tasarım süreçlerinde birlikte çalıştığı bir yaklaşım geliştirmiştir. Parametrik tasarım için Revit ve Dynamo yazılımı, simülasyon için EnergyPlus yazılımı kullanılmıştır. MATLAB program dilinde Fuzzy C-means clustering (FCM), The Extreme Learning Machine (ELM), Particle Swarm Optimization (PSO) algoritmaları kullanılarak model geliştirilmiştir. İki farklı iklim tipine sahip bölgelerde tasarlanan farklı planlara sahip binalar üzerinden iklimsel farklılıkların binalar üzerindeki etkileri değerlendirilmiş olup, binaların yükseklikleri, genişlikleri, pencere-duvar boyutları, kiriş boyutları, yapı malzemeleri gibi parametrelerin önemli etkileri olduğu görülmüştür. Daha sonra 1024 örnek eğitim veri seti için 128 örnek test veri seti için kullanılarak erken tasarım kararlarının çevresel etkileri için doğru tahminler elde edilmiştir. Geliştirilen modelin performansı, 500 örnek içeren Monte Carlo analizine dayanan sonuçlarla karşılaştırıldığında geliştirilen modelin uygulanabilir olduğu doğrulanmıştır.

Rhee ve diğ. (2019) tarafından yapılan araştırmada, binaları çevreleriyle olan ilişkilerine göre sınıflandırma ve kümeleme işlemlerini makine öğrenmesi ile yaparak kentsel analiz

gerçekleştirmek hedeflenmektedir. Rhino-Grasshopper yazılımında kent modellemesi yapılmıştır. Modeldeki veriler Tensorboard platformunda t-distributed Stochastic Neighbor Embedding (t-SNE), DBSCAN, K-Nearest Neighbor algoritmaları ile işlenerek makine öğrenmesi modeli oluşturulmuştur. Görüntülerden mimari bağlamlar çıkarmak için t-SNE algoritması ile yüksek boyutlu verileri daha düşük verilere çevirerek boyut azaltma işlemi yapılmıştır. t-SNE görselleştirme sonuçlarına DBSCAN uygulanarak veri noktaları arasında benzer mimari bağlamları temsil eden binalar gruplandırılmıştır. KNN ile DBSCAN tarafından tanımlanan binaların ayak izleri ve sınırları detaylı olarak işaretlenmiştir. Bu kapsamda geliştirilen makine öğrenmesi modellerinin kentsel morfolojik analiz için kullanabilir olduğu sonucuna varılmıştır.

Newton (2019) ise, belirli üsluba sahip mimari plan tarzının makine öğrenmesi ile öğrenilerek benzer nitelikte yeni plan şemaları oluşturulmasını sağlayan model geliştirilmesini hedeflemektedir. PYTHON programlama dilinde TensorFlow platformunda Generative Adversarial Network, Wasserstein Generative Adversarial Network (WGAN) ve Deep Neural Network makine algoritmaları kullanılarak model geliştirilmiştir. Görüntülerin analiz edilmesinde sıklıkla kullanılan GAN modeli ile Le Corbusier'in mimari planlarından oluşan 45 plan görüntüsü üzerinden eğitim gerçekleştirilip performans denemeleri gerçekleştirilmiş olup, WGAN ile mimari planlar sentezlenmiştir. Burada temel amaç küçük veri setleri ile istenilen sonuca ulaşılabilir olup olmadığı tartışılmıştır. 45 görüntülük veri seti üzerinde büyütme, döndürme, gürültü ekleme gibi çeşitli veri artırma uygulamaları denenmiş ve en başarılı sonucu gürültü ekleme ile elde edildiği sonucuna varılmıştır.

Uzun ve Çolakoğlu'nun (2019) araştırmasında, mimari plan ve kesitlerin tespit edilmesini sağlayan bir makine öğrenmesi modeli geliştirmesi hedeflenmektedir. 100 tane piksel bazlı kesit çizimi, 100 tane piksel bazlı plan çizimlerinden oluşan görüntü veri seti kullanılmıştır. 80 tane plan çizimi, 80 tane kesit çizimi eğitim veri seti için ayrılmıştır. Model eğitimi için ilk olarak LabelImg yazılımında mimari kesit ve planların etiketlemeleri yapılmıştır. Daha sonra TensorFlow platformunda önceden eğitilmiş bir model üzerinden denetimli makine öğrenmesi algoritmaları işlenmiştir. Tensorboard platformunda ise algoritmanın eğitim doğruluğu test edilmiştir. Modelde kullanılan veri kümesi boyutunun yeterli büyüklükte olmaması, veri setindeki örnek türlerinin farklılaşan

örnekler olduğundan heterojen olması, plan ve kesit çizim görüntülerinin farklı pikseller olması sebebi ile test edilen algoritmanın birçok tahminde istenilen sonucu verememesine sebep olmuştur. Veri kümesinin boyutu, veri setindeki örnek türleri ve veri setindeki örneklerin çözünürlüklerinin modelin performansını etkileyen önemli unsurlar olduğu sonucu çıkarılmıştır.

Wu ve diğ. (2019) tarafından yapılan çalışmada, bambu elemanlarının birleşimi için arttırılmış gerçeklikle desteklenen ve nesne tanıma özelliği kullanılarak eğitilmiş bir makine öğrenmesi modeli önerilmektedir. 230 görselden oluşan veri setindeki LabelImg yazılımı kullanılarak etiketleme işlemi yapılan bambu görsellerinin 182 görüntüsü eğitim seti için, 48 görüntüsü test veri seti için ayrılmıştır. TensorFlow platformunda Faster Region-based Convolutional Neural Network (Faster_RCNN) algoritması kullanılarak makine öğrenmesi modeli oluşturulmuştur. Geliştirilen model sayesinde bambu direklerinin uçlarını ve düğümlerini %98 oranda doğrulukla tahmin etme başarısı yakalanmıştır. Bambu malzemelerinin birleşim detayları için 3D yazıcı ve CNC makineleri kullanılarak birleşim elemanları üretilmiştir. Daha sonra arttırılmış gerçeklik kullanılarak bambu malzemelerin nasıl birleşeceğine dair talimatlar kolay ve verimli şekilde gerçekleştirilmiştir. Böylece mimari malzemelerin detaylarının makine öğrenmesi ile tespit edilebildiği, üretim teknolojileri ile birleşim elemanlarının üretilbildiği, arttırılmış gerçeklik ile malzeme ve birleşim elemanlarının inşaat aşamasında kullanılabilir olduğu sonucuna varılmıştır.

Yetkin ve Sorguç (2019) ise araştırmalarında, bir kafes kiriş tasarımının ilk aşamalarında tasarım alternatifleri arasından yüksek performans sağlanabilmesi için bir çerçeve önermiştir. Kafes kiriş tasarımı için Karamba yazılımından örnek parametrik modeller kullanılmıştır. Rhino-Grasshopper yazılımında farklı tasarım alternatifleri çoğaltılmıştır. Sonrasında önceden eğitilmiş Artificial Neural Network makine öğrenmesi algoritması kullanılarak tahmin modeli önerilmiştir. 350 ve 1150 farklı tasarım alternatifinden oluşan yapay sinir ağı eğitilirken, verilerin sayısı arttıkça hata oranının düştüğü gözlemlenmiştir. Birçok yinleme sonrasında yapay sinir ağlarının kafes kirişin çapraz destek konumlarının düşük bir hata oranı ile doğru tahmin ettiği görülmüştür.

Koo ve diğ. (2019) tarafından yapılan çalışmada, BIM modellerini anlamsal olarak detaylandırmak için modeldeki verilerin geometrik ve ilişkisel bakımından sınıflandırma

işlemine yapan bir makine öğrenmesi modeli geliştirilmiştir. 6 farklı BIM modelindeki yapısal elemanların detaylandırılması ile toplamda 4187 öğeye sahip 8 yapı eleman sınıfından oluşan bir veri seti elde edilmiştir. IfcOpenShell kütüphanesinden BIM verilerinin detaylı bilgileri çıkarılmıştır. PYTHON programlama dilinde SVM, Naïve Bayes ve Logistic Regression algoritmaları kullanılarak model geliştirilmiştir. İlk aşamada 3349 eğitim veri seti, 838 test veri seti şeklinde veri seti bölünerek modelin eğitimi gerçekleştirilmiştir. SVM'nin Naïve Bayes ve Logistic Regression algoritmalarına göre daha iyi sınıflandırmada bulunduğu görülmüştür. Modelin iyi performans verebilmesi için veri setinde bulunan elemanların dengeli şekilde yer alması, farklı elemanların benzer niteliklere sahip olmaması önemli parametreler olduğu sonucuna varılmıştır.

Li ve diğ. (2019) tarafından yapılan çalışmada, karmaşık bina formlarının erken tasarım aşamasında enerji tüketimi için makine öğrenmesi ile tahmin modeli oluşturulmuştur. Mekanların enerji analizleri ve simülasyonları EnergyPlus ve DesignBuilder yazılımları kullanılarak oluşturulmuştur. MATLAB programlama dilinde Artificial Neural Network, Method of Characterization Decomposition (MCD method) ve Method of Spatial Homogenization Decomposition (MSHD method) kullanılarak makine öğrenmesi modeli geliştirilmiştir. MCD yönteminde toplamda 172.980 örnek içeren veri setinin 150.000 örneği ANN enerji tahmininin eğitim veri seti için kullanılarak model eğitilmiştir. 22980 örnek test veri seti için ayrılarak ANN modelinin doğruluğu test edilmiştir. Hesaplama birimlerinin soğutma/ısıtma enerji tüketimine ilişkin R^2 değeri 0,998'den yüksek sonuç elde edilmiştir. MSHD yönteminde ise 243 örnek seti içeren veri setinin 220 örneği ANN enerji tahmininin eğitim veri seti için kullanılarak model eğitilmiştir ve 23 örnek test veri seti için ayrılarak ANN modelinin doğruluğu test edilmiştir. Soğutma/ısıtma enerji tüketiminin tahmin edilen değerlerine ilişkin sonuçlar R^2 değeri 0,999'un üzerinde olduğu ve tahmin doğruluğunu karşılamaktadır. Basit geometrilere kadar karmaşık formlara kadar ANN modelinin bina enerji tüketimi hesaplamalarında hızlı tahminler için kullanılabilir olduğu sonucu çıkarılmıştır.

Alymani ve diğ. (2020) tarafından yapılan çalışmada, mimari tarzların topografya ile ilişkisine göre anlaşılması için kümeleme yöntemleri ile model oluşturulması hedeflenmektedir. PYTHON programlama dilinde Scikit-Learn kütüphanesi kullanılarak

Jupyter Notebook platformunda K-Means Cluster, K-Modes Cluster ve Gaussian Mixture Model, t-SNE algoritmalarından oluşan makine öğrenmesi modeli geliştirilmiştir. 139 mimari görsel veri setinin %70'i eğitim veri seti için, %30'u test veri seti için ayrılmıştır. K-means algoritması %89 başarı oranı ile en iyi performansı göstermiştir. Etiketleme işlemi yapılmadan da etiketsiz veriler üzerinden binaların zeminle ilişkilerinin kümelendirilebileceği sonucu çıkarılmıştır.

Brown ve diğ. (2020), mimari kat planlarının işlevlerine göre sınıflandırılmasının makine öğrenmesi ile yapılmasını hedeflemiştir. 454 mimari kat planlarının 6 oda sınıfına göre etiketleme işlemi için VGG Image Annotator yazılımı kullanılmıştır. Keras kütüphanesinden yararlanılarak TensorFlow platformunda PYTHON programlama dilinde Mask Region-based Convolutional Neural Network (Mask R-CNN) algoritması ile makine öğrenmesi modeli geliştirilmiştir. Kısıtlı veri söz konusu olduğundan ve benzer oda planlarının olması sebebiyle modelin bazı odaları yanlış sınıflandırmasına sebep olmuştur. Bu sebeple modelin veri kümesinin boyutu ve veri kümesindeki semboller, ikonlar, çizgi gibi özellikler, görüntü içindeki elemanların şekilleri ve formları makine öğrenmesi modelinin çalışma performansını etkilediği sonucuna varılmıştır.

Płoszaj-Mazurek ve diğ. (2020) parametrik tasarımın ilk aşamalarında karbon ayak izi tahmini sağlayan bir model geliştirmiştir. Parametrik bina tasarımı için Rhino-Grasshopper yazılımında 3 farklı tasarım modellenmiştir. Ardından karbon ayak izi hesaplamaları ve simülasyonları için EnergyPlus yazılımı kullanılmıştır. Elde edilen veriler Keras kütüphanesinden alınan sinir ağı PYTHON programlama dilinde yazılmıştır. Denetimli makine öğrenmesi algoritması olan Gradient Boosting Regressor (GBR) ve Convolutional Neural Network algoritması kullanılarak model geliştirilmiştir. Birinci çalışmada küboid olan şekiller kullanılarak eğitilmiş 100.000 örneğe sahip GBR modelde toplam karbon ayak izi tahmini %1,3 hata oranı elde edilmiştir. İkinci çalışmada küboid olmayan prizma şekiller kullanılarak eğitilmiş 997 örneğe sahip GBR modelde toplam karbon ayak izi tahmini %1,6 hata oranı elde edilmiştir. Üçüncü çalışmada ise kentsel bir ortamda varsayılan şekiller kullanılarak 3000 örneğe sahip CNN modeli eğitilmiş ve yapılandırılmış karbon tahmini için %0,6 operasyonel karbon için %0,8 hata oranı elde edilmiştir. Elde edilen sonuçlarda belirli boyutlarda tasarımlar, yapı

malzemeleri gibi sınırlamar olmasına rağmen makine öğrenmesinin binaların çevresel performansını ölçümlemede kullanılabilir olduğu sonucu elde edilmiştir.

Chan ve Spaeth (2020) ise mimari eskizlerden gerçekçi görüntüler oluşturmak amacı ile makine öğrenmesini kullanmıştır. TensorFlow platformunda Cyclic-cGAN ve Pix2Pix algoritmaları ile model oluşturulmuştur. Modelin çalışma prensibi eskizleri görsellere dönüştürmek ve bu görsellerden eskizler üretmek şeklinde iki döngüden oluşmaktadır. 84 eskizden oluşan veri setinin 80'i eğitim veri seti için, 4'ü test veri seti için ayrılmıştır. Elde edilen sonuçlara göre oluşturulan modelin giriş eskizlerini görüntülere dönüştürebildiği, eskizleri yorumlayarak yeni mekânsal ilişkiler oluşturabildiği görülmüştür. Böylece öğrenme modelinin erken tasarım aşamasında mimarlar için yardımcı bir araç olabileceği öngörülmüştür.

Zheng ve diğ. (2020) tarafından yapılan çalışmada, parametrik tasarımlar yapılırken form oluşturma aşamasında formların yapısal performansını değerlendirebilen bir makine öğrenmesi modeli önerilmiştir. Parametrik form oluşturmak için Rhino-Grasshopper yazılımı kullanılmıştır. TensorFlow platformunda PYTHON programlama dilinde Genetic Algorithm ve ANN makine öğrenmesi algoritmaları kullanılarak model geliştirilmiştir. Yapısal performansı ölçümleyebilmek için formların bükülme ve burkulma kapasitesi ve inşa edilebilirlik açısından çok geniş veya çok küçük alanlara sahip olması sebebi ile kabul edilemez yüz şeklinde iki kriter dikkate alınmıştır. En uygun yapay sinir ağı seçim işlemi için 1500 rastgele oluşturulmuş örnek içeren farklı katman sayılarına sahip yapay sinir ağları test edilerek en yüksek doğruluğa sahip olduğundan model eğitimi için 5 katmanlı yapay sinir ağı seçilmiştir. Daha sonra başlangıçta 175 örnek içeren veri seti kullanılarak yinelemeli yöntemle 5 döngüden oluşan ve her döngünün çıkışındaki veriler yeni döngünün giriş verisine eklenerek yapay sinir ağlarının formların bükülme kapasitesi hesaplama ve kabul edilemez yüzleri tespit etme eğitimi gerçekleştirilmiştir. Elde edilen sonuçlara göre döngü sayısı arttıkça tahmin edilen bükülme kapasitesi artmaya başlarken kabul edilemez yüzlerin sayısı azalmaya başlaması istenilen sonuçları vermiştir. Böylece form bulma sürecinde eğitilen yapay sinir ağı modelinin genetik algoritmalara göre daha hızlı ve tüm değerleri tahmin edebilir olduğu görülmüştür.

Gonzalez ve diğ. (2020), yapısal bina tipolojilerinin tanımlanması ve sınıflandırılması için derin öğrenme modeli geliştirmiştir. Keras kütüphanesi kullanılarak TensorFlow platformunda geliştirilen derin öğrenme modeli için veri arttırma işlemini yaparken ImageNet kütüphanesinden yararlanılmıştır. VGG16, VGG19, InceptionV3, Xception, ResNet50 olmak üzere 5 farklı CNN modeli ve Gaussian Blur kullanılarak model geliştirilmiştir. 10.000 görüntü içeren veri kümesi yığma veya betonarme malzemeli olma durumuna ve sünek olma - sünek olmama durumuna bağlı şekilde 8 kategoride sınıflandırılmıştır. Seçilen 5 CNN modellerinin hepsinde, veri kümesinin %60'ı eğitim, %20'si test ve %20'si doğrulama işlemleri için ayrılmıştır. Her modelin sonunda elde edilen bilgilere göre malzemenin anlaşılmasını engelleyecek şekilde cephelerin kaplanması, binalarda görülmeyen donatılara sahip duvarların olması, benzer desen ve renkleri gösteren malzemelerin kullanılması gibi etkenlerin binaların bazılarının yanlış sınıflandırıldığı tespit edilmiştir. Fakat buna rağmen üç bina tipolojisinde hem süneklik hem de malzeme tipi için doğruluk seviyeleri başarılı sonuçlar verdiği görülmüştür.

Hamid-Lakzaeian (2020) ise lazer tarama ile desteklenen bina cephe özelliklerinin tespit edilmesini sağlayan bir makine öğrenmesi modeli geliştirmiştir. Cloud Compare ve Cyclone yazılımları kullanılarak 3 farklı cephe görüntüsüne sahip binaların cephesine ait nokta bulutu verileri işlenmiştir. MATLAB programlama dilinde Random Sample Consensus (RANSAC), Multi-Planar algoritması kullanılarak makine öğrenmesi modeli geliştirilmiştir. Burada temel amaç binaların cephe görüntüleri üzerinden yapısal elemanların yapısal olmayan elemanlardan ayırarak sınıflandırma işleminin gerçekleştirilmesidir. Çoklu düzlemlili bina cephelerindeki farklı düzlemlerin tespitinde, cephelerde yer alan pencere, kapı gibi açıklıkların belirlenmesinde, cephelerdeki balkonlar, mimari süslemeler gibi çıkıntıların belirlenmesinde geliştirilen nokta bulutu işlemeli modelin kullanılabileceği sonucu çıkarılmıştır.

Hsu ve diğ. (2020) tarafından yapılan çalışmada, BIM aracılığı ile yapı tasarım aşamasında çıkabilecek olası çakışmaların geliştirilen makine öğrenmesi algoritması ile çözümlenmesi hedeflenmektedir. Revit yazılımı kullanılarak tasarlanan yapının verileri Visual Studio platformunda işlenmiştir. Weka yazılımı kullanılarak Backpropagation Neural Network (BPNN) ve Simulated Annealing (SA) algoritmaları kullanılarak model geliştirilmiştir. BPNN kullanılarak model eğitilerek öğrenme gerçekleştirilmiş olup

çakışma analizleri tespiti gerçekleştirildi ve çakışma sayısını minimuma düşürebilmek adına SA kullanılarak model optimizasyonu gerçekleştirilmiştir. Deneysel sonuçlar önerilen modelin başarısını doğrulamış olup tasarımın erken aşamalarında çakışmaların tespiti ile hem zaman kaybı önleme hem maliyet revizyonlarını en aza indirmeye fırsatı oluşturmaktadır.

Sebestyen ve Tyc (2020) ise çalışmalarında, parametrik cephe tasarımının enerji performansını değerlendirebilen makine öğrenmesi modeli önermiştir. Parametrik cephe tasarımı Rhino-Grasshopper yazılımında, hava durumu ile bilgilerin işlenmesini EnergyPlus yazılımında gerçekleştirilmiştir. PYTHON programlama dilinde, Keras, Sklearn kütüphaneleri kullanılmıştır. TensorFlow platformunda RandomSearchCV ve Artificial Neural Network algoritmaları ile model geliştirilmiştir. Cephe sisteminin çevresel analizinin gerçekleştirilmesi için denetimli öğrenme seçilmiştir. 4.500 farklı basit cephe ve 10.000 farklı karmaşık cephe sistemi için veriler oluşturulmuştur. Eğitim veri setleri ile modelin eğitimi, test veri setleri ile modelin çalışma performansı değerlendirilmiştir. Cephe üzerindeki gölgelendirme elemanlarının yükseklikleri, uzunlukları, açıları gibi etkenlerin gölge analizinin tahmin doğruluğunda önemli parametreler olduğu gözlemlenmiştir. Değerlendirme sonucunda elde edilen tahmin oranlarına göre geliştirilen makine öğrenmesi modelinin erken tasarım aşamasında basit ve karmaşık cephelerin gölge analizlerinde kullanılabileceği tespit edilmiştir.

He ve diğ. (2021) tarafından yapılan çalışmada, bina ve yakın çevresindeki rüzgar ortamının makine öğrenmesi modeli ile değerlendirilmesi amaçlanmaktadır. Rhino-Grasshopper yazılımı kullanılarak parametrik bina modellemesi yapılmıştır. Daha sonra NumPy, Pandas ve Scikit-Learn kütüphanelerinden alınan verilerle birlikte Jupyter Notebook platformunda Split Function, Extra Tree Regressor (ETR) algoritmaları kullanılarak makine öğrenmesi modeli geliştirilmiş ve analizler gerçekleştirilmiştir. 300 bina örneğinin hesaplamalı akışkanlar analizi sonuçları makine öğrenmesi modelinin eğitimi için kullanılmış ve 24 bina örneği modelin tahmin doğruluğu için test edilmesinde kullanılmıştır. Bu çalışmada sadece dikdörtgen formlu binalar ve düşük hız alanları kullanıldığı göz önünde bulundurularak, oluşturulan modelin test sonuçlarında R^2 değeri %97,7 ulaşarak tahminlerin doğru yapıldığı görülmüştür.

Fatehi ve diğ. (2021) tarafından geliştirilen makine öğrenmesi modeli ile mimaride uygulanan seramik malzemesi tasarımının verimliliğini ve işlevselliğini arttırmak hedeflenmektedir. Tasarlanan seramiklerin enerji analizleri için ANSYS Workbench ve ANSYS Fluent yazılımları kullanılmıştır. PYTHON programlama dilinde Sklearn kütüphanesinden alınan Multi Layer Perceptron algoritması, ReLu aktivasyon fonksiyonu ve Artificial Neural Network kullanılarak makine öğrenmesi modeli geliştirilmiştir. Mimari seramik panellerin sürtünme yoluyla enerji dağıtımında %30'a kadar, karoların kayma mesafesinde %7'ye kadar iyileşmeler ve gerinim enerjisinde %80'e kadar azalma sonuçları elde edildiğinden makine öğrenmesinin mimari seramik panellerin termomekanik performansını incelemek için kullanılabilir olduğu gözlemlenmiştir.

Dixit ve diğ. (2021), kentsel ölçekten bakıldığında bina sınırlarının tespitini yapmak amaçlı uydu görüntülerinden çıkarım yapabilen bir derin öğrenme modeli geliştirmiştir. QGIS yazılımı kullanılarak haritalar hazırlanmıştır. Keras kütüphanesi kullanılarak TensorFlow platformunda Dilated-ResUnet, Convolutional Neural Network, ReLu aktivasyon fonksiyonu, Sigmoid sınıflandırma algoritmaları kullanılarak derin öğrenme modeli geliştirilmiştir. Veri setinde bulunan 2463 görüntü modelin eğitimi, 129 görüntü modelin doğrulanması ve 129 görüntü modelin testi için kullanılarak model eğitimi tamamlanmıştır. Değerlendirmeler sonucunda 0,4718'li F1 puanı, 0,8631 doğruluk oranı elde ederek makine öğrenmesi modelinin uydu görüntülerinden bina çıkarımı için kullanılabileceği sonucu çıkarılmıştır.

Martínez-Rocamora ve diğ. (2021) ise BIM tabanlı tasarlanan bir yapının bina tipolojisinin çevresel etkilerini değerlendirebilen bir makine öğrenmesi modeli önermiştir. BIM tabanlı proje Revit yazılımı kullanılarak modellenmiştir. Binanın çevresel etkilerinin ölçümü için Revit yazılımı ile entegre çalışan Tally yazılımı kullanılmıştır. Scikit-Learn, Numpy, Seaborn ve Matplotlib kütüphaneleri kullanılarak PYTHON programlama dili kullanılarak Random Forest, Decision Trees ve Correlation Matrix algoritmaları kullanılarak model geliştirilmiştir. 92 konutlu 11 katlı bir konut binası verileri dikkate alınarak modeller test edilmiştir. Ötrofikasyon potansiyeli, küresel ısınma potansiyeli, duman oluşma potansiyeli, birincil enerji talebi, yenilenemeyen enerji talebi, yenilenebilir enerji talebi gibi binaların çevresel etkilerini tahmin etmek için etkili olan cephe, cephenin ısı yalıtım malzemesi, bölmeler, çatı ve çatının ısı yalıtım

malzemeleri gibi parametreler dikkate alınarak model eğitilmiştir. Elde edilen sonuçlara göre RF algoritması, bina tipolojisindeki en belirleyici değişkenler olan bölmeler ve cephelerin belirlenmesinde ve binaların çevresel etkilerinin tahmin edilmesinde başarılı sonuçlar vermiştir.

Xiang ve diğ. (2021) tarafından yapılan çalışmada, yüksek yoğunluklu yapılı çevre ve insan etkileşimini anlamaya yönelik makine öğrenmesi modeli oluşturulmuştur. Çalışmanın gerçekleştirildiği bölgenin üç boyutlu bina modellemesi Rhino-Grasshopper yazılımı kullanılarak yapılmıştır. Ardından 103 katılımcının yapılı çevredeki hareketleri ve hissettikleri duygular veri olarak MATLAB programlama dilinde kayıt altına alınmıştır. Aynı zamanda 548 sokak görünüm fotoğrafından oluşan yapılı çevre veri seti, CamVid kütüphanesinden önceden eğitilmiş Resnet-18 ve Deeplab v3+ algoritmaları kullanan bir model oluşturulup gökyüzü, bina, araba, insan, yol, ağaç ve işaret sembolü olmak üzere 7 sınıfa yeniden sınıflandırılmıştır. Duygu tahmini için Random Forest, Multiple Linear Regression (MLR) makine öğrenmesi algoritmaları kullanarak yapılı çevre ve insan etkileşimini ortaya koyan bir model önerilmiştir. RF modelinin tahmin yeteneği MLR modeline göre daha iyi olduğu, ağaç ve bina görünümü faktörlerinin duyguyu tahmin etmek için en önemli değişkenler olduğu sonucu çıkarılmıştır.

Daemei ve diğ. (2021) tarafından yapılan araştırmada, yeşil bitki örtüsü ile kaplı olan bir binanın termal performansını ölçmeye yönelik bir derin öğrenme modeli geliştirilmiştir. Deneysel ölçümlerin yapılabilmesi için bina modellemesini EnergyPlus yazılımı ile ve yeşil bitki örtüsü ile kaplı duvarın çevredeki hava üzerindeki etkisini değerlendirmek için ENVI-met yazılımları kullanılmıştır. Analizler sonucu elde verilerin %80'i eğitim veri seti olarak, %20'si test veri seti olarak kullanılmıştır. Keras kütüphanesi kullanılarak TensorFlow platformunda PYTHON programlama dilinde Artificial Neural Network ve Multi Layer Perceptron Artificial Neural Network (MLP ANN) algoritmalarından oluşan bir model oluşturulmuştur. Geliştirilen modelin yeşil olmayan duvar hava sıcaklığı, yeşil olmayan duvar bağıl nemi, yeşil duvar hava sıcaklığı ve yeşil duvar bağıl nemini tahmin etmede elde edilen sonuçlar sırası ile %0,7, %0,67, %0,69 ve %0,6 hata oranlarına sahip olduğu görülmüştür. Yeşil duvarın iç mekan sıcaklığını düşürdüğü, bağıl nem seviyesini azalttığı tespit edilmiştir.

Zheng ve Yuan'nın (2021) çalışmasında, tasarımcılara parametrik tasarım aşamasında destek olacak farklı yapı formları üretebilen bir makine öğrenmesi modeli geliştirilmiştir. Parametrik tasarım için Rhino-Grasshopper yazılımı kullanılmıştır. Sinir ağı eğitimi için TensorFlow platformunda Numpy kütüphanesinden yararlanılarak PYTHON programlama dilinde Generative Adversarial Network, Artificial Neural Network, Pix2Pix, Random Forest, Linear Regressor ve K-Means Cluster makine öğrenmesi algoritmaları kullanılarak model geliştirilmiştir. Geliştirilen ANN modeli diğer modellere göre %98,05'lik bir doğruluk oranı sunmakta ve farklı katmanlara sahip ANN modellerinden 5 katmanlı olan ANN modelinde hata oranının en düşük olduğu görülmüştür. Sonuç olarak, ANN ile mevcut mimari verilerle eğitilmesi ile farklı özelliklere sahip yeni tasarımların özelliklerini öğrenebilir ve yeni tasarımlar geliştirebilir olduğu tespit edilmiştir.

Martínez-Comesaña ve diğ. (2021), bir binanın iç mekan çevre koşullarını tahmin edebilen bir makine öğrenmesi algoritması önermiştir. Çalışma için seçilen mevcut bir binanın içinde ölçülen değerler ve bina dışındaki hava durumu verileri toplanarak veri seti oluşturulmuştur. Binanın içinde iç mekan sıcaklığı, bağıl nem ve karbondioksit ölçümleri yapılmıştır. Binanın dışında ise hava sıcaklığı, bağıl nem ve küresel güneş ışıınımı değişkenlerinin verileri toplanmıştır. PYTHON programlama dilinde çok amaçlı genetik algoritma NSGA-II, Artificial Neural Network ve Multi Layer Perceptron algoritması kullanılarak makine öğrenmesi modeli geliştirilmiştir. Model sonuçlarında dış mekan için toplanan verilerin iç mekan çevre koşullarına etkisi önemli bir parametre olduğu gözlemlenmiştir. İç mekan sıcaklık tahmini için hata oranının %5,90 olması, bağıl nem hesaplamalarında hata oranının %2,89 olması, karbondioksit seviyelerinin ölçülmesinde ise hata oranı beklenen sonuç gelmesi sebebi ile geliştirilen modelin binanın iç mekan çevre koşullarını hesaplamada kullanılabilir olduğu sonucu çıkarılmıştır.

Fan ve diğ. (2021) tarafından yapılan çalışmada, kentsel alanları uydu görüntülerinden analiz edip sınıflandırma ve bilgi çıkarımı yapabilen bir derin öğrenme modeli geliştirilmiştir. Uydu görüntülerinden alınan veriler Normalization algoritmaları ile normalleştirme işlemi yapılarak, ArcMap ve eCognition yazılımlarında Random Forest algoritması kullanılarak bina, yol, diğer geçirimsiz, ağaç, düşük bitki örtüsü, boş arazi, su

ve gölge gibi 8 kategoriye sınıflandırılmıştır. Veri kümesindeki verilerin %80'i eğitim için kullanılarak model eğitilmiş, %20'si test için kullanılarak modelin doğruluğu test edilmiştir. Daha sonra yapıların sınırları belirginleştirilmiş ve analizler yapılmıştır. TensorFlow platformunda CNN modeli olan FCN ve UNet modellerini ResNet ile birleştirerek Res-FCN ve Res-UNet elde edilmiştir. Res-UNet'in ilk katmanlarına başlangıç modülü eklenerek Res-UNet + elde edilmiştir. Bu 5 derin öğrenme modellerinin tahmin oranları karşılaştırılıp Res-UNet + modeli daha iyi performans gösterdiği için bu model seçilmiştir. Oluşturulan modelin %83,1 doğruluk oranı ile uydu görüntülerinin sınıflandırılma işleminin yapılabilirdiği sonucu göstermiştir.

Wang ve diğ. (2021) tarafından yapılan araştırmada, kentsel ölçekte binaların aylık ve yıllık kullanıldığı enerji tahmini için model geliştirmek ve test etmek hedeflenmiştir. Bu kapsamda 539 konut binası ve 153 kamu binasının aylık ve yıllık enerji verileri dikkate alınarak 5 tipik veri odaklı kentsel bina enerji tahmin modeli incelenmiştir. Scikit-Learn kütüphanesinden yararlanılarak TensorFlow platformu tercih edilmiştir. PYTHON programlama dilinde K-Nearest Neighbor, Support Vector Machine ve Long Short-Term Memory algoritmaları kullanılarak makine öğrenmesi modeli geliştirilmiştir. Veri odaklı oluşturulan 5 farklı modelde bu üç makine öğrenmesi teknikleri test edilmiştir. 5 modelin test sonuçlarına göre 3 algoritmadan LSTM'in kentsel bina enerji modelinde tahminlerinin daha iyi performans gösterdiği görülmüştür.

Lin ve Tsay'nın (2021) çalışmasında, bina cephelerinin gün ışığı performansını tahmin etmeye yönelik makine öğrenmesi modeli geliştirilmiştir. Parametrik olarak tasarlanan cepheler Rhino-Grasshopper yazılımı kullanılarak oluşturulmuştur. Gün ışığı simülasyonları yapmak için Rhino yazılımı ile entegre çalışabilen DIVA yazılımı kullanılmıştır. 193.500 veri setinin %90'ı eğitim veri seti için, %10'u test veri seti için ayrılmıştır. Makine öğrenmesi modeli eğitebilmek için Grasshopper yazılımı ile entegre çalışabilen DODO yazılımı kullanılmış olup, Artificial Neural Network algoritması kullanılarak gün ışığı tahmin modeli geliştirilmiştir. Farklı cephelerde gün ışığı tahmin modeli test edilerek, geliştirilen model ile simülasyonlar arasında benzer sonuçlar edilmesi sebebi ile binaların gün ışığı performansında makine öğrenmesinin kullanılabilir olduğu gözlemlenmiştir.

He ve diğ. (2021) ise mimari kat planları üzerinden gün ışığı simülasyonları yapabilen derin öğrenme modeli önermiştir. SketchUp ve Rhino-Grasshopper yazılımları ile mimari kat planları modellenmiştir. MOOSAS yazılımı ile simülasyon için ön hazırlık yapılmıştır. RAIDIANCE ve DAYSIM yazılımları kullanılarak simülasyon hesaplamaları yapılmıştır. Convolutional Neural Network, Generative Adversarial Network, ResNet50 ve Pix2Pix algoritmaları kullanılarak model geliştirilmiştir. 575 örnekten oluşan gerçek konut kat planları ile 575 örnekten oluşan temsili parametrik modelleri kullanılarak iki veri seti oluşturulmuştur. Her iki veri setinin %70'i eğitim, %15'i doğrulama, %15'i test için ayrılmıştır. Değerlendirmeler ve tahminler cepheler dahil edilmeden sadece kat planları üzerinden yapılmıştır. ResNet modeli parametrik formlar yerine genel bina formlarının gün ışığı performansını tahmin etmede başarılı olmuştur, Pix2Pix algoritması ise kat planları üzerinden aydınlık dağılımını tahmin etmede verimli sonuçlar etmiştir.

Millán ved diğ. (2022) tarafından yapılan çalışmada, tasarım sürecinde makine öğrenmesi algoritmalarının etkisini test etmek amacıyla deneysel bir çalışma yapılmıştır. 3 boyutlu modelleme için SketchUp ve MG-Shade yazılımı kullanılmıştır. WEKA yazılımı ile makine öğrenmesi algoritmaları Naïve Bayes, Random Forest ve JRip kullanılarak Denetimli makine öğrenmesi ve hiyerarşik kümeleme algoritması kullanarak Denetimsiz makine öğrenmesi modelleri geliştirilmiştir. 52 katılımcı öğrencinin tasarladıkları barınak tasarımları estetik, işlevsellik, teknik yönler ve ekonomik yönler olmak üzere 4 kategoriye göre uzmanlar tarafından değerlendirilmiştir. Denetimli öğrenme modeli ile alınan kararlara göre en iyi projelerin sınıfını belirlenmiştir. Denetimsiz öğrenme modeli ile benzer stratejiler kullanan projeler kümelendirilmiştir. Elde edilen sonuçlara göre tasarım süreçlerindeki stratejileri ve ilişkileri açıklamak ve anlamak için makine öğrenmesinin kullanılabilir olduğu gözlemlenmiştir.

Singh ve diğ. (2022) ise, enerji verimli bina tasarımı için BIM ve makine öğrenmesinin entegre çalıştığı bir yaklaşım önermiştir. Tasarım alanını keşfetme, seçenekleri analiz etme, seçenekleri karşılaştırma, duyarlılık analizi yapma ve değişiklikleri izleme gibi hedeflenen beş özellik ile makine öğrenmesinin enerji verimliliği ve enerji performansı hakkında bilgiler sunması amaçlanmıştır. BIM aracı olan Revit yazılımı kullanılmıştır. Enerji simülasyonları için EnergyPlus yazılımı kullanılmıştır. Makine öğrenmesi modeli

geliştirmek için TensorFlow platformunda C# programlama dili kullanılarak enerji tahmin modeli oluşturulmuştur. Scikit-Learn kütüphanesi kullanılarak PYTHON programlama dilinde istatistik analizler gerçekleştirilmiştir. Deep Convolutional Neural Network algoritmaları kullanılarak model geliştirilmiştir. Eğitim için 25.000 rastgele örnekten oluşan veri seti kullanılmış olup 1000 rastgele örnek içeren veri seti test için kullanılarak model değerlendirilmesi yapılmıştır. Makine öğrenmesi modeli, bina kat plan görüntüsü ve sayısal tasarım parametrelerini girdi olarak hesaplama süreleri daha kısaltmış ve %1,80 hata oranı ile başarılı bir performans göstermiştir.

Zhang ve diğ. (2022) tarafından yapılan çalışmada, mekanların insanlar üzerindeki etkisini makine öğrenmesi ile ölçümleyebilmek adına bir model geliştirilmiştir. Mekan tasarımı için Revit yazılımı kullanılmıştır. Arttırılmış gerçeklik deneyimi sunulan 144 katılımcının mekanları değerlendirdikleri 120 yanıtlik anket verilerinin 100'ü model eğitimi, 20'si model değerlendirmesi için ayrılarak veriler işlenmiştir. Minitab yazılımı ile istatistiksel hesaplamalar yapılmıştır. MATLAB programlama dilinde Artificial Neural Network, Linear Regression, Radial Basis Function Neural Network (RBFNN), General Regression Neural Network (GRNN), Support Vector Regression ve Fuzzy İnference Systems (FIS) makine öğrenmesi algoritması kullanılarak model geliştirilmiştir. %83,21 doğruluk oranına sahip GRNN ile oluşturulan makine öğrenmesi modelinin diğer dört makine öğrenmesi modellerine göre tasarım özellikleri ve insan duygusal deneyimi arasındaki ilişkiyi daha iyi açıkladığı görülmüştür. 2.sırada %83,14 doğruluk oranı ile RBFNN modeli yer almakta ve GRNN modeline çok yakın sonuçlar elde ederek başarılı tahminlerde bulunmuştur.

Qian ve diğ. (2022) ise çalışmalarında, erken tasarım aşamasında mimari eskizler yapabilen makine öğrenmesi modeli önermiştir. PyTorch kütüphanesi kullanılarak Generative Adversarial Network ve Self-Adaptive Sparse Trans Form Module (SASTM) algoritmalarından oluşan makine öğrenmesi modeli geliştirilmiştir. Önerilen modelde temel amaç eğitim veri setinden farklı yeni mimari eskizler oluşturabilmektir. 823 görüntüden oluşan bir mimari görüntü veri seti ve 6584 adet eskiz görüntüsünden oluşan bir veri seti hazırlanmıştır. GAN ve SASTM algoritmaların model değerlendirmesine bakıldığında, modellerin eğitim setinden farklı eskizler üretebildiği görülmüştür. Üretilen eskizlerin ise eğitim setinde olmayan ama mevcutta uygulanmış gerçek binaların

görüntülerine benzer şekilde eskizler olması sebebi ile modellerin erken tasarım aşamasında mimarlara form bulma konusunda yardımcı olabileceği düşünülmektedir.

Alaçam ve diğ. (2022), tarihi bir haritadan uydu görüntüsüne stil ve bilgi aktarımı yapabilecek bir makine öğrenmesi modeli geliştirmiştir. 243 İstanbul Pervititch haritalarından 67 düzenlenmiş görüntü ve uydu görüntüleri veri setine eklenmiştir. Pervititch haritalarının farklı ölçeklerde olması uydu görüntüleri ile eşleştirildiğinde düzenli bir ızgara oluşturmamasına sebep olacağından aynı ölçekte olmalarına dikkat edilmiştir. Model eğitimi için Google Colab platformu ve PyTorch kütüphanesi kullanılmıştır. CycleGAN ve Pix2Pix algoritmaları kullanarak model oluşturulmuştur. Önerilen modelin inşaat teknikleri/malzemeleri, yeşil alanlar, etiketler ve stil aktarımının başarılı şekilde yapabildiği görülmüştür. Veri setinin ölçek, renk tonları ve çizim stili gibi özelliklerinin hata olasılığını etkilediği parametreler olduğu görülmüştür.

Dong ve Lin'nin (2022) çalışmasında, kentsel tasarımın makine öğrenmesi algoritması ile oluşturulması üzerine bir model geliştirilmiştir. Kentsel morfolojiyi temsil eden 136 Avrupa şehri örneği veri seti olarak seçilmiştir. 25 görüntü test verisi olarak kullanılmıştır. Harita bilgilerinin işlenmesi için QGIS yazılımı, model eğitimi için PYTHON programlama dili kullanılmıştır. Generative Adversarial Network ve Image-to-Image Translation algoritmalarından oluşan model geliştirilmiştir. Eğitilen modelin değerlendirme sonucunda, giriş görüntüsü üzerinde yol, yeşil alan, su sistemleri, binalar gibi temel kentsel özelliklerin işlenmesi ile yeni kentsel formlar üretebildiği görülmüştür.

Mousavi ve diğ. (2022) tarafından yapılan çalışmada, BIM ve makine öğrenmesi algoritmaları kullanılarak hasar gören binaların hasar durumlarının tespiti için bir model önerilmiştir. 152 farklı konut binasından 75 binanın görüntülerinden 509 duvarın sismik stabilite özellikleri ve hasar durumları çıkarılmıştır. Binalara ait fotoğraflar hasarsız, çatlak ve çarpık olmak üzere 3 kategoride sınıflandırılmıştır. Konut binalarından oluşan verilerin hasar tahmini için PYTHON programlama dilinde Scikit-Learn kütüphanesi kullanılarak Artificial Neural Network, Support Vector Machine, Decision Trees, Random Forest, Extremely Randomized Trees (ERT) ve Multi Layer Perceptron algoritmaları ile model geliştirilmiştir. Daha sonra BIM aracı ile bir bina modellenmiş ve C# programlama dili kullanılarak modeldeki binada oluşabilecek hasarların tespiti için

bir model geliştirilmiştir. Hazırlanan veri seti ile eğitilen ERT makine öğrenmesi modeli %86 genel doğruluk oranı ile başarılı tahminlerde bulunmuştur.

Sun ve diğ. (2022), bina cephelerinden binaların mimari tarzını ve çağını algılayabilecek bir derin öğrenme modeli önermiştir. Toplamda 39.211 örnek içeren veri setindeki veriler %80'i modelleme eğitimi için, %20'si model değerlendirmesi için kullanılmak üzere ayrılmıştır. Bina cephelerinin fotoğrafları 9 farklı mimari stil ve çağına göre sınıflandırılmıştır. ImageNet kütüphanesinden önceden eğitilmiş bir model üzerinden görüntülerden bilgi çıkarımı yapılmıştır. PYTHON programlama dilinde PyTorch kütüphanesi kullanılarak Deep Convolutional Neural Network ve DenseNet121 algoritmaları ile derin öğrenme modeli geliştirilmiştir. Geliştirilen modelin, binaların çağlarına ve yaşlarına göre sınıflandırılma doğrulanmasında %81,09 doğruluk oranına sahip olması, modelin başarılı performans gösterdiği sonucu çıkarılmaktadır.

Payet ve diğ. (2022) tarafından yapılan çalışmada, bir binanın çevresel değişkenlere ilişkin değerlerinin insanlar üzerindeki etkisini makine öğrenmesi modeli ile incelemiştir. Tropikal iklimde yer alan karma modlu binada yaşayan insanların, pencere açma, vantilatör kullanımı gibi kullanıcı eylem verileri ve iç mekan hava sıcaklığı ile iç mekan bağıl nem gibi binanın çevresel verileri bir yıl boyunca toplanarak veri seti oluşturulmuştur. PYTHON programlama dilinde Scikit-Learn kütüphanesi kullanılarak K-Means, Random Forest, Decision Trees, Bayesian Networks ve algoritmaları ile model geliştirilmiştir. Modelde kullanılan veri setindeki verilerin %55'i modelin eğitimi, %45'i modelin test aşaması için ayrılmıştır. Hava sıcaklıklarına bağlı olarak pencere açma ve vantilatör kullanım düzeyini tahmin etmede RF modeli diğer modellere göre en yüksek doğruluk oranı elde etmiştir. Elde edilen sonuçlara göre, karma modlu binalarda bina sakinlerinin davranışlarını makine öğrenmesi ile tahmin edilebileceği görülmüştür.

Yoon ve diğ. (2022) ise çalışmalarında, insan davranışının binanın çevresel verileri ve enerji tüketimi tahmin modeli üzerinden değerlendirilmesi amaçlanmıştır. 9 gün boyunca belirli bir mekanda insan davranışları kayıt altına alınmıştır. Kayıt altına alınan davranışlar uyku, dinlenme, çalışma, yemek yapma, yemek yemek, egzersiz ve dışarda şeklinde 7 kategoride sınıflandırılmıştır. İnsan davranışlarının, 5 çevresel değişken ve 4 enerji tüketim değişkenler üzerinden doğru tahmin edilebilmesi adına PYTHON programlama dilinde Scikit-Learn kütüphanesi kullanılarak Random Forest, K-Nearest

Neighbor, Support Vector Machine algoritmaları ile makine öğrenmesi modeli geliştirilmiştir. Bina sakinlerinin faaliyetlerinden etkilenen çevresel değişkenler ve enerji tüketim değişkenlerinin tahmin edilmesinde ortalama 0,94 F1 puan olarak model doğrulanmıştır.

Zhang ve diğ. (2022), stadyum tasarımında termal konforun artırılmasına yönelik bir model önermiştir. Stadyumun şekli ve termal performansı arasındaki ilişkinin makine öğrenmesi algoritması ile tahmin edilmesi ve termal konfor performansını optimizasyon algoritmaları ile iyileştirmek hedeflenmiştir. Bu kapsamda Rhino-Grasshopper yazılımı ile 3D modeller yapılmış, EnergyPlus ve OpenFOAM yazılımları ile simülasyonlar alınmıştır. Simülasyonda 770 farklı veri seti kaydedilmiş olup, veri setinin %70'i modelin eğitimi için, %15'i doğrulama için, %15'i ise modelin test edilmesi için ayrılmıştır. Makine öğrenmesi modeli eğitmek için MATLAB programlama dili kullanılmıştır. Artificial Neural Network, Levenberg–Marquardt ve Optimizasyon Algorithms kullanılarak model oluşturulmuştur. Simülasyonlar gerçek ölçümlerle yakın sonuçlar vermiş olup kullanılan makine öğrenmesi modellerinin performansı doğrulanmıştır. Ayrıca optimizasyon yapılan stadyum tasarımı termal konfor performansında %8,96 oranında iyileşme göstermiştir. Sonuç olarak yarı açık stadyumlarda seyircilerin termal konforunu arttırmak için makine öğrenmesi tekniklerinin kullanılabileceği görülmüştür.

Algamdey ve diğ. (2022) tarafından yapılan çalışmada, kentsel özelliklerin makine öğrenmesi algoritmaları ile kümelenmesi ve analiz edilmesi amaçlanmaktadır. Bu amaçla toplanan kentsel veriler ilgi çekici noktalar, yaya ağı ve adresli konumlar şeklinde üç temel özelliğe daraltılmıştır. PYTHON programlama dilinde NetworkX, OSMX, Pandana ve GeoPandas kütüphaneleri kullanılarak K-Means Cluster algoritması ile model geliştirilmiştir. Farklı kentsel koşullara sahip beş şehir üzerinden geliştirilen modelin performansı test edilmiştir. Test sonuçlarına göre modelin beş farklı kenti karşılaştırabildiği ve kentlere ait özellikleri kümeleyebildiği görülmüştür.

Kristiansen ve diğ. (2022), konut binalarının yıllık aydınlatma ve çalışma sıcaklığının makine öğrenmesi modeli ile tahmin edilmesini amaçlamıştır. Rhino-Grasshopper yazılımında konut modellemesi yapılmıştır. Enerji simülasyonları için EnergyPlus yazılımı, aydınlatma ölçümleri için Radiance yazılımı kullanılmıştır. Simülasyondan elde edilen verilerin %70'i modelin eğitimi için, %15'i doğrulama için, %15'i ise modelin test

edilmesi için ayrılmıştır. Makine öğrenmesi modeli için PYTHON programlama dili kullanılarak PyTorch kütüphanesinden yararlanılmıştır. Artificial Neural Network ve ReLu aktivasyon fonksiyonu makine öğrenmesi algoritmaları modelde kullanılmıştır. Modelin sonuçlarında geleneksel yöntemlere kıyasla simülasyon süresi %96 azalma göstererek daha hızlı sonuçlar edilmiştir. Yıllık çalışma sıcaklık ve gün ışığı aydınlatma değerlerinin makine öğrenmesi ile tahmin sonuçlarına bakıldığında makine öğrenmesinin bina performans simülasyonlarında kullanılabileceği görülmüştür.

Sun ve diğ. (2022) tarafından yapılan çalışmada, tarihi binaların cephe görüntülerinden mimari tarzlarının tanımlanmasını sağlayan bir model önerilmiştir. Tarihi bir cadde üzerinde farklı mimari tarzlara sahip binalardan oluşan 115 fotoğraflık bir veri kümesi oluşturulmuştur. Daha sonra her görüntü üzerinde 13 farklı kategoriden oluşan cephe elemanlarına göre etiketleme işlemi yapılmıştır. 115 görüntünün 92 tanesi model eğitimi için, 23 tanesi modelin test edilmesi için ayrılmıştır. Veri setindeki görseller çevrilmesi ve döndürülmesi gibi veri arttırma işlemi ile 460 görüntü elde edilmiş olup, bu verilerin 368'i eğitim için, 92'si test için ayrılmıştır. CycleGAN algoritması kullanılarak PyTorch kütüphanesinde makine öğrenmesi modeli geliştirilmiştir. Orijinal görüntüler ve arttırılmış veriler üzerinden eğitilen modelin niceliksel karşılaştırmasında arttırılmış veri seti ile geliştirilen modelin eğitim sürecinin istikrarını arttırabileceği gözlemlenmiştir. Görsel analiz yoluyla yapılan niteliksel değerlendirmede, arttırılmış veri kümesi ile eğitilmiş modelin, etiketlenmiş veri kümesindeki benzer özelliklere sahip yeni cephelerde cephe özelliklerini tanıyabildiği gözlemlenmiştir.

Kim ve diğ. (2022) ise araştırmalarında, konut binalarında iç mekan ile dış mekan arasındaki etkileşimi yaratan pencere tasarımları ve manzaralarının insanlar üzerindeki etkisini ölçümleyebilmek adına makine öğrenmesi kullanarak bir model önermiştir. Mekanların 3D tasarımları Rhino-Grasshopper yazılımı ile yapılmıştır. Mekanlar için tasarlanan pencerelerin görünüm özelliklerini çıkarmaya yarayan ve C# programlama dili kullanılarak yazılan bir hesaplama modeli geliştirilmiştir. 181 katılımcının pencere tasarımlarını değerlendirdikleri anket sonuçlarında 4659 yanıt veri olarak kaydedilmiş olup, bu verilerin 590 pencere görünümüne sahip mekanların 3D verilerinin karşılaştırılması için ML.NET kütüphanesi kullanılarak Random Forest ve Fast Tree Regression algoritmalarından oluşan makine öğrenmesi modeli geliştirilmiştir. Tahmin

modeli bir başka manzara değerlendirme modeli ile karşılaştırılarak değerlendirilmesi yapılmıştır. Geliştirilen modelin diğer model ile karşılaştırıldığında anket yanıtlarına göre tahmin doğruluğu daha yüksek olduğu görülmüştür. Bina yönelimi, plan yerleşimi veya cephe tasarımı gibi manzara parametrelerini etkileyen unsurlarla birlikte pencere görünümünün insanlar üzerindeki etkisi geliştirilen model sonuçlarına göre erken tasarım aşamasında dikkate alınmasını göstermektedir.

Gan (2022), modüler bina tasarımı için BIM tabanlı modelleme aracının makine öğrenmesi ile entegre çalıştığı bir model geliştirmiştir. BIM tabanlı modellemeler Revit ve Dynamo yazılımında, model eğitimi ise PYTHON programlama dili ile gerçekleştirilip Generative Adversarial Network ve Convolutional Neural Network algoritmaları kullanılarak model oluşturulmuştur. Bina tasarımı için gerekli olan hacimsel modüllerin mekânsal nitelikleri ve topolojik ilişkilerini anlayarak BIM verilerini okuyabilen, dönüştürebilen ve üretken tasarımlar yapabilen bir derin öğrenme modeli geliştirilmiştir.

Karadağ ve diğ. (2022) tarafından yapılan çalışmada, eğitim binası tasarımında makine öğrenmesi yöntemleri kullanarak yeni sınıf düzenleri oluşturabilen bir model önerilmektedir. Veri seti, tipik okul veri tabanından elde edilen 144 sınıf düzeni içeren on tipik okul projesini içermektedir. Eğitim binası verilerinin kaynak ve hedef görüntü gösterimleri Autocad yazılımı ile yapılmış olup, sınıf bileşenlerine renk kodları atanmıştır. Keras kütüphanesi kullanılarak TensorFlow platformunda Pix2Pix ve Generative Adversarial Network algoritmaları ile model eğitilmiştir. Model iki aşamadan oluşmaktadır. İlk adımda sınıfın sınırları kullanılarak sınıf çözümlemeleri yapılmış olup elde edilen sonuçla birlikte ikinci adımda tefrişlerin detaylı olarak işlenerek sınıf planları oluşturulmuştur. Model değerlendirilme sonuçlarına göre her iki adım doğrulamasında başarılı sonuçlar vermiştir. Doğrulama setinden elde edilen verilerle modelin başka sınıf modellerinde uygulanma potansiyeli olduğu görülmüştür.

Güzelci (2022), kültürel miras yapısı kümbetlerin başlık geometrilerini tahmin eden makine öğrenmesi algoritması geliştirmiştir. Bu çalışmada 60 yapı için 91 farklı kesit çizimi veri seti olarak toplanmıştır. Kümbetlerin kesit görüntüleri aynı detay seviyede olacak şekilde Autocad yazılımı ile bilgisayar ortamına aktarılmıştır. 91 iç mekan ve 91 dış kabuk şeklinde veri setindeki kesitlerin konturları çizilmiştir. Model eğitimi için 81 çizim, model değerlendirilmesi için 10 çizim ayrılmıştır. TensorFlow platformunda Keras

kütüphanesi kullanılarak Pix2Pix algoritmaları ile model oluşturulmuştur. Veri kümesi sınırlamalar dolayısı ile az sayıda olmasına rağmen, doğrulama aşamasından elde edilen sonuçlara göre eğitim ve test süreçlerinde iki aşamalı doğrulama gerçekleştirerek başarılı tahminler gerçekleştirmiştir.

Liu ve diğ. (2023) ise, erken tasarım aşamasında kampüslerin mekan düzenlemesini oluşturmak için makine öğrenmesi modeli geliştirmiştir. PYTHON programlama dili kullanılarak House-GAN++, Pix2Pix ve Convolutional Message Passing Networks (Conv-MPN) algoritmaları ile iki model oluşturulmuştur. İlk modelde kampüs tasarımı için gerekli olan alan konturunun çizilmesi ve mekan düzenlemesinin kavramsal diyagramlarla oluşturulmasıdır. İkinci modelde ise birinci modelin çıktıları girdi olarak alınarak, kampüs bina düzeninin çıkarılması yapılmaktadır. Model eğitimi için 230 kampüs örneği seçilmiş olup 30'u modelin değerlendirilmesi için kullanılmıştır. Ana giriş düzeni, yol güzergahları, işlevsel bölgeleme, bina düzeni ve kamusal alanlar olmak üzere beş açıdan veri etiketleme işlemi yapılmıştır. Değerlendirme sonucunda her kriter ayrı ayrı incelenmiştir. Elde edilen sonuçlara göre geliştirilen model ile yeni kampüs düzenleri oluşturabilmektedir fakat modelin başarılı olduğu noktalar olmasına rağmen yeterli performansı gösteremediği noktalar da olmuştur. Çalışmada başarılı ve başarısız olunan noktalar tartışılmıştır.

Akdoğan ve diğ. (2023) tarafından yapılan çalışmada, mekanların termal konforu ve hava kalitesinin insanlar üzerindeki etkisinin makine öğrenmesi algoritmaları ile tespit edilmesi amaçlanmaktadır. Çalışma için bir ofis binasında çalışan yirmi dört kişilik bir grubun bir yıllık iç-dış termal ölçümü ve ilişkilerini daha önceden kaydettiği veriler kullanılarak veri seti oluşturulmuştur. PYTHON programlama dilinde Google Colab platformunda Pandas, Matplotlib, Seaborn, NumPy, Scipy ve Sklearn kütüphanelerinden yararlanılarak Gaussian Naïve Bayes algoritmasından oluşan makine öğrenmesi modeli oluşturulmuştur. Modelin tahminlerinin doğruluğu kontrol edildiğinde %80 doğruluk oranına sahip olduğu görülmüştür.

Aalaei ve diğ. (2023), erken tasarım aşamasında mekanların birbirleri ile olan ilişkisinin grafiklerle ifade edilmesi derin öğrenme modeli ile gerçekleştirmiştir. Rhino-Grasshopper yazılımı ile mekanların sınırları oluşturulmuş ve mekenların kavramsal diyagramları oluşturulmuştur. Veri setleri için RPLAN kütüphanesinden 80 bin mimari

kat planını içeren veri seti kullanılmıştır. Veri setinde 11 farklı mekan tipi belirlenmiş olup bazı oda tipleri benzer yapıda olduğu için birleştirilmiş tek tip olarak sınıflandırılmıştır. PYTHON programlama dilinde PyTorch kütüphanesinden yararlanılarak Generative Adversarial Network, Convolutional Neural Network, Support Vector Classifier (SVC), PCA ve Douglas Peucker algoritmaları kullanılarak derin öğrenme modeli geliştirilmiştir. Modelin kullanıcı etkileşimli, esnek yapılı, uygulanabilir ve orantılı kat planları ürettiği görülmüştür. Üretilen kat planlarının Archicad yazılımı kullanılarak 3D görselleştirilmesinin yapılması ile derin öğrenmenin BIM ortamı ile etkileşimli olabileceği sonucu çıkarılmıştır.

Shafavi ve diğ. (2023) ise araştırmalarında, iklimsel ve çevresel faktörlerin bina cephe tasarımında en iyi performansı veren bir makine öğrenmesi algoritması önermiştir. İklimlerin bina tasarımındaki etkisini araştırmak adına altı farklı iklim tipine sahip şehirler seçilmiştir. Pencere-duvar oranı, genişlik-derinlik oranı, pencere yönü ve çıktı derinliği gibi dört ana tasarım parametreleri dikkate alınarak çeşitli mekan tasarımları geliştirilmiştir. Mekanlar Rhino-Grasshopper yazılımında modellenmiştir. Enerji simülasyonları için ClimateStudio yazılımı kullanılmıştır. 2000 tasarım alternatifi ve 6 iklim tipi ile veri seti oluşturulmuştur. Toplamda 12.000 veriye sahip veri setinin %85'i eğitim için, %15'i modelin değerlendirilmesi için ayrılmıştır. PYTHON programlama dilinde Scikit-Learn ve CatBoost kütüphaneleri kullanılarak CatBoost Regressor algoritması, NSGA-III optimizasyon algoritması ve SHAP ile model geliştirilmiştir. Geliştirilen model ile farklı iklim, yön, mekan oranları için gün ışığının mekanla ilişkisini maksimize etmek ve enerji talebini azaltmak üzere pencere duvar oranını ve çıktı derinliklerini optimize etmeyi hedeflemektedir. Oluşturulan modelin sonuçlarında başarılı tahmin değerleri elde edilmiştir. Sonuçlara göre simülasyon verileri ile beslenen modelin erken tasarım aşamasında gün ışığı analizi yapılabilmesi için tahmin modeli olarak kullanılabileceği görülmüştür.

Venkatraj ve diğ. (2023) tarafından yapılan çalışmada, bina yaşam döngüsünde enerji verimliliğinin değerlendirilmesine yönelik bir makine öğrenmesi modeli geliştirilmiştir. Parametrik mekan tasarımı için Rhino-Grasshopper yazılımı seçilmiştir. Enerji simülasyonları için EnergyPlus yazılımı kullanılmıştır. Makine öğrenmesi modeli için TensorFlow platformunda Keras, Scikit-Learn ve Pandas kütüphanelerinden

yararlanılarak Artificial Neural Network ve ReLu aktivasyon fonksiyonu kullanılmıştır. 6000 örnekten oluşan veri setinin %70'i eğitim, %15'i doğrulama, %15'i ise test için ayrılmıştır. Modelin sonuçlarına bakıldığında gerçek enerji yoğunluğu ile model çıktısı değerlerinin arasında çok az bir fark olması ve R^2 değerinin 1'e yakın olması ile model başarılı bir performans göstermiştir. Böylece makine öğrenmesinin bina yaşam döngüsü enerji değerlendirilmesinde kullanılabileceği görülmüştür.

Gong ve diğ. (2023) tarafından yapılan çalışmada, mahalle ölçeğinde mekanların dış ortamlarının termal konforunun makine öğrenmesi ile modellenmesi amaçlanmaktadır. Parametrik kent modeli için Rhino-Grasshopper yazılımı kullanılmıştır. Ladybug yazılımı ile rüzgar, ışık, ısı ve diğer iklim parametreleri dikkate alınarak enerji simülasyonları alınmıştır. Toplamda 36.000 görüntü veri örneğinden oluşan bir veri seti hazırlanmıştır. Veri setinin %70'i eğitim, %15'i doğrulama, %15'i ise test için ayrılmıştır. TensorFlow platformunda Pix2Pix, CycleGAN ve Generative Adversarial Network algoritmaları işlenerek makine öğrenmesi modeli oluşturulmuştur. Modellerin performansları karşılaştırıldığında Pix2Pix algoritmasının diğerlerine göre daha iyi performans gösterdiği, tarihi kent adalarının mimari formları ve evrensel termal iklim indeksi ile ilişkisini yüksek düzeyde kavrayabildiği görülmüştür.

Abdulfattah ve diğ. (2023) araştırmalarında, BIM ve makine öğrenmesinin entegre çalıştığı projelerdeki tasarım değişikliklerinin proje maliyeti ve programı üzerindeki etkisini tahmin edebilen bir model önermiştir. BIM aracı olarak Revit yazılımı ile mimari ve yapısal bileşenlere sahip basitleştirilmiş bir model oluşturulmuştur. Bu modelin özelliklerinde değişiklikler yapılarak 547 farklı model Dynamo yazılımı kullanılarak elde edilmiştir. Oluşturulan model verilerinin %80'i eğitim için, %20'si test için ayrılmıştır. Daha sonra eğitim için ayrılan veriler arasından %20'si modelin doğrulanması için kullanılmıştır. Jupyter Notebook platformunda Pandas, Scikit-Learn, Matplotlib kütüphanelerinden yararlanılmıştır. PYTHON programlama dilinde Multi Layer Perceptron, Multiple Linear Regression ve Artificial Neural Network makine öğrenmesi algoritmaları kullanılarak önceden çözülmüş çakışmalardan oluşan veri kümesi ile modeller eğitilmiştir. Tasarım değişikliklerinin proje maliyeti üzerindeki etkisinin tahmininde MLP modeli MLR modeline göre daha iyi tahmin gerçekleştirmiştir. Tasarım değişikliklerinin programlar üzerindeki etkisinin tahmininde MLR modeli MLP modeline

göre daha iyi performans göstermiştir. Elde edilen tahmin oranlarına göre BIM tabanlı projelerdeki yapılan değişikliklerin proje maaliyeti ve programlar üzerindeki etkileri makine öğrenmesi ile tahmin edilebileceği sonucu çıkarılmıştır.

Li ve diğ. (2023) ise çalışmalarında, değişen iklim koşullarını dikkate alarak optimize edilmiş bina tasarımları yapmayı hedefleyen bir model önermiştir. Belirli bir bölgeye ait konut binalarının 2020, 2050 ve 2020-2050 yıllarının iklim koşullarının verileri ile veri seti oluşturulmuştur. Her kümede bulunan verilerin %80'i eğitim için, %20'si test için ayrılmıştır. Parametrik bina tasarımı için Rhino-Grasshopper yazılımı, enerji performans analizleri için EnergyPlus yazılımı seçilmiştir. PYTHON programlama dilinde Matplotlib kütüphanesinden yararlanılarak AdaBoost Regressor (ABR), Extra Tree Regressor, Extreme Gradient Boosting (XGB), Particle Swarm Optimization ve NSGA-II algoritmaları kullanılarak model geliştirilmiştir. Modellerin soğutma talebini, ısıtma talebini ve enerji maliyetini tahmin etmedeki performansları karşılaştırılmıştır. Genel olarak ERT modelinin eğitim aşamasında diğer modellere göre daha iyi performans gösterdiği, test aşamasında ise ETR ve XGB'nin en iyi iki model olduğu belirlenmiştir. Optimum çözümler analiz edildiğinde enerji ve maliyet verimli bina tasarımında, dış duvar, çatı, yalıtım kalınlıkları gibi tasarım parametrelerinin önemli olduğu görülmüştür.

Quevedo ve diğ. (2023) tarafından yapılan çalışmada, bina enerji simülasyonları ve makine öğrenmesinin entegre çalışarak binaların enerji performansının karşılaştırılması hedeflenmektedir. Veri seti için 23.256 örnekten oluşan hazır Enerji performansı analizi için EnergyPlus yazılımı kullanılmıştır. Ayrıca EnergyPlus ile entegre çalışabilen Eppy kütüphanesi ve Pandas kütüphanesi kullanılarak PYTHON programlama dilinde Multiple Linear Regression, Artificial Neural Network ve Support Vector Machine algoritmaları ile modeller oluşturulmuştur. Modellerin değerlendirilmesi yapıldığında en yüksek tahmin doğruluğu sırasıyla SVM, ANN, Linear Regression şeklindedir. Elde edilen sonuçlara göre modeller başarılı olmuştur fakat gerçek bina üzerinde de test ederek modellerin doğruluğu değerlendirilmiştir. SVM modelinin enerji tahminin gerçek ve öngörülen enerji tüketim değerleri arasındaki %1'lik fark ile en yüksek performansı göstermiştir. Önerilen makine öğrenmesi modelleri ile binaların enerji tüketimini tahmin etmede kullanılabileceği doğrulanmıştır.

Han ve diğ. (2023) ise, bina performans optimizasyonu sağlayarak binaların sürdürülebilir tasarımına katkı sağlamayı hedeflemiştir. Bina alan bilgisi ve bina performans bilgileri olmak üzere 2 tür bilgidен oluşan bir veri tabanı oluşturulmuştur. Parametrik bina tasarımı için Rhino-Grasshopper yazılımı kullanarak 10.000 bina modeli oluşturulmuştur ve oluşturulan binaların enerji performans analizi için EnergyPlus ve Radiance yazılımları kullanılmıştır. PYTHON programlama dilinde Sklearn kütüphanesinden yararlanılarak Analytic Hierarchy Process Method (AHP), Artificial Neural Network, Sensitivity Analysis-Based Decision Making (SADM) ve Optimization Algorithms kullanılarak model geliştirilmiştir. Önerilen makine öğrenmesi modeli, gerçek bina üzerinde test edilerek enerji tüketimi tahmininde R^2 değerinin 0,945 doğruluk oranına sahip olması ile başarılı tahminde bulunmuştur. Ayrıca bina performansını doğrudan etkileyen 16 yapı bileşeninde yapılan değişikliklerle bina performansının analizi yapılmış ve sonucu en çok etkileyen değişkenin pencerelerin U değerinin düşürülmesi olmuştur. Böylece geliştirilen modellerin bina enerji tüketimi tahmininde ve bina değişkenlerinin analizi yapılarak bina enerji performansını optimize etmede kullanılabilir olduğu görülmüştür.

Li ve Zheng'in (2023) çalışmasında, kentin morfolojik yapısında önemli etken olan arazi yüzey sıcaklığını tahmin edebilen bir model geliştirilmiştir. Yapılı çevrenin bilgilerinin renkler kullanarak haritada işlenmesi ve 8 kategoride sınıflandırma işlemi ArcGIS yazılımı ile yapılmıştır. PIL, Numpy ve Matplotlib kütüphanelerinden yararlanılarak PYTHON programlama dilinde Generative Adversarial Network ve Pix2Pix algoritmaları kullanılarak makine öğrenmesi modeli geliştirilmiştir. Modelde kullanılmak üzere 566 görüntü çiftinin %80'i eğitim için, %20'si test için ayrılarak veri setleri hazırlanmıştır. Modelin uygulamasını test etmek amacı ile plan değişikliklerinin arazi yüzeyi sıcaklığı üzerindeki çevresel etkilerini tahmin etmek için farklı senaryolar geliştirilmiş ve en iyi tahmin performansı gösterecek durumlar değerlendirilmiştir.

Urbietta ve diğ. (2023) tarafından yapılan çalışmada, makine öğrenmesi algoritmaları kullanılarak BIM modelleri oluşturmak hedeflenmiştir. Burada temel amaç, üç etiketle yapısal elemanları ve mimari elemanları tahmin etmek, her kat için bir etiket kullanarak kesit görüntüsünden kat yüksekliğini tahmin edilmesidir. BIM tabanlı modeller Labelme yazılımı kullanılarak her bir yapı elemanının etiketleme işlemi yapılmıştır. Daha sonra

elde edilen görüntülerden oluşan veri setinin %75'i eğitim için ayrılarak toplamda 69 görüntü modelin eğitilmesinde kullanılmıştır. Veri setinin %25'i test için ayrılarak toplamda 22 görüntü modelin değerlendirilmesinde kullanılmıştır. PYTHON programlama dilinde TensorFlow platformunda Keras ve Imgaug kütüphanelerinden yararlanılarak Mask R-CNN, Feature Pyramid Network (FPN) ve ResNet algoritmaları ile model eğitilmiştir. Daha sonra eğitilen model ile birlikte planlardan BIM modelleri üretebilmek adına Google Colab platformunda PYTHON programlama dilinde IfcOpenShell kütüphanesi kullanılarak model geliştirilmiştir. Model sonucunda ise yapısal ve mimari elemanların birbirleri ile ilişkisi doğru kurularak BIM modeli elde edilmiştir.

Long (2023), erken tasarım aşamasında enerji verimli bir bina kabuğu tasarımı için bir model önermektedir. Bina modellemeleri ve enerji simülasyon analizleri için DesignBuilder yazılımı kullanılmıştır. Simülasyondan elde edilen 2013 örnek verilerin %70'i eğitim için, %30'u test için bölünmüştür. PYTHON programlama dilinde Deap kütüphanesinden yararlanılarak Genetic Algorithm ile optimize edilmiş parametrelerle, Gradient Boosting (GB), Random Forest, Artificial Neural Network, Deep Neural Network, Support Vector Machine, Generalized Linear Model (GENLINE) kullanılarak 6 farklı enerji tahmini yapan makine öğrenmesi modelleri geliştirilmiştir. 6 farklı makine öğrenmesi modellerinde en yüksek doğruluk oranına sahip GB modeli olmuştur. Hesaplama verimliliğinde GENLINE modeli düşük hesaplama süresi ile doğruluk oranı yüksek model olmuştur. Sağlamlık açısından GB modeli yüksek sağlamlık göstermiştir. Yorumlanabilirlik açısından SVM ve GENLINE modelleri basit algoritmaları ve şeffaf karar vermeleri sebebi ile daha iyi yorumlanmaktadır. Yürütme süresinde en kısa süreyle duyarlı uygulamalar gösteren RF modeli olmuştur. Genel olarak binanın ön enerji tüketimi tahmini için GB modeli daha iyi performans sergilemiştir. Daha sonra optimizasyon sorunlarını çözerek bina enerjisinin maliyet ile enerji hedefleriyle optimize etmek için NSGAI, Differential Evolution Strategy (DES), Multi-Objective Particle Swarm Optimization (MOPSO) algoritmaları kullanılmıştır. Böylece tasarım değişkenlerinin bina enerjisi tahminindeki önemi tespit edilerek, yapılan optimizasyon ile enerji ve maliyette eşzamanlı tasarruf olduğu görülmüştür.

Fathy ve diğ. (2023) tarafından yapılan çalışmada, gün ışığının mekanlarla olan ilişkisi ve kullanıcı üzerindeki etkisinin sanal gerçeklik ve makine öğrenmesinin birlikte çalıştığı model üzerinden araştırılmıştır. Parametrik modelleme için Rhino-Grasshopper yazılımı kullanılmış olup 4 sahne hazırlanmış ve üç görüntü model eğitimi, 1 görüntü modelin değerlendirilmesi için ayrılmıştır. Simülasyonlar için Radiance yazılımı kullanılmıştır. 41 katılımcının gün ışığı ile aydınlanan mekanlardaki kafa hareketlerini yakalamak için Unity yazılımı ile artırılmış gerçeklik uygulaması yapılmıştır. MATLAB programlama dilinde Bagged Trees algoritması kullanarak makine öğrenmesi modeli oluşturulmuştur. Model değerlendirilmesi sonucunda modelin %85 tahmin doğruluğu göstermiştir.

Mehrotra ve Yi'nin (2023) araştırmasında, yapı formlarının enerji ve gün ışığı performansı üzerindeki etkisinin makine öğrenmesi algoritmaları ile değerlendirilmesi amaçlanmaktadır. Parametrik yapı formları Rhino-Grasshopper yazılımında, enerji simülasyonları Climate Studio ve EnergyPlus yazılımlarında oluşturulmuştur. Jupyter Notebook platformunda Scikit-Learn, modAL, Scriptcontext ve Rinoscriptsyntax kütüphanelerinden yararlanılarak PYTHON programlama dilinde Deep Neural Network, Support Vector Machine, Gaussian Process Regression, Random Forest, Extreme Gradient Boosting ve Decision Trees makine öğrenmesi algoritmaları ile model geliştirilmiştir. Her altı makine öğrenmesi modelinin ısıtma yükü, soğutma yükü, toplam yük, gün ışığı performansı uyarlanabilir ve uyarlanabilir olmayan örnekleme yöntemi üzerinden değerlendirilmiştir. Uyarlanabilir örneklemeyle dayalı modeller daha doğru tahmin yapmış olmasına rağmen eğitim süresi bazı modellerde daha uzun sürmüştür. Hem uyarlanabilir hem uyarlanabilir olmayan veriler her model için güçlü sağlamlık göstermiştir. Model sonucunda şekiller, pencere-duvar oranı ve komşuluk gölgelendirmesinin bina kütlelendirme çalışmalarında önemli parametreler olduğu gözlemlenmiştir.

Qian ve diğ. (2023) tarafından yapılan çalışmada, erken tasarım aşamasında yüksek bina tasarımı için yapılan eskizlerin oluşturulan derin öğrenme modeli ile yapılması amaçlanmaktadır. Model oluşturmak için ImageNet ve PyTorch kütüphanesinden yararlanılmış olup, Self-Sparse GAN, VGG19 kullanılmıştır. Veri seti için yüksek bina görüntülerinin arka planları kaldırılıp toplam 1092 adet eskiz edilmiştir. Önceden eğitilmiş Self-Sparse GAN ile eğitim veri setinden farklı olarak yeni eskizler

türetebileceği ve şekil ile dokuları öğrenebildiği görülmüştür. SASTM ile optimize edilerek modelin en iyi performansı elde edebildiği görülmüştür. Modelin çalışma başarısını değerlendirmek adına Pix2Pix algoritmaları ile kıyaslaması yapılmıştır. Pix2Pix algoritmasında elle çizilmiş çizimler giriş verisi olarak kullanıldığından sınırlı sayıda eskiz üretebilmekte ve bu yüzden önerilen modelin eskiz türetme yeteneğinin daha başarılı olduğu görülmektedir.

Uzun ve Cangür'ün (2023) çalışmasında, cumbalı cephelerin makine öğrenmesi yöntemi ile değerlendirilmesi amaçlanmaktadır. 300 cumbalı pencere görüntülerine sahip veri seti oluşturulmuştur. Görüntülerin hepsi aynı çözünürlükte yeniden boyutlandırılmıştır. PYTHON programlama dili kullanılarak LabelImg yazılımı ile veri setindeki 150 görüntü cumbalı pencere ontolojisinden 20 etiketle etiketleme işlemi yapılmıştır. Veri setinin %70'i eğitim, %30'u test verisi olarak bölünmüştür. StyleGAN, You Only Look Once (YOLO) algoritmaları kullanılarak model geliştirilmiştir. StyleGAN modelinin, cumbalı pencere görüntüler üzerinde ontolojik değerlendirme yaparak nesne tespiti yapabildiği doğrulanmıştır.

Takhmasib ve diğ. (2023) tarafından yapılan çalışmada, kinetik cephelerin iç mekan gün ışığındaki etkisinin makine öğrenmesi modeli ile değerlendirilmesi amaçlanmaktadır. Kinetik cephe modülü yapabilmek için lazerle kesilmiş malzemeler biraraya getirilmiştir. Gün ışığını ölçümleyebilmek için oluşturulan test ortamına dört adet gün ışığı sensörü koyulmuştur. İç mekan aydınlatmasını ölçmek için bir ışık sensörü yatay olarak diğer ışık sensörü parlama seviyesini değerlendirmek için dikey olarak iç mekanlara yerleştirilmiştir. Cephe modellemesi için Rhino-Grasshopper yazılımı, gün ışığı parlama hesaplamaları için ClimateStudio ve Radiance yazılımları, enerji performans analizleri için EnergyPlus yazılımı kullanılmıştır. Simülasyondan elde edilen veri setinin %75'i eğitim, %25'i test verisi olarak bölünmüştür. PYTHON programlama dilinde NumPy, SciPy, pyDOE ve Scikit-Learn kütüphaneleri kullanılmıştır. Decision Trees Regressor (DTR), Random Forest Regressor (RFR), Extreme Gradient Boosting kullanılarak makine öğrenmesi modeli önerilmiştir. Yorumlama çerçevesi olarak SHapley Additive exPlanations (SHAP) kullanılmıştır. Gradient Boosting, Histogram-Based Gradient Boosting (HGB), Artificial Neural Network ve Convolutional Neural Network algoritmaları ile karşılaştırmalı bir değerlendirme yapılmıştır. Simülasyona dayalı

doğrulamada XGB modeli en iyi performansı göstermiştir. Saha doğrulamasında ise RFR mdeli daha iyi performans göstermiştir. Tüm değerlendirmeler sonucunda makine öğrenmesi modellerinin gün ışığı simülasyonları ile sensörler kullanılarak elde edilen gerçek gün ışığı parlama olasılık değerlerinin uyumlu sonuçlar gösterdiği görülmüştür.

Yan ve diğ. (2023) tarafından yapılan çalışmada, erken tasarım aşamasında binaların karbon emisyonlarının tahmini için bir model önerilmektedir. 2000 konut ünitesi içeren bir veri seti kullanılarak, veri setinin %80'i eğitim için %20'si modelin değerlendirilmesi için ayrılmıştır. Ayrıca elektrik ve ısıtma karbon emisyon faktörlerinin verileri toplanmıştır. Parametrik bina modellemesi için Rhino-Grasshopper yazılımı kullanılmıştır. Makine öğrenmesi modeli için PyTorch kütüphanesinden yararlanılarak Convolutional Neural Network, ResNet ve ReLu algoritmaları kullanılarak 4 model oluşturulmuştur. Modellerin değerlendirme sonucunda elde edilen R^2 değerleri 0,91 ile 0,98 arasında olması modellerin doğruluğunu göstermektedir. Elde edilen sonuçların enerji simülasyonları ile karşılaştırılması için EnergyPlus yazılımı seçilmiştir. Sonuçlara göre CNN modelinin performansı EnergyPlus modelinin çıktılarıyla tutarlı olduğu görülmüştür.

Croce ve diğ. (2023), kültürel mirasın tanımlanması ve sınıflandırılması için makine öğrenmesi ile oluşturulan platform önermiştir. MATLAB programlama dilinde CamVid kütüphanesi kullanılarak Convolutional Neural Network, Random Forest, Deeplab v3+ ve ResNet-18 algoritmaları kullanılarak makine öğrenmesi temelli AİoLi platformu oluşturulmuştur. Makine öğrenmesi ile oluşturulan platformun 3D modeller ve 2D görüntüler arasında bilgi aktarımı yapabilme ve kültürel miras mimarilerin görüntülerinden bilgiler çıkarabilme yetenekleri doğrulanmıştır.

Wang ve diğ. (2023) ise çalışmalarında, mimari yerleşim planlarının derin öğrenme modeli ile oluşturulması amaçlanmaktadır. 700'den fazla bina planı toplanarak veri seti oluşturulmuş olup eğitim ve değerlendirme işlemleri için iki veri setine ayrılmıştır. Modelin eğitimi için PYTHON programlama dili ile OpenCV ve PyTorch kütüphaneleri kullanılmıştır. Structured Convolution Block (SCB), Convolutional Layer (Conv), ReLu, Batch Normalization, Sigmoid Function, IC-SA-Unet ve ResNet algoritmaları ile derin öğrenme modeli geliştirilmiştir. Geliştirilen modelin başarısını ölçümleyebilmek adına diğer U-Net algoritmaları ile karşılaştırılmıştır. Elde edilen sonuçlarda, IC-SA-UNet

algoritması ile daha kısa sürede daha iyi tanımlanmış belirgin mimari planlar üretebildiği görülmüştür. Üretilen plan düzlemi verilerinin üç boyutlu modele geçirilmesi için Rhino yazılımı kullanılmıştır. Böylece üretilen çizimlerin 3D modellemelerinin yapılması ile erken tasarım aşamasında kütle yerleşim planlaması yapılırken geliştirilen modelin yardımcı araç olarak kullanılabileceği görülmüştür.

Karadağ (2023), kültürel miras yapılarının eksik kısımlarının makine öğrenmesi modeli ile tahmin edilmesini amaçlamaktadır. Osmanlı türbelerinden oluşan 192 adet plan çizimi veri setini oluşturmak için toplanmıştır. Önerilen model için ilk olarak türbelerin orijinal çizimleri ve türbelere ait mimari bileşenlerin eksiltilmiş hallerinin olduğu iki veri seti oluşturulması gerekmektedir. Daha sonra türbelerin orijinal halleri üzerinde, türbelerin sahip olduğu farklı bileşenlerin renkleri kullanılarak etiketleme işlemi yapılmıştır. Elde edilen veri setinin %80'i modelin eğitimi, %20'si modelin test edilmesi için ayrılmıştır. PYTHON programlama dilinde Keras kütüphanesinden yararlanılarak TensorFlow platformunda Generative Adversarial Network ve Pix2Pix algoritması ile model geliştirilmiştir. Eğitim süreci sonucunda 200 döngüden sonra verimli sonuçlar alınmaya başlanılmıştır. Modelin niceliksel değerlendirilmesi yapıldığında geliştirilen modelin Osmanlı türbelerinin eksik ya da hasarlı unsurları tespit ederek başarılı şekilde tamamlaması ile kültürel mirasların restitüsyon işlemlerinde makine öğrenmesinin kullanılabileceği görülmüştür.

Alymani ve diğ. (2023) tarafından yapılan çalışmada, yapı ve zemin arasındaki ilişkinin makine öğrenmesi ile sınıflandırılması amaçlanmaktadır. Grasshopper yazılımı ve Topologic kütüphanesi kullanılarak parametrik modeller oluşturulmuştur. Oluşturulan modeller bina ve zemin ilişkisi göz önünde bulundurularak, binaların zeminden yükseltildiği 700 tane ayırma grafiği, binaların doğrudan zemine oturduğu 96 tane tutarlılık grafiği, binaların topografya ile örtüştüğü 104 tane kitleme grafiği şeklinde 3 sınıfa ayrılmıştır. Toplamda 900 grafikten oluşan veri setinin %35'i eğitim, %35'i doğrulama, %35'i test olarak ayrılmıştır. PyTorch kütüphanesinden yararlanılarak PYTHON programlama dilinde Deep Graph Convolutional Neural Network (DGCNN) ve ReLu algoritmaları ile makine öğrenmesi modeli oluşturulmuştur. Model 200 döngüden sonra en iyi sınıflandırma performansı göstermiştir. Makine öğrenmesi

modelinin doğruluk oranı %95,6 olması ile mimari kütlelerin topoloji ile ilişkisinin doğru sınıflandırıldığını göstermektedir.

Zou ve diğ. (2023) ise, kültürel miras yapılarının dış cephe özelliklerine göre makine öğrenmesi algoritmaları kullanılarak değerlendirilmesini amaçlanmaktadır. Çin Hubei bölgesinin antik mimarisine ait 96 mimari yapının 2580 görsellerinden oluşan bir veri seti oluşturulmuş olup, her bir görüntü yüksek kaide, derin saçak ve zarif üçgen çatı olmak üzere 3 kategoride sınıflandırılmıştır. Hubei bölgesel geleneksel mimari biçimleri tanımlamak için güneydoğu, kuzeydoğu, güneybatı ve kuzeybatı olmak üzere dört farklı bölgeye ait 96 mimari yapının 576 görüntüsünden oluşan ikinci veri seti oluşturulmuştur. Hubei bölgesindeki modern mimarilere ait üçüncü bir veri seti oluşturulmuştur. LabelImg yazılımı kullanılarak yapı görüntülerinin etiketlenmesi ve Faster-R-CNN, VGGNet ve Region Proposal Network (RPN) algoritmaları kullanılarak model eğitimi gerçekleştirilmiştir. Seçilen bölgede genel olarak zarif üçgen çatının daha belirgin olduğu, kuzeybatı bölgesinde derin saçak özelliğinin daha belirgin olduğu görülmüştür. Elde edilen niceliksel sonuçlara göre seçilen bölgedeki mimari miras yapılarının özelliklerinin tanımlanmasında makine öğrenmesi modeli tutarlı sonuçlar göstermiştir.

Aman ve diğ. (2023) tarafından yapılan çalışmada, kentsel alanların çevresel özelliklerinin bina performansı üzerindeki etkisini makine öğrenmesi modeli ile tahmin edilmesi amaçlanmaktadır. Seçilen çalışma bölgesinde iki blok ve çevresindeki binalar dikkate alınarak parametrik kent tasarımının BIM modellemesi Revit ve Grasshopper yazılımları kullanılarak oluşturulmuştur. ClimateStudio yazılımı ile gün ışığı simülasyonları alınmıştır. Gün ışığı özerkliği değerlerini tahmin etmek için simülasyon verileri ile PyTorch platformunda Pymoo kütüphanesi kullanılarak Graph Neural Network (GNN) algoritması ile makine öğrenmesi modeli eğitilmiştir. Multi Objective Optimization ve NSGA-II algoritmaları ile modelin optimizasyonu sağlanmıştır. Optimize edilmiş modelin tahmin sonuçları ile simülasyon sonuçlarının niceliksel değerlendirmeleri sonucunda %96,78 doğruluk oranına sahip R^2 değeri elde edilerek modelin gerçek değerlere yakın tahminler yaptığı doğrulanmıştır.

5.3. Araştırma Sorularının Cevaplandırılması


Tez çalışmasının bu bölümünde, literatür taramasının başında oluşturulan üç araştırma sorusu dikkate alınarak analiz edilen 86 çalışmadan elde edilen verilerin detayları açıklanmıştır. Okunurluğun artırılması için her bir çalışma 1'den 86'ya kadar numaralandırılmış olup, çalışma numaraları ve çalışma referanslarının eşleştirilmesi Tablo 5.1'de listelenmiştir.

Tablo 5.1. Çalışma numarası ve referans eşleştirilmesi

<u>Çalışma Numaraları</u>	<u>Kaynak Gösterimi</u>	<u>Çalışma Numaraları</u>	<u>Kaynak Gösterimi</u>
1.	Aggarwal (2007)	44.	Millán ve diğ. (2022)
2.	Peng ve Gero (2007)	45.	Singh ve diğ. (2022)
3.	Wilkinson ve diğ. (2013)	46.	Zhang ve diğ. (2022)
4.	Krijnen ve Tamke (2015)	47.	Qian ve diğ. (2022)
5.	Mao ve diğ. (2016)	48.	Alaçam ve diğ. (2022)
6.	Takizawa ve Furuta (2017)	49.	Dong ve Lin (2022)
7.	Muehlbauer ve diğ. (2017)	50.	Mousavi ve diğ. (2022)
8.	Chatzikonstantinou ve Sariyildiz (2017)	51.	Sun ve diğ. (2022)
9.	As ve diğ. (2018)	52.	Payet ve diğ. (2022)
10.	Tamke ve diğ. (2018)	53.	Yoon ve diğ. (2022)
11.	Singaravel ve diğ. (2018)	54.	Zhang ve diğ. (2022)
12.	Bloch ve Sacks (2018)	55.	Algamdey ve diğ. (2022)
13.	Huang ve Zheng. (2018)	56.	Kristiansen ve diğ. (2022)
14.	Brown ve Mueller (2019)	57.	Sun ve diğ. (2022)
15.	Feng ve diğ. (2019)	58.	Kim ve diğ. (2022)
16.	Rhee ve diğ. (2019)	59.	Gan ve diğ. (2022)
17.	Newton (2019)	60.	Karadağ ve diğ. (2022)
18.	Uzun ve Çolakoğlu (2019)	61.	Güzelci (2022)
19.	Wu ve diğ. (2019)	62.	Liu ve diğ. (2023)
20.	Yetkin ve Gönenç Sorguç (2019)	63.	Akdoğan ve diğ. (2023)
21.	Koo ve diğ. (2019)	64.	Aalaei ve diğ. (2023)
22.	Li ve diğ. (2019)	65.	Shafavi ve diğ. (2023)
23.	Alymani ve diğ. (2020)	66.	Venkatraj ve diğ. (2023)
24.	Brown ve diğ. (2020)	67.	Gong ve diğ. (2023)
25.	Płoszaj-Mazurek ve diğ. (2020)	68.	Abdulfattah ve diğ. (2023)
26.	Chan ve Spaeth (2020)	69.	Li ve diğ. (2023)
27.	Zheng ve diğ. (2020)	70.	Quevedo ve diğ. (2023)
28.	Gonzalez ve diğ. (2020)	71.	Han ve diğ. (2023)
29.	Hamid-Lakzaeian (2020)	72.	Li ve Zheng (2023)
30.	Hsu ve diğ. (2020)	73.	Urbietta ve diğ. (2023)
31.	Sebestyen ve Tyc (2020)	74.	Long (2023)
32.	He ve diğ. (2021)	75.	Fathy ve diğ. (2023)
33.	Fatehi ve diğ. (2021)	76.	Mehrotra ve Yi (2023)
34.	Dixit ve diğ. (2021)	77.	Qian ve diğ. (2023)
35.	Martínez-Rocamora ve diğ. (2021)	78.	Uzun ve Cangür (2023)
36.	Xiang ve diğ. (2021)	79.	Takhmasib ve diğ. (2023)
37.	Daemei ve diğ. (2021)	80.	Yan ve diğ. (2023)
38.	Zheng ve Yuan (2021)	81.	Croce ve diğ. (2023)
39.	Martínez-Comesaña ve diğ. (2021)	82.	Wang ve diğ. (2023)
40.	Fan ve diğ. (2021)	83.	Karadağ (2023)
41.	Wang ve diğ. (2021)	84.	Alymani ve diğ. (2023)
42.	Lin ve Tsay (2021)	85.	Zou ve diğ. (2023)
43.	He ve diğ. (2021)	86.	Aman ve diğ. (2023)

5.3.1. Makine Öğrenmesi Kullanılan Mimarlık Alanları (AS1)

Literatür taramasının başında oluşturulan “Literatürde makine öğrenimi kullanılarak mimarlığın hangi alt alanları incelendi ve bu alt alanlarda hangi sorunlar ele alındı?” (AS1) sorusuna 86 çalışmanın vermiş olduğu cevaplar başlıklarına ve konu alanlarına göre gruplandırılmıştır (Şekil 5.5).



Şekil 5.5. İncelenen 86 makaledeki mimarlığın alt alan nicelikleri

1.Araştırma sorusundan elde edilen cevaplar, CAD (Bilgisayar Destekli Tasarım), CAE (Bilgisayar Destekli Mühendislik) ve CAM (Bilgisayar Destekli Üretim) olmak üzere mimarlığın üç ana temasına göre kategorilendirilmiştir. Çalışmalarda, Cephe Tasarımı, Eskiz Çizimi, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Tarihi Binalar, BIM, Yapı Tipolojisi, Yapı ve Yakın Çevre, Dijital Üretim, Nokta Bulutları veya Nesne Tanıma, Tasarım Süreci, Tasarım ve Uygulama, Yapı Elemanları, Sürdürülebilirlik, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı, Yüksek Katlı Binalar olmak üzere mimarlığın 22 farklı alt alanında makine öğrenmesi kullanılarak problemlere çözüm aranmıştır.


Tablo 5.1’de oluşturulan 86 çalışmanın referans numaraları ile bu çalışmalarda mimarlığın hangi ana temaları ve hangi alt alanları ele alındığına dair bilgiler Tablo 5.2’de liste halinde gösterilmiştir. CAD alanında 12 farklı alt alan, CAM alanında 5 farklı alt alan, CAE alanında ise 5 farklı alt alanlardaki mimari problemlere makine öğrenmesi ile çözüm aranmıştır.

Tablo 5.2.Çalışma numaraları ve mimarlığın alt alanları ilişkisi

Ana Temalar	Alt Başlıklar	Referanslar
CAD (Computer Aided Design)	Cephe Tasarımı	[8], [29], [31], [37], [42], [51], [57], [65], [78], [79], [85]
	Eskiz Çizimi	[26], [47], [77]
	Genişletilmiş Gerçeklik	[6], [19], [46], [75]
	Hesaplamalı Tasarım	[2], [7], [8], [10], [14], [15], [20], [22], [25], [27], [31], [32], [36], [38], [42], [43], [44], [45], [50], [54], [56], [59], [64], [65], [66], [67], [68], [69], [71], [74], [75], [76], [79], [80], [84], [86]
	Kavramsal Tasarım	[6], [9], [12], [21], [24], [26], [78]
	Kentsel Tasarım	[6], [16], [34], [40], [41], [48], [49], [55], [72], [86]
	Kullanıcı Deneyimi	[6], [36], [46], [52], [53], [58], [63], [75]
	Mekan Tasarımı	[2], [9], [12], [13], [17], [18], [23], [24], [30], [38], [44], [45], [46], [52], [53], [54], [56], [58], [59], [60], [61], [62], [63], [64], [68], [69], [70], [71], [73], [74], [75], [76], [82], [84], [86]
	Tarihi Binalar	[48], [51], [57], [61], [81], [83], [85]
	BIM	[4], [9], [12], [21], [30], [35], [45], [50], [59], [68], [73], [86]
	Yapı Tipolojisi	[17], [28], [35]
	Yapı ve Yakın Çevre	[16], [23], [32], [34], [36], [58], [65], [67], [72], [84], [86]
CAM (Computer Aided Manufacturing)	Dijital Üretim	[10], [19], [79]
	Nokta Bulutları veya Nesne Tanıma	[7], [29], [34], [78], [81], [85]
	Tasarım Süreci	[3], [7], [14], [15], [22], [25], [30], [44], [45], [47], [62], [64], [68], [74], [77], [80]
	Tasarım ve Uygulama	[3], [4], [10], [19], [30], [33], [50], [54], [56], [79]
	Yapı Elemanları	[1], [4], [14], [20], [21], [58], [73], [78]
CAE (Computer Aided Engineering)	Sürdürülebilirlik	[8], [11], [19], [32], [37], [65], [71]
	Yapı Fiziği	[3], [5], [8], [11], [22], [25], [31], [32], [37], [39], [41], [42], [43], [45], [52], [53], [54], [56], [63], [66], [67], [69], [70], [71], [74], [75], [76], [79], [80], [86]
	Yapı Malzemesi	[19], [33]
	Yapı Performansı	[8], [11], [14], [27], [31], [37], [39], [41], [42], [50], [56], [65], [66], [69], [70], [71], [74], [76], [79], [80], [86]
	Yüksek Katlı Binalar	[3], [77]

5.3.2. Mimarlıkta Kullanılan Makine Öğrenmesi Modelleri (AS2)


Literatür taramasının başında oluşturulan “Mimarlıkta ele alınan sorunların çözümü için hangi makine öğrenmesi modelleri kullanılmıştır?” (AS2) sorusuna 86 çalışmanın vermiş olduğu cevaplar çalışma özelinde incelenerek tespit edilmiştir.



Şekil 5.6. Çalışmalarda kullanılan makine öğrenmesi modelleri


Çalışmalarda problemlerin çözümü için Tahmin, Optimizasyon, Analiz, Değerlendirme, Bilgi Çıkarımı, Nesne Tanıma, Sınıflandırma, Görüntü İşleme ve Kümeleme olmak üzere 9 farklı makine öğrenmesi modelleri kullanılmıştır (Şekil 5.6).

86 çalışmada ele alınan 12 farklı CAD (Bilgisayar Destekli Tasarım), 5 farklı CAM (Bilgisayar Destekli Üretim) ve 5 farklı CAE (Bilgisayar Destekli Mühendislik) mimarlık alanlarında ele alınan problemlerin çözümü için kullanılan Değerlendirme (61 çalışma), Tahmin (57 çalışma), Optimizasyon (41 çalışma), Analiz (40 çalışma), Sınıflandırma (26 çalışma), Görüntü İşleme (23 çalışma), Bilgi Çıkarımı (19 çalışma), Nesne Tanıma (13 çalışma) ve Kümeleme (6 çalışma) modellerinin ilişkisi “Chord” diyagramı ile Şekil 5.7’de ifade edilmiştir.



Şekil 5.7. Çalışma alanları ve kullanılan makine öğrenmesi modelleri

5.3.3. Mimarlıkta Kullanılan Makine Öğrenmesi Araç ve Teknikleri (AS3)



Şekil 5.8. Çalışmalarda kullanılan makine öğrenmesi araç ve teknikleri

Literatür taramasının başında oluşturulan “Mimarlık alanında belirlenen sorunların çözümü için literatürde hangi programlama dilleri, yazılımlar, makine öğrenimi platformları, programlama kütüphaneleri ve makine öğrenimi algoritmaları kullanılmıştır?” (AS3) sorusuna 86 çalışmanın vermiş olduğu cevaplar tek tek analiz edilmiştir. 86 çalışma için oluşturulan referans numaraları ile çalışmalarda kullanılan yazılımlar, programlama kütüphaneleri, programlama dilleri, makine öğrenimi platformları ve makine öğrenimi algoritmaları alluvial diyagram kullanılarak eşleştirilmiş ve görselleştirilmiştir (Şekil 5.8). Çalışmaların bazılarında kullanılan makine öğrenmesi araç ve teknikleri hakkında açık bilgilerin bulunmadığı durumlarda “Açıklanmayan” şeklinde diyagramlarda ifade edilmiştir.


5.3.3.1. Mimarlıkta Kullanılan Yazılımlar ve Makine Öğrenmesi Algoritmaları

Yapılan literatür çalışması sonucunda 86 çalışmanın 60 çalışmasında 21 farklı mimarlık alanında belirlenen problemleri çözmek için toplamda 36 farklı yazılım kullanıldığı tespit edilmiştir.

60 çalışmada, Cephe Tasarımı, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Tarihi Binalar, BIM, Yapı Tipolojisi, Yapı ve Yakın Çevre, Dijital Üretim, Nokta Bulutları veya Nesne Tanıma, Tasarım Süreci, Tasarım ve Uygulama, Yapı Elemanları, Sürdürülebilirlik, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı, Yüksek Katlı Binalar olmak üzere mimarlığın 21 farklı alt alanında yazılımlar kullanılmıştır.

60 çalışmada, Rhino-Grasshopper (29 çalışma), EnergyPlus (18 çalışma), Revit (9 çalışma), Radiance (6 çalışma), ClimateStudio (4 çalışma), LabelImg (4 çalışma), Dynamo (3 çalışma), Autocad (2 çalışma), DesignBuilder (2 çalışma), WEKA (2 çalışma), QGIS (2 çalışma), DIVA (2 çalışma), SketchUp (2 çalışma), Unity (2 çalışma), ANSYS CFX (1 çalışma), ANSYS Fluent (1 çalışma), ANSYS Workbench (1 çalışma), DODO (1 çalışma), Generative Components (1 çalışma), Karamba (1 çalışma), VGG Image Annotator (1 çalışma), Cyclone (1 çalışma), Cloud Compare (1 çalışma), Tally (1 çalışma), ENVI-met (1 çalışma), ArcMap (1 çalışma), eCognition (1 çalışma), DAYSIM (1 çalışma), Ladybug (1 çalışma), MOOSAS (1 çalışma), MG-Shade (1 çalışma), Minitab

(1 çalışma), OpenFOAM (1 çalışma), Archicad (1 çalışma), Labelme (1 çalışma), ArcGIS (1 çalışma) yazılımları kullanılmıştır (Şekil 5.9).



Şekil 5.9. Çalışmalarda kullanılan yazılımlar ve makine öğrenmesi algoritmaları

60 çalışmada, ABR, AHP, AlexNet, ANN, Bagged Trees, Batch Normalization, BPNN, CBML, CCA, CNN, Conv, Correlation Matrix, CycleGAN, DBSCAN, DCNN, Deeplab v3+, DES, DGCNN, Dilated-ResUnet, DNN, Douglas Peucker, DT, DTR, ELM, ETR, Fast Tree Regression, Faster-R-CNN, FCM, FIS, FPN, GA, GANs, GB, GBR, GENLINE, GNN, GoogLeNet, GPR, GRNN, ICSA-Unet, Image-to-Image Translation, JRip, K-Means Cluster, K-NN, Levenberg–Marquardt, Linear Regression, Linear Regressor, LSTM, Mask R-CNN, MCD method, MLP, MLP ANN, MLR, MOPSO, MSHD method, MTL, MOO, Naïve Bayes, Normalization Algorithm, NSGA-II, NSGA-III, OLS, Optimization Algorithms, PCA, Pix2Pix, PSO, RandomSearchCV, RANSAC, RBFN, RBFNN, ReLU, ResNet Variations, RF, RFR, RPN, SA, SADM, SCBs, SHAP, Sigmoid Function, Split Function, StyleGAN, Supervised Learning, SVC, SVM, SVR, t-SNE, VGGNet Variations, XGB, YOLO olmak üzere 90 farklı makine öğrenmesi algoritması kullanılmıştır.


5.3.3.2. Mimarlıkta Kullanılan Programlama Kütüphaneleri

Yapılan literatür çalışması sonucunda 86 çalışmanın 51 çalışmasında 22 farklı mimarlık alanında belirlenen problemleri çözmek için toplamda 33 farklı programlama kütüphanesi kullanıldığı tespit edilmiştir.

51 çalışmada, Cephe Tasarımı, Dijital Üretim, Eskiz Çizimi, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Nokta Bulutları veya Nesne Tanıma, Sürdürülebilirlik, Tarihi Binalar, Tasarım Süreci, Tasarım ve Uygulama, BIM, Yapı Elemanları, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı, Yapı Tipolojisi, Yapı ve Yakın Çevre, Yüksek Katlı Binalar olmak üzere mimarlığın 22 farklı alt alanında programlama kütüphaneleri kullanılmıştır.

51 çalışmada, Scikit-Learn (14 çalışma), PyTorch (12 çalışma), Keras (11 çalışma), Pandas (5 çalışma), NumPy (5 çalışma), Matplotlib (5 çalışma), Sklearn (4 çalışma), IfcOpenShell (3 çalışma), ImageNet (3 çalışma), OpenCV (2 çalışma), SciPy (2 çalışma), Seaborn (2 çalışma), CamVid (2 çalışma), Osmx (1 çalışma), modAL (1 çalışma), PYTHONOCC (1 çalışma), PyBrain (1 çalışma), Chainer (1 çalışma), NetworkX (1 çalışma), Pandana (1 çalışma), GeoPandas (1 çalışma), ML.NET (1 çalışma), RPLAN (1 çalışma), CatBoost (1 çalışma), Eppy (1 çalışma), PIL (1 çalışma), Imgaug (1 çalışma),


Deap (1 çalışma), Scriptcontext (1 çalışma), Rinoscriptsyntax (1 çalışma), pyDOE (1 çalışma), Topologic (1 çalışma), Pymoo (1 çalışma) olmak üzere 33 farklı programlama kütüphaneleri kullanılmıştır (Şekil 5.10).



Şekil 5.10. Çalışmalarda kullanılan programlama kütüphaneleri

5.3.3.3. Mimarlıkta Kullanılan Programlama Dilleri ve Makine Öğrenmesi Algoritmaları

Yapılan literatür çalışması sonucunda 86 çalışmadan 55 çalışmada 20 farklı mimarlık alanında belirlenen problemleri çözmek için toplamda 4 farklı programlama dili kullanıldığı tespit edilmiştir (Şekil 5.11).



Şekil 5.11. Çalışmalarda kullanılan programlama dilleri ve makine öğrenmesi algoritmaları

55 çalışmada, Cephe Tasarımı, Dijital Üretim, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Nokta Bulutları veya Nesne Tanıma, Sürdürülebilirlik, Tarihi Binalar, Tasarım Süreci, Tasarım ve Uygulama, BIM, Yapı Elemanları, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı, Yapı Tipolojisi, Yapı ve Yakın Çevre olmak üzere mimarlığın 20 farklı alt alanında programlama dili kullanılmıştır.


55 çalışmada, PYTHON (44 çalışma), MATLAB (10 çalışma), C# (3 çalışma), R (1 çalışma) olmak üzere 4 farklı programlama dili kullanılmıştır. 1 çalışmada MATLAB ve R programlama dili, 2 çalışmada PYTHON ve C# programlama dili birlikte kullanılmıştır.

55 çalışmada mimarlığın alt alanlarındaki problemlere çözüm ararken, CIAC, ABR, AHP, AlexNet, ANN, Bagged Trees, Batch Normalization, Bayesian Networks, CBML, CCA, CNN, Conv, Conv-MPN, Correlation Matrix, DCNN, Deeplab v3+, DenseNet121, DES, DGCNN, DNN, Douglas Peucker, DT, DTR, ELM, ETR, Fast Tree Regression, FCM, FIS, FPN, GA, GANs, Gaussian Naïve Bayes, GB, GBR, GENLINE, GMM, GoogLeNet, GPR, GRNN, HGB, House-GAN++, ICASA-Unet, Image-to-Image Translation, K-Means Cluster, K-Modes Cluster, K-NN, Levenberg–Marquardt, Linear Regression, Linear Regressor, Logistic Regression, LSTM, MRF, Mask R-CNN, MCD method, MLP, MLP ANN, MLR, MOPSO, MSHD method, MTL, Multi-Planar, Naïve Bayes, NSGA-II, NSGA-III, Optimization Algorithms, PCA, Pix2Pix, PSO, RandomSearchCV, RANSAC, RBFNN, ReLU, ResNet Variations, RF, RFR, SADM, SCBs, SHAP, Sigmoid Function, StyleGAN, Supervised Learning, SVC, SVM, SVR, t-SNE, Unsupervised Learning, WGAN, XGB, YOLO olmak üzere 90 farklı makine öğrenmesi algoritmaları kullanılmıştır.

Literatürden seçilen 86 çalışmanın 55 çalışmasında mimarlığın 20 farklı alt alanlarındaki problemleri çözmek için kullanılan 4 farklı programlama dillerinin her birinin analizleri yapılmış olup her programlama dili ile kullanılan yazılımlar, programlama kütüphaneleri, programlama platformları ve makine öğrenmesi algoritmalarının ilişkisi ayrı ayrı incelenmiştir. 86 çalışmanın 31 çalışmasında programlama dili ile ilgili açıklama yapılmamıştır.

PYTHON Programlama Dili

55 çalışmanın 44 çalışmasında PYTHON programlama dili kullanılarak, CAD (Bilgisayar Destekli Tasarım) alanında; Cephe Tasarımı, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Tarihi Binalar, BIM, Yapı Tipolojisi, Yapı ve Yakın Çevre, CAM (Bilgisayar Destekli Üretim) alanında; Dijital Üretim, Nokta Bulutları veya Nesne Tanıma, Tasarım Süreci, Tasarım ve Uygulama, Yapı Elemanları, CAE (Bilgisayar Destekli Mühendislik) alanında; Sürdürülebilirlik, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı olmak üzere 20 farklı mimarlığın alt alanındaki problemlere çözüm aranmıştır.



Şekil 5.12. PYTHON programlama dili kullanan çalışmalar


PYTHON programlama dili ile beraber ANSYS Fluent, ANSYS Workbench, ArcGIS, Archicad, ClimateStudio, DesignBuilder, Dynamo, EnergyPlus, ENVI-met, LabelImg, Labelme, QGIS, Radiance, Revit, Rhino-Grasshopper, Tally, Unity, VGG Image Annotator olmak üzere 18 farklı yazılım kullanılmıştır (Şekil 5.12). 14 çalışmada hangi yazılım kullanıldığına dair bilgi verilmemiştir.

Problemlerin çözümü için yazılım setlerinden ve veri setlerinden yararlanılan, CatBoost, Chainer, Deap, Eppy, GeoPandas, IfcOpenShell, ImageNet, Imgaug, Keras, Matplotlib, modAL NetworkX, NumPy, Osmx, OpenCV, Pandana, Pandas, PIL, PyBrain, pyDOE, PYTHONOCC, PyTorch, Rinoscriptsyntax, RPLAN, Scikit-Learn, SciPy, Scriptcontext, Seaborn, Sklearn, Topologic olmak üzere 30 farklı programlama kütüphaneleri kullanılmıştır.

PYTHON programlama dili ile programlama platformu olarak TensorFlow, Jupyter Notebook ve Google Colab kullanılmıştır.

MATLAB Programlama Dili

55 çalışmanın 10 çalışmasında MATLAB programlama dili kullanılarak, CAD (Bilgisayar Destekli Tasarım) alanında; Cephe Tasarımı, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Tarihi Binalar, Yapı ve Yakın Çevre, CAM (Bilgisayar Destekli Üretim) alanında; Nokta Bulutları veya Nesne Tanıma, Tasarım Süreci, Tasarım ve Uygulama, Yapı Elemanları, CAE (Bilgisayar Destekli Mühendislik) alanında; Yapı Fiziği, Yapı Performansı olmak üzere 13 farklı mimarlığın alt alanındaki problemlere çözüm aranmıştır.




Şekil 5.13. MATLAB programlama dili kullanan çalışmalar

MATLAB programlama dili ile beraber, Cloud Compare, Cyclone, DesignBuilder, Dynamo, EnergyPlus, Minitab, OpenFOAM, Radiance, Revit, Rhino-Grasshopper, Unity olmak üzere 11 farklı yazılım kullanılmıştır (Şekil 5.13). 1 çalışmada ise hangi yazılım kullanıldığına dair bilgi verilmemiştir.

Problemlerin çözümü için yazılım setlerinden ve veri setlerinden yararlanılan, CamVid programlama kütüphanesi kullanılmıştır. MATLAB programlama dili ile programlama platformu olarak Aöli kullanılmıştır.

C# Programlama Dili

55 çalışmanın 3 çalışmasında C# programlama dili kullanılarak, CAD (Bilgisayar Destekli Tasarım) alanında; Hesaplamalı Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, BIM, Yapı ve Yakın Çevre, CAM (Bilgisayar Destekli Üretim) alanında; Tasarım Süreci, Tasarım ve Uygulama, CAE (Bilgisayar Destekli Mühendislik) alanında; Yapı Elemanları Yapı Fiziği, Yapı Performansı olmak üzere 10 farklı mimarlığın alt alanındaki problemlere çözüm aranmıştır.




Şekil 5.14. C# programlama dili kullanan çalışmalar

C# programlama dili ile, Revit ve Rhino-Grasshopper yazılımları kullanılmıştır. Problemlerin çözümü için yazılım setlerinden ve veri setlerinden yararlanılan, Scikit-Learn ve ML.NET programlama kütüphaneleri kullanılmıştır. C# programlama dili ile programlama platformu olarak TensorFlow kullanılmıştır (Şekil 5.14).

R Programlama Dili

55 çalışmanın 1 çalışmasında R programlama dili kullanılarak, CAD (Bilgisayar Destekli Tasarım) alanında; Hesaplamalı Tasarım, CAM (Bilgisayar Destekli Üretim) alanında; Tasarım Süreci, Yapı Elemanları, CAE (Bilgisayar Destekli Mühendislik) alanında; Yapı Performansı olmak üzere 4 farklı mimarlığın alt alanındaki problemlere çözüm aranmıştır.



Şekil 5.15. R programlama dili kullanan çalışmalar

R programlama dili ile DIVA yazılımı kullanılmıştır. R programlama dili ile kullanılan programlama kütüphanesi ve programlama platformları hakkında bilgi verilmemiştir (Şekil 5.15).

5.3.3.4. Mimarlıkta Kullanılan Programlama Platformları ve Makine Öğrenmesi Algoritmaları


Yapılan literatür çalışması sonucunda 86 çalışmanın 33 çalışmasında 20 farklı mimarlık alanında belirlenen problemleri çözmek için toplamda 8 farklı programlama platformu kullanıldığı görülmüştür (Şekil 5.16).

33 çalışmada, Cephe Tasarımı, Dijital Üretim, Eskiz Çizimi, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Nokta Bulutları veya Nesne Tanıma, Sürdürülebilirlik, Tarihi Binalar, Tasarım Süreci, Tasarım ve Uygulama, BIM, Yapı Elemanları, Yapı Fiziği, Yapı Performansı, Yapı Tipolojisi, Yapı ve Yakın Çevre olmak üzere mimarlığın 20 farklı alt alanında programlama platformları kullanılmıştır.

33 çalışmada, TensorFlow (22 çalışma), Jupyter Notebook (4 çalışma), Google Colab (3 çalışma), Aİoli (1 çalışma), AZURE (1 çalışma), Tensorboard (1 çalışma), Visual Studio

(1 çalışma), CIDEA (1 çalışma) olmak üzere 8 farklı programlama platformu kullanılmıştır. 1 çalışmada TensorFlow ve Google Colab programlama platformu birlikte kullanılmıştır.

55 çalışmada mimarlığın alt alanlarındaki problemlere çözüm ararken, ANN, BPNN, CBML, CNN, CycleGAN, DBSCAN, DCNN, Deeplab v3+, Dilated-ResUnet, DNN, DT, ETR, Faster-R-CNN, FPN, GA, GANs, Gaussian Blur, Gaussian Naïve Bayes, GMM, GPR, InceptionV3, K-Means Cluster, K-NN, Linear Regressor, LSTM, Mask R-CNN, MLP, MLP ANN, MTL, MOO, Normalization Algorithm, NSGA-II, OLS, Optimization Algorithms, Pix2Pix, RandomSearchCV, RBFN, ReLU, ResNet Variations, RF, SA, Split Function, Supervised Learning, SVM, t-SNE, VGGNet Variations, WGAN, Xception, XGB olmak üzere 49 farklı makine öğrenmesi algoritması kullanılmıştır.



Şekil 5.16. Çalışmalarda kullanılan programlama platformları

6. TARTIŞMA

Yapay zeka teknolojilerinin gelişmesi ile insana özgü olan anlama, düşünme, yorumlama, karar verme, tecrübeye göre tercih yapabilme gibi özelliklerin bilgisayar destekli makinelerin çalışma prensipleri haline getirilerek, insan zekasını taklit ederek oluşturulan yapay zekaya sahip makineler geliştirilmiştir ve geliştirilmeye de devam edilmektedir. Bu makineler, çeşitli meslek alanlarındaki çeşitli sorunlara çözüm sağlama potansiyelini göstermiştir. Bu tez çalışması, yapay zekanın bir alt alanı olan makine öğrenmesinin mimarlık mesleğinde kullanımını analiz etmeyi amaçlamaktadır. Bu amaçla tez çalışmasında sistematik bir araştırma gerçekleştirilmiştir. Literatür taraması için üç araştırma sorusu formüle edilmiş olup birincisi, mimarlığın birçok alt disiplini olduğundan makine öğrenmesinin mimarlığın hangi alanlarında kullanıldığını belirlemektir. İkincisi mimarlıkta belirlenen alanlardaki problemleri çözerken hangi makine öğrenmesi modellerini kullanarak problemler çözülmüştür. Üçüncüsü ise belirlenen problemleri çözerken hangi makine öğrenmesi araç ve tekniklerinin kullanıldığını tespit etmektir. Belirli anahtar kelimeler kullanılarak seçilen dokuz akademik arama ve yayınlanma platformunda arama yapılarak, 2007-2023 yılları arasında mimarlıkta makine öğrenmesi kullanımına ilişkin 232 çalışmayı belirlemek ve analiz etmek için dört aşamalı sistematik araştırma metodolojisi kullanılmıştır. Oluşturulan arama kriterleri ve dahil etme-hariç tutma kriterlerine uygun olan 86 çalışma seçilmiş olup, seçilen çalışmaların araştırma sorularına verdikleri cevaplar analiz edilmiştir. Bu bölümde, literatür taraması için oluşturulan araştırma sorularına seçilen çalışmaların verdikleri yanıtlar tartışılmıştır.

“Literatürde makine öğrenimi kullanılarak mimarlığın hangi alt alanları incelendi ve bu alt alanlarda hangi sorunlar ele alındı?” (AS1) sorusuna 86 çalışmanın verdikleri yanıtlara göre mimarlıkta makine öğrenmesi kullanımına göre Bilgisayar Destekli Tasarım, Bilgisayar Destekli Üretim ve Bilgisayar Destekli Mühendislik olmak üzere üç ana başlık altında sınıflandırılmıştır.

- Bilgisayar Destekli Tasarım (CAD) alanında: Cephe Tasarımı, Eskiz Çizimi, Genişletilmiş Gerçeklik, Hesaplamalı Tasarım, Kavramsal Tasarım, Kentsel Tasarım, Kullanıcı Deneyimi, Mekan Tasarımı, Tarihi Binalar, BIM, Yapı Tipolojisi, Yapı ve Yakın Çevre olmak üzere 12 farklı alt alan tespit edilmiştir.


- Bilgisayar Destekli Üretim (CAM) alanında: Dijital Üretim, Nokta Bulutları veya Nesne Tanıma, Tasarım Süreci, Tasarım ve Uygulama, Yapı Elemanları olmak üzere 5 farklı alt alan tespit edilmiştir.
- Bilgisayar Destekli Mühendislik (CAE) alanında: Sürdürülebilirlik, Yapı Fiziği, Yapı Malzemesi, Yapı Performansı, Yüksek Katlı Binalar olmak üzere 5 farklı alt alan tespit edilmiştir.

“Mimarlıkta ele alınan sorunların çözümü için hangi makine öğrenmesi modelleri kullanılmıştır?” (AS2) sorusuna 86 çalışmanın vermiş olduğu cevaplara göre, problemin çözümüne uygun olan makine öğrenmesi modellerinin tercih edildiği tespit edilmiştir. Problemleri çözümlmek adına Tahmin, Optimizasyon, Analiz, Değerlendirme, Bilgi Çıkarımı, Nesne Tanıma, Sınıflandırma, Görüntü İşleme ve Kümeleme olmak üzere 9 farklı makine öğrenmesi modelleri kullanılmıştır. Makine öğrenmesi modellerinin 86 çalışmanın kaç çalışmasında kullanıldığı ve 22 farklı alt alandan kaç farklı alt alanda kullanıldığı Tablo 6.1’de listelenmiştir.


Tablo 6.1.Makine öğrenmesi modellerinin özellikleri

Makine Öğrenmesi Modelleri	Çalışma Sayısı	Kullanılan Alt Alanlar
Değerlendirme Modeli	61 çalışma	22 farklı alt alan
Tahmin Modeli	57 çalışma	21 farklı alt alan
Optimizasyon Modeli	41 çalışma	19 farklı alt alan
Analiz Modeli	40 çalışma	18 farklı alt alan
Sınıflandırma Modeli	26 çalışma	19 farklı alt alan
Görüntü İşleme Modeli	23 çalışma	18 farklı alt alan
Bilgi Çıkarımı Modeli	19 çalışma	16 farklı alt alan
Nesne Tanıma Modeli	13 çalışma	16 farklı alt alan
Kümeleme Modeli	6 çalışma	6 farklı alt alan

Makine öğrenmesinin temel çalışma prensibinin ilk adımı problemi tanımlamaktır. İkinci adımı ise problemin çözümlenebilmesi için uygun modellerin seçilmesidir. Üçüncü adımda uygun yazılımlar, programlama dilleri, programlama kütüphaneleri, programlama platformları, algoritmaların seçilmesi ile istenilen sonuca ulaşılmalıdır. Bu sebeple 1. araştırma sorusu olan mimarlığın hangi alanlarındaki problemler ele alındı sorusu ile 2. araştırma sorusu olan ele alınan problemlerin çözümü için hangi makine öğrenmesi modelleri seçildi sorusunun birbirleri ilişkisinin grafiksel gösterimi Şekil 6.1’de “Chord” diyagramı kullanılarak gerçekleştirilmiştir.



Şekil 6.1. Makine öğrenmesi modelleri ile mimarlık alt alanları eşleştirmesi



Şekil 6.1. (Devam) Makine öğrenmesi modelleri ile mimarlık alt alanları eşleştirmesi

“Mimarlık alanında belirlenen sorunların çözümü için literatürde hangi programlama dilleri, yazılımlar, makine öğrenimi platformları, programlama kütüphaneleri ve makine öğrenimi algoritmaları kullanılmıştır?” (AS3) sorusuna 86 çalışmanın vermiş olduğu cevaplar tek tek analiz edilmiştir.

-86 çalışmanın 60 çalışmasında 36 farklı yazılım kullanıldığı tespit edilmiştir. Yazılımların kullanım alanlarına göre 7 farklı kategoride Tablo 6.2’de sınıflandırılmıştır.

Tablo 6.2.Yazılımların kullanım alanlarına göre sınıflandırılması


<u>Mimari Tasarım ve Modelleme</u>	<u>Enerji ve Çevre Performansı Analizi</u>	<u>Coğrafi Bilgi Sistemleri</u>	<u>Veri Analizi</u>	<u>Nokta Bulutu Analizi</u>	<u>Görüntü İşleme ve Etiketleme</u>	<u>Oyun Geliştirme</u>
Rhino- Grasshopper	EnergyPlus	QGIS	WEKA	Cyclone	eCognition	Unity
Revit	DesignBuilder	ArcMap	DODO	Cloud Compare	LabelImg	
SketchUp	DIVA	eCognition	Minitab		Labelme	
Dynamo	ANSYS CFX				VGG Image Annotator	
Autocad	ANSYS Fluent					
Generative Components	ANSYS Workbench					
Archicad	OpenFOAM					
MG-Shade	DAYSIM					
Karamba	Ladybug					
MOOSAS	Radiance					
	ClimateStudio					
	ENVI-met					
	Tally					

-86 çalışmanın 51 çalışmasında 33 farklı programlama kütüphanesi kullanıldığı tespit edilmiştir. En fazla kullanılan programlama kütüphaneleri arasında ilk üçte Scikit-Learn (14 çalışma), PyTorch (12 çalışma) ve Keras (11 çalışma) yer almaktadır.

-86 çalışmanın 55 çalışmasında 4 farklı programlama dili olan PYTHON, MATLAB, R ve C# kullanıldığı belirlenmiştir. Çalışmalarda en çok PYTHON (44 çalışma) ve MATLAB (10 çalışma) programlama dili tercih edilmiştir. 2 çalışmada PYTHON ve C# programlama dili, 1 çalışmada MATLAB ve R programlama dili ortak kullanılmıştır.

-86 çalışmanın 33 çalışmasında 8 farklı programlama platformu kullanılmış olup kullanım sırasında ilk üçte TensorFlow (22 çalışma), Jupyter Notebook (4 çalışma), Google Colab (3 çalışma) programlama platformları bulunmaktadır.

-86 çalışmanın her birinde makine öğrenmesi algoritmaları kullanılmış olup 113 farklı türde makine öğrenmesi algoritması tespit edilmiştir (Şekil 6.2). Çalışmalarda en çok kullanılan makine öğrenmesi algoritmaları arasında ANN (23 çalışma), GANs (13 çalışma), RF (13 çalışma), Pix2Pix (12 çalışma), CNN (10 çalışma), ResNet Variations (9 çalışma), ReLU (8 çalışma) ve SVM (8 çalışma) yer almaktadır.




Şekil 6.2. Çalışmalarda kullanılan makine öğrenmesi algoritmaları

Makine öğrenmesinde problemlerin tanımları yapıldıktan sonra problemlerin çözümü için oluşturulacak sistemde, modeller ile araç ve tekniklerin seçilmesi önemli bir adımdır. Bu noktada 2. araştırma sorusu olan ele alınan problemlerin çözümü için hangi makine öğrenmesi modelleri seçildi sorusu ile 3. araştırma sorusu olan ele alınan problemlerin çözümü için hangi makine öğrenmesi araç ve tekniklerinin kullanıldı sorusunun niceliksel değerleri ile ilişkisi makine öğrenmesinde sonuca ulaşılması için gerekli olan temel prensipleri oluşturmaktadır. İki araştırma sorusunun özellikleri Tablo 6.3'te, birbirleri ile ilişkisi ise Şekil 6.3'de ifade edilmiştir.

Tablo 6.3.Makine öğrenmesi araç ve teknikleri ile makine öğrenmesi modellerinin özellikleri

<u>Makine Öğrenmesi Araç ve Teknikleri</u>	<u>Çeşit Sayısı</u>	<u>Kullanılan Çalışma Sayısı</u>	<u>Kullanılan Alt Alanlar</u>
Yazılımlar	36 çeşit	60 çalışma	21 farklı alt alan
Programlama Kütüphaneleri	33 çeşit	51 çalışma	22 farklı alt alan
Programlama Dili	4 çeşit	55 çalışma	20 farklı alt alan
Programlama Platformları	8 çeşit	33 çalışma	20 farklı alt alan
Algortimalar	113 çeşit	86 çalışma	22 farklı alt alan
Modeller	9 çeşit	86 çalışma	22 farklı alt alan



Şekil 6.3. Makine öğrenmesi araç ve teknikleri ile makine öğrenmesi modelleri ilişkisi

7. SONUÇLAR VE ÖNERİLER

Mimarlık mesleğinde geleneksel el çiziminden başlayan tasarım süreci, bilgisayar ve yazılım teknolojilerinin gelişmesi ile dijital ortamlara aktarılmıştır. Böylece mimari tasarımlar, bilgisayar destekli yazılımlar kullanılarak hesaplamalı bir şekilde üç boyutlu modellemeleri yapılabilir hale gelmiştir. Mimari tasarımların bilgisayar destekli ortamlarda gerçekleştirilmesi ile tasarımların uygulama aşamasında çıkabilecek bazı problemlerinin uygulama öncesinden fark edilmesini sağlamaktadır. Problemlerin önceden tespit edilmesi, daha hızlı çözümler üretilmesiyle zamanın etkili kullanılmasını, uygulama sırasında çıkabilecek maddi kayıpların önlenmesiyle maliyetin minimuma düşürülmesini, proje ekibinin birbirleriyle iletişiminin artmasıyla proje yönetiminin daha verimli hale getirilmesi gibi kazançlar sağlamaktadır.

Gelişen bilgisayar ve yazılım teknolojileri, mimari tasarımların yanı sıra üretimlerinin de bilgisayar destekli hale getirilmesi ile tasarım ve uygulama süreçlerinin daha entegre çalışabilir hale gelmesini sağlamıştır. Böylece tasarım aşamasından üretim aşamasına kadar geçen her adımın bilgisayar ortamında koordineli takibinin yapılmasını imkan sağlamıştır. Tüm bu süreçler, Bilgisayar Destekli Tasarım, Bilgisayar Destekli Mühendislik ve Bilgisayar Destekli Üretim başlıkları altında değerlendirilmektedir.

Günümüzde yapay zeka ve bilişim teknolojilerinin hızla ilerlemesi ile CAD, CAM ve CAE gibi bilgisayar destekli tasarım, mühendislik ve üretim alanlarında bu teknolojiler önemli bir yardımcı araç haline gelmiştir. Yapılan tez çalışmasında ise yapay zeka teknolojilerinin bir alt alanı olan makine öğrenmesinin mimarlık mesleğinde kullanımını CAD, CAM ve CAE olmak üzere üç ana başlıkta ele alınmıştır. CAD alanında 12 farklı mimari alt alanda, CAM alanında 5 farklı mimari alt alanda, CAE alanında ise 5 farklı alt alanda makine öğrenmesinin problemlere çözüm arandığı görülmüştür.

Makine öğrenmesinin çalışma prensibi temel olarak bir problemin tanımlanması, o problemlere ait verilerin doğru ve yeterli sayıda toplanması, problemlerin çözümü için uygun olan modellerin seçilmesi ve çözüme ulaştıracak uygun yazılımların, programlama kütüphanelerinin, programlama dillerinin, programlama platformlarının ve algoritmalarının seçilmesi şeklinde bir süreci ifade etmektedir. Tez çalışması kapsamında yapılan literatür taramasında CAD, CAM ve CAE alanlarında 22 farklı mimari alt

alanlarda belirlenen mimari problemlere makine öğrenmesi ile çözüm aranmıştır. Tarihi binaların korunmasından yapı elemanlarının hesaplamalarının yapılmasına, eskiz aşamasından kentsel tasarıma, kullanıcı deneyiminden yapı performansına kadar birçok farklı mimari alanda problemler tanımlanmıştır. Belirlenen problemlerin çözümleri için 9 farklı makine öğrenmesi modelleri seçilmiştir. Daha sonra 36 farklı yazılım, 33 farklı programlama kütüphanesi, 4 farklı programlama dili, 8 farklı programlama platformu ve 113 tane makine öğrenmesi algoritması kullanılarak makine öğrenmesi ile problemlerin çözümlenmesi gerçekleştirilmiştir.

Yapılan tez çalışmasında ele alınan 86 çalışmanın incelenmesi ile makine öğrenmesinin mimarinin farklı kullanım alanlarında farklı problemleri ele aldığı ve problemlerin çözümüne özel çeşitli modeller, yazılımlar, programlama kütüphaneleri, programlama dilleri, programlama platformları ve algoritmalarının kullanıldığı sonucu tespit edilmiştir.

Litaratür taramasının veri kapsamı ve odağına ilişkin mevcut sınırlamalara dayanarak geliştirilebilecek potansiyel alanlar bulunmaktadır. Birincisi, veritabanlarının seçimine ilişkin olarak, sistematik inceleme 2007'den 2023'e kadar akademik arama ve yayınlanma platformlarıyla sınırlandırılmıştır ve böylece sınırlı sayıda çalışmaya ulaşılmıştır. Gelecekteki çalışmalar, daha kapsamlı bir analiz için "ProQuest Dissertation and thesis" veya "EThos" gibi veritabanları da dahil edilerek, araştırmayı daha geniş bir platform yelpazesini kapsayacak şekilde genişletilebilir ve zaman aralığı uzatılabilir. İkinci olarak, çalışmanın kapsamını yapılan aramayla uyumlu hale getirmek için ulaşılmak istenilen mimari alt alanlara ilişkin spesifik arama terimlerinin dahil edilmesi ile daha fazla çalışmaya ulaşılabilir. Üçüncü olarak, makine öğrenmesi modelleri veya makine öğrenmesi yazılımları, programlama kütüphaneleri, programlama dilleri, programlama platformları ve algoritmalarının terimleri aramaya dahil edilmesi ile makine öğrenmesinin mimaride kullanımına ilişkin daha kapsamlı bir çalışma elde edilebilir.

KAYNAKLAR

- Aalaei, M., Saadi, M., Rahbar, M., Ekhlasi, A. (2023). Architectural Layout Generation Using a Graph-Constrained Conditional Generative Adversarial Network (GAN). *Automation in Construction*, 155, 1-17.
- Abdel-Aleem, A., El-Sharief, M. A., Hassan, M. A., El-Sebaie, M. G. (2017). Implementation of Fuzzy And Adaptive Neuro-Fuzzy Inference Systems in Optimization of Production Inventory Problem. *Applied Mathematics & Information Sciences*, 11(1), 289-298.
- Abdulfattah, B. S., Abdelsalam, H. A., Abdelsalam, M., Bolpagni, M., Thurairajah, N., Perez, L. F., Butt, T. E. (2023). Predicting Implications of Design Changes in BIM-Based Construction Projects Through Machine Learning. *Automation in Construction*, 155, 1-23.
- Afify, H., Abd ElGhaffar, Z. A. (2007). Advanced Digital Manufacturing Techniques (CAM) in Architecture. ASCAAD, Egypt, 28-30 Kasım 2007.
- Aggarwal, Y. (2007). Modeling of Reinforcement in Concrete Beams Using Machine Learning Tools. *International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*, 1(8), 69-73.
- Akay, E. Ç. (2018). Ekonometride Yeni Bir Ufuk: Büyük Veri ve Makine Öğrenmesi. *Sosyal Bilimler Araştırma Dergisi*, 7(2), 41-53.
- Akdoğan, M., Alaçam, S., Töreyin, B. U. (2023). a Bayesian Model for Optimizing Thermal Comfort and Indoor Air Quality. *SIGraDi 2023*, Uruguay, 29,30 Kasım-1 Aralık 2023.
- Akipek, F. Ö., İnceoğlu, N. (2007). Bilgisayar Destekli Tasarım ve Üretim Teknolojilerinin Mimarlıktaki Kullanımları. *MEGARON/Yıldız Teknik Üniversitesi, Mimarlık Fakültesi E-Dergisi*, 2(4), 237-253.
- Aksoy, B. (2021). Finansal Tablo Hileleri'nin Makine Öğrenmesi Yöntemleri ve Lojistik Regresyon Kullanılarak Tahmin Edilmesi: Borsa İstanbul Örneği. *Maliye ve Finans Yazıları*, (115), 27-58.
- Alaçam, S., Karadağ, I., Güzelci, O. Z. (2022). Reciprocal Style and Information Transfer Between Historical Istanbul Pervititch Maps and Satellite Views Using Machine Learning. *Estoa. Revista de la Facultad de Arquitectura y Urbanismo de la Universidad de Cuenca*, 11(22), 97-113.
- Alan, A., Karabatak, M. (2020). Veri Seti-Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(2), 531-540.

- Algamdey, A., Mastalski, A., Chronis, A., Gurung, A., Vargas, F. R., Bodenbender, G., Khairallah, L. (2022). AI Urban Voids: A Data-Driven Approach to Urban Activation. *CDRF 2022 Hybrid Intelligence*, Çin, 25-26 Haziran 2022.
- Altaş, İ. H. (1999). Bulanık Mantık: Bulanıklılık Kavramı. *Enerji, Elektrik, Elektromekanik-3e*, 62, 80-85.
- Alymani, A., Jabi, W., Corcoran, P. (2020). Machine Learning Methods for Clustering Architectural Precedents-Classifying the Relationship Between Building and Ground. *38th eCAADe*, Almanyada, 16-17 Eylül 2020.
- Alymani, A., Jabi, W., Corcoran, P. (2023). Graph Machine Learning Classification Using Architectural 3D Topological Models. *Simulation*, 99(11), 1117-1131.
- Alzubi, J., Nayyar, A., Kumar, A. (2018). Machine Learning from Theory to Algorithms: an Overview. *Second National Conference on Computational Intelligence (NCCI 2018)*, Bangalore, 5 Aralık 2018.
- Aman, J., Kim, J. B., Verniz, D. (2023). AI-Integrated Urban Building Energy Simulation. *41th eCAADe*, Avusturya, 20-23 Eylül 2023.
- Arslan, H. (2008). Sakarya Üniversitesi Web Sitesi Erişim Kayıtlarının Web Madenciliği İle Analizi. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 216041.
- Artoni, F., Delorme, A., Makeig, S. (2018). Applying Dimension Reduction to EEG Data By Principal Component Analysis Reduces the Quality of Its Subsequent Independent Component Decomposition. *NeuroImage*, 175, 176-187.
- As, I., Pal, S., Basu, P. (2018). Artificial Intelligence in Architecture: Generating Conceptual Design Via Deep Learning. *International Journal of Architectural Computing*, 16(4), 306-327.
- Atalay, M., Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları- Artificial Intelligence and Machine Learning Applications in Big Data Analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Awad, M., Khanna, R. (2015). Machine Learning in Action: Examples. Awad, M., Khanna, R., (Ed.) *Efficient Learning Machines* (1) (209-240). New York: Apress.
- Aydoğan, Ü. (2006). Bilgisayar Destekli Tasarım Yazılımlarının Stratejik Kullanımının Değerlendirilmesi. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 223494.

- Ayesha, S., Hanif, M. K., Talib, R. (2020). Overview And Comparative Study of Dimensionality Reduction Techniques for High Dimensional Data. *Information Fusion*, 59, 44-58.
- Ayndın, M.E. (1997). Zeki Etmenlerde Öğrenme Kabiliyetinin Geliştirilmesi ve Dinamik Bir Atölye Tipi Çizelgeleme Uygulaması. Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 68270.
- Bahman, A. S., Iannuzzo, F. (2018). Computer-Aided Engineering Simulations. Suganuma, K. (Ed.), *Wide Bandgap Power Semiconductor Packaging* (1) (199-223). Sawston: Woodhead Publishing.
- Başoğlu, B., Bulut, M. (2017). Kısa Dönem Elektrik Talep Tahminleri için Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575-583.
- Bekleriç, G. (2003). Yapay Zekada Zeki Etmenler Ve Uygulamaları. Yüksek Lisans, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 142885.
- Belsare, A. D., Mushrif, M. M. (2012). Histopathological Image Analysis Using Image Processing Techniques: An Overview. *Signal & Image Processing*, 3(4), 23-36.
- Bilgin, M. (2017). Gerçek Veri Setlerinde Klasik Makine Öğrenmesi Yöntemlerinin Performans Analizi. *Breast*, 2(9), 1-6.
- Bloch, T., Sacks, R. (2018). Comparing Machine Learning and Rule-Based Inferencing for Semantic Enrichment of BIM Models. *Automation in Construction*, 91, 256-272.
- Bozüyük, T., Yağci, C., Gökçe, İ., Gökem, A. K. A. R. (2005). *Yapay Zeka Teknolojilerinin Endüstrideki Uygulamaları*. Elektrik Programı Tezi, Marmara Üniversitesi, İstanbul.
- Brown, L., Yip, M., Gardner, N., Haeusler, M. H., Khean, N., Zavoleas, Y., Ramos, C. (2020). Drawing Recognition- Integrating Machine Learning Systems into Architectural Design Workflows. *38th eCAADe*, Almanya, 16-17 Eylül 2020.
- Brown, N. C., Mueller, C. T. (2019). Design Variable Analysis and Generation for Performance-Based Parametric Modeling in Architecture. *International Journal of Architectural Computing*, 17(1), 36-52.
- Catania, L. J. (2021). *Foundations of Artificial Intelligence in Healthcare and Bioscience* (1) (29-72). Cambridge: Academic Press.
- Chan, Y. H. E., Spaeth, A. B. (2020, September). Architectural Visualisation with Conditional Generative Adversarial Networks (CGAN). *38th eCAADe*, Almanya, 16-17 Eylül 2020.

- Chang, K. H. (2014). *Product Design Modeling using CAD/CAE The Computer Aided Engineering Design Series (1)* (1-37). Cambridge: Academic Press.
- Chatzikonstantinou, I., Saryıldız, I. S. (2017). Addressing Design Preferences Via Auto-Associative Connectionist Models: Application in Sustainable Architectural Façade Design. *Automation in Construction*, 83, 108-120.
- Chellappa, R., Rosenfeld, A. (2003). Image Processing. Meyers, R., A. (Ed.), *Encyclopedia of Physical Science and Technology* (3) (595-630). Cambridge: Academic Press.
- Croce, V., Manuel, A., Caroti, G., Piemonte, A., De Luca, L., Véron, P. (2023). Semi-Automatic Classification of Digital Heritage on the Aïoli Open Source 2D/3D Annotation Platform Via Machine Learning and Deep Learning. *Journal of Cultural Heritage*, 62, 187-197.
- Çevik, K. K., Kayakuş, M. (2020). Bilişim Teknolojileri Departmanında Kullanıcıların Taleplerine Cevap Verme Süresinin Makine Öğrenmesi ile Tahmin Edilmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(3), 728-739.
- Daemei, A. B., Shafiee, E., Chitgar, A. A., Asadi, S. (2021). Investigating The Thermal Performance of Green Wall: Experimental Analysis, Deep Learning Model, and Simulation Studies in a Humid Climate. *Building and Environment*, 205, 1-14.
- Danuser, G. (2011). Computer Vision in Cell Biology. *Cell*, 147(5), 973-978.
- Daş, R., Polat, B. ve Tuna, G. (2019). Derin ile Öğrenme Resim ve Videolarda Nesnelerin Tanınması ve Takibi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 571-581.
- Dayan, A., Yılmaz, A. (2022). Doğal Dil İşleme ve Derin Öğrenme Algoritmaları ile Makine Dili Modellemesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(3), 467-475.
- Dixit, M., Chaurasia, K., Mishra, V. K. (2021). Dilated-Resunet: a Novel Deep Learning Architecture for Building Extraction from Medium Resolution Multi-Spectral Satellite Imagery. *Expert Systems with Applications*, 184, 1-16.
- Dong, Z., Lin, J. (2022). Nolli Map: Interpretation of Urban Morphology Based on Machine Learning. *CDRF 2022 Hybrid Intelligence*, Çin, 25-26 Haziran 2022.
- Döşoğlu, M. K., Duman, S., Öztürk, A. (2009). Genetik Algoritma Kullanarak Ekonomik Dağıtım Analizi. *Türkiye uygulaması. Politeknik Dergisi*, 12(3), 167-172.
- Dwivedi, R., Srivastava, V. K. (2023). Fundamental Optimization Methods for Machine Learning. Goswami, T., Sinha, G.R. (Ed.), *Statistical Modeling in Machine Learning* (1) (227-247). Cambridge: Academic Press.

- Ergün, S. (2012). Zeki Etmenler ile Sera Kontrolü. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta, 318147.
- Ersöz, F., Çınar, Y. (2021). Veri Madenciliği ve Makine Öğrenimi Yaklaşımlarının Karşılaştırılması: Tekstil Sektöründe bir Uygulama. *Avrupa Bilim ve Teknoloji Dergisi* (29), 397-414.
- Escobar, C. A., Morales-Menendez, R. (2024). *Machine Learning in Manufacturing* (1) (45-59). Amsterdam: Elsevier.
- Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., Akinyelu, A. A. (2022). a Comprehensive Survey of Clustering Algorithms: State-Of-The-Art Machine Learning Applications, Taxonomy, Challenges, and Future Research Prospects. *Engineering Applications of Artificial Intelligence*, 110, 1-43.
- Fan, Y., Ding, X., Wu, J., Ge, J., Li, Y. (2021). High Spatial-Resolution Classification of Urban Surfaces Using a Deep Learning Method. *Building and Environment*, 200, 1-13.
- Fatehi, E., Sarvestani, H. Y., Ashrafi, B., Akbarzadeh, A. H. (2021). Accelerated Design of Architected Ceramics with Tunable Thermal Resistance Via a Hybrid Machine Learning and Finite Element Approach. *Materials & Design*, 210, 1-13.
- Fathy, F., Mansour, Y., Sabry, H., Refat, M., Wagdy, A. (2023). Virtual Reality and Machine Learning for Predicting Visual Attention in a Daylit Exhibition Space: a Proof of Concept. *Ain Shams Engineering Journal*, 14(6), 1-19.
- Feng, K., Lu, W., Wang, Y. (2019). Assessing Environmental Performance in Early Building Design Stage: an Integrated Parametric Design and Machine Learning Method. *Sustainable Cities and Society*, 50, 1-15.
- Gan, V. J. (2022). BIM-Based Graph Data Model for Automatic Generative Design of Modular Buildings. *Automation in Construction*, 134, 1-20.
- Gong, P., Huang, X., Huang, C., Wang, S. (2023). Modeling on Outdoor Thermal Comfort in Traditional Residential Neighborhoods in Beijing Based on GAN. *CDRF 2023–Phygital Intelligence*, Çin, 24 Haziran 2023.
- Gonzalez, D., Rueda-Plata, D., Acevedo, A. B., Duque, J. C., Ramos-Pollan, R., Betancourt, A., Garcia, S. (2020). Automatic Detection of Building Typology Using Deep Learning Methods on Street Level Images. *Building and Environment*, 177, 1-12.
- Gökalp, Ö. M. (2022). *Makine Öğrenmesi*. ResearchGate, https://www.researchgate.net/publication/357974983_Makine_Ogrenmesi_-_Machine_Learning (Ziyaret tarihi: 25 Mayıs 2024).

- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., Lew, M. S. (2016). Deep Learning for Visual Understanding: a Review. *Neurocomputing*, (187), 27-48.
- Güven, G. Ö., Yılmaz, Ş., İnceoğlu, F. (2024). Determining Medical Students' Anxiety and Readiness Levels About Artificial Intelligence, *Heliyon*, 10(4), 1-7.
- Güzceli, O. Z. (2022). A Machine Learning-based Model to Predict the Cap Geometry of Anatolian Seljuk Kümbets. *Periodica Polytechnica Architecture*, 53(3), 207-219.
- Hamid-Lakzaeian, F. (2020). Point Cloud Segmentation and Classification of Structural Elements in Multi-Planar Masonry Building Facades. *Automation in Construction*, 118, 1-20.
- Han, Z., Li, X., Sun, J., Wang, M., Liu, G. (2023). An Interactive Multi-Criteria Decision-Making Method for Building Performance Design. *Energy and Buildings*, 282, 1-17.
- Hatipoğlu, A., Güneri, Y., Yılmaz, E. (2024). Makine ve Derin Öğrenme Temelli Karşılaştırmalı Bir Öngörücü Bakım Uygulaması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(2), 1037-1048.
- He, Q., Li, Z., Gao, W., Chen, H., Wu, X., Cheng, X., Lin, B. (2021). Predictive Models for Daylight Performance of General Floorplans Based on CNN and GAN: a Proof-of-Concept Study. *Building and Environment*, 206, 1-14.
- He, Y., Liu, X. H., Zhang, H. L., Zheng, W., Zhao, F. Y., Schnabel, M. A., Mei, Y. (2021). Hybrid Framework for Rapid Evaluation of Wind Environment Around Buildings Through Parametric Design, CFD Simulation, Image Processing and Machine Learning. *Sustainable Cities and Society*, 73, 1-14.
- Hsu, H. C., Chang, S., Chen, C. C., Wu, I. C. (2020). Knowledge-Based System for Resolving Design Clashes in Building Information Models. *Automation in Construction*, 110, 1-14.
- Huang, W., Zheng, H. (2018). Architectural Drawings Recognition and Generation Through Machine Learning. *38th Annual Conference of the Association for Computer Aided Design In Architecture (ACADIA)*, Meksika, 18- 20 Ekim 2018.
- İçen, D., Günay, S. (2014). Uzman Sistemler ve İstatistik. *Journal of Statisticians: Statistics and Actuarial Sciences*, 7(2), 37-45.
- İnce, H., İmamoğlu, S. E., İmamoğlu, S. Z. (2021). Yapay Zeka Uygulamalarının Karar Verme Üzerine Etkileri: Kavramsal Bir Çalışma. *International Review of Economics and Management*, 9(1), 50-63.
- İşçi, Ö., Korukoğlu, S. (2003). Genetik Algoritma Yaklaşımı ve Yöneylem Araştırmasında Bir Uygulama. *Yönetim ve Ekonomi Dergisi*, 10(2), 191-208.

- Jakhar, D., Kaur, I. (2020). Artificial Intelligence, Machine Learning and Deep Learning: Definitions and Differences. *Clinical and experimental dermatology*, 45(1), 131-132.
- Japkowicz, N. (2006, July). Why Question Machine Learning Evaluation Methods. *AAAI Workshop on Evaluation Methods for Machine Learning*, 6(11), 1-6.
- Kalita, J. K., Bhattacharyya, D. K., Roy, S. (2024). *Fundamentals of Data Science Theory and Practice* (1) (181-214). Cambridge: Academic Press.
- Karadağ, İ. (2023). Machine Learning for Conservation of Architectural Heritage. *Open House International*, 48(1), 23-37.
- Karadağ, İ., Güzelci, O. Z., Alaçam, S. (2023). EDU-AI: a Twofold Machine Learning Model to Support Classroom Layout Generation. *Construction Innovation*, 23(4), 898-914.
- Karayaneva, Y., Hintea, D. (2018). Object Recognition in Python and Mnist Dataset Modification and Recognition with Five Machine Learning Classifiers. *Journal of Image and Graphics*, 6(1), 10-20.
- Kaynar, O., Arslan, H., Görmez, Y., Işık, Y. E. (2018). Makine Öğrenmesi Ve Öz nitelik Seçim Yöntemleriyle Saldırı Tespiti. *Bilişim Teknolojileri Dergisi*, 11(2), 175-185.
- Keskinel, F. (1985). CAD/CAM Sistemlerine Genel Bir Bakış. *Mimarlık Dergisi*, 219(23), 18-21.
- Kim, J., Kent, M., Kral, K., Doğan, T. (2022). Seemo: a New Tool for Early Design Window View Satisfaction Evaluation in Residential Buildings. *Building and Environment*, 214, 1-14.
- Kokkotis, C., Moustakidis, S., Papageorgiou, E., Giakas, G., Tsaopoulos, D. E. (2020). Machine Learning in Knee Osteoarthritis: a Review. *Osteoarthritis and Cartilage Open*, 2(3), 1-13.
- Koo, B., La, S., Cho, N. W., Yu, Y. (2019). Using Support Vector Machines to Classify Building Elements for Checking the Semantic Integrity of Building Information Models. *Automation in Construction*, 98, 183-194.
- Koyuncu, M., & Sert, M. (2013). Videolarda Görüntü, Ses ve Metin Verileri Kullanılarak Anlamsal Bilgi Çıkarımı, Depolanması ve Sorgulanması. *TUBİTAK*, 109E014, 1-59.
- Krijnen, T., Tamke, M. (2015). Assessing Implicit Knowledge in BIM Models with Machine Learning. *Modelling Behaviour*, Danimarka, 29 Eylül 2015.

- Kristiansen, T., Jamil, F., Hameed, I. A., Hamdy, M. (2022). Predicting Annual Illuminance and Operative Temperature in Residential Buildings Using Artificial Neural Networks. *Building and Environment*, 217, 1-14.
- Kumar, I., Singh, S. P. (2022). Machine Learning in Bioinformatics. Singh, D. B., Pathak, R. K. (Ed.), *In Bioinformatics* (1) (443-456). Cambridge: Academic Press.
- Kwon, H. J., Kwon, H. K. (2019). Computer Aided Engineering (CAE) Simulation for the Design Optimization of Gate System on High Pressure Die Casting (HPDC) Process. Chen, F., Wang, Y. C., Jeong, B., Kim, D.W. (Ed.), *Robotics and Computer-Integrated Manufacturing* (55) (147-153).
- Lee-Post, A. (2003). Computer-Aided Manufacturing. Bidgoli, H., (Ed.), *Encyclopedia of Information Systems* (1) (187-203). Amsterdam: Elsevier.
- Li, Q., Zheng, H. (2023). Prediction of Summer Daytime Land Surface Temperature in Urban Environments Based on Machine Learning. *Sustainable Cities and Society*, 97, 1-22.
- Li, Z., Dai, J., Chen, H., Lin, B. (2019). An ANN-Based Fast Building Energy Consumption Prediction Method for Complex Architectural Form at the Early Design Stage. *Building Simulation*, 12, 665-681.
- Li, Z., Zhao, Y., Xia, H., Xie, S. (2023). A Multi-Objective Optimization Framework for Building Performance Under Climate Change. *Journal of Building Engineering*, 80, 1-31.
- Lin, C. H., Tsay, Y. S. (2021). A Metamodel Based on Intermediary Features for Daylight Performance Prediction of Façade Design. *Building and Environment*, 206, 1-14.
- Liu, H., Lang, B. (2019). Machine Learning and Deep Learning Methods for Intrusion Detection Systems: a Survey. *Applied Sciences*, 9(20), 1-28.
- Liu, Y., Zhang, Z., Hu, K., Deng, Q. (2023). Graph Constrained Multiple Schemes Generation for Campus Layout. *CDRF 2023-Phygital Intelligence*, Çin, 24 Haziran 2023.
- Long, L. D. (2023). An AI-Driven Model for Predicting and Optimizing Energy-Efficient Building Envelopes. *Alexandria Engineering Journal*, 79, 1-22.
- Mahmoodpour, M., Lobov, A., Hayati, S., Pastukhov, A. (2019). An Affordable Deep Learning Based Solution to Support Pick and Place Robotic Tasks. *Instrumentation Engineering, Electronics and Telecommunications-2019: Proceedings of the V International Forum*, Izhevsk, 20-22 Kasım 2019.
- Maleki, F., Ovens, K., Najafian, K., Forghani, B., Reinhold, C., Forghani, R. (2020). Overview Of Machine Learning Part 1: Fundamentals and Classic Approaches. *Neuroimaging Clinics*, 30(4), e17-e32.

- Malhotra, A. G., Borkar, P., Chowdhary, R., Sing, S. (2023). Combating COVID-19 by Employing Machine Learning Predictions and Projections. Pal, K., Ari, S., Bit, A., Bhattacharyya, S. (Ed.), *Advanced Methods in Biomedical Signal Processing and Analysis* (1) (175-203). Cambridge: Academic Press.
- Mao, J., Pan, Y., Fu, Y. (2016). Towards Fast Energy Performance Evaluation: A Pilot Study for Office Buildings. *Energy and Buildings*, 121, 104-113.
- Martínez-Comesaña, M., Ogando-Martínez, A., Troncoso-Pastoriza, F., López-Gómez, J., Febrero-Garrido, L., Granada-Álvarez, E. (2021). Use of Optimised MLP Neural Networks for Spatiotemporal Estimation of Indoor Environmental Conditions of Existing Buildings. *Building and Environment*, 205, 1-12.
- Martínez-Rocamora, A., Rivera-Gómez, C., Galán-Marín, C., Marrero, M. (2021). Environmental Benchmarking of Building Typologies Through BIM-Based Combinatorial Case Studies. *Automation in Construction*, 132, 1-17.
- Mehrotra, A., Yi, H. (2023). Effect of Adaptive Intelligent Sampling and Machine-Learning Emulators in Surrogate Energy Modeling of Architectural Massing. *Journal of Building Engineering*, 72, 1-32.
- Meshram, K. (2024). *Machine Learning Applications in Civil Engineering* (1). Amsterdam: Elsevier.
- Millán, E., Belmonte, M. V., Boned, F. J., Gavilanes, J., Pérez-de-la-Cruz, J. L., Díaz-López, C. (2022). Using Machine Learning Techniques for Architectural Design Tracking: an Experimental Study of the Design of a Shelter. *Journal of Building Engineering*, 51, 1-18.
- Mitchell, T. (1997). *Machine Learning* (1). New York: McGraw Hill.
- Mousavi, M., TohidiFar, A., Alvanchi, A. (2022). BIM and Machine Learning in Seismic Damage Prediction for Non-Structural Exterior Infill Walls. *Automation in Construction*, 139, 1-13.
- Muehlbauer, M., Song, A., Burry, J. (2017). Towards Intelligent Control in Generative Design, in *Computer-Aided Architectural Design Futures (CAADFutures) 2017*, Türkiye, 12-14 Temmuz 2017.
- Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *Proceedings of the National Academy of Sciences*, 116(44), 22071-22080.
- Mustapha, M. T., Ozsahin, I., Ozsahin, D. U. (2024). Introduction to Machine Learning and Artificial Intelligence. Zgallai, W. A., Ozsahin, D. U. (Ed.), *Artificial Intelligence and Image Processing in Medical Imaging* (1) (1-24). Cambridge: Academic Press.

- Nabiyev, V. V. (2012). *Yapay Zeka: İnsan-Bilgisayar Etkileşimi* (4). Ankara: Seçkin Yayıncılık.
- Negi, N., Chawla, G. (2021). Clustering Algorithms in Healthcare. Bhatia, S., Dubey, A.K., Chhikara, R., Chaudhary, P., Kumar, A. (Ed.) *In Intelligent healthcare: Applications of ai in ehealth* (1) (211-224). Cham: Springer.
- Newton, D. (2019). Deep Generative Learning for the Generation and Analysis of Architectural Plans with Small Datasets. *Technology|Architecture + Design*, 3(2), 176–189.
- Nismi Mol, E. A., Santosh Kumar, M. B. (2023). Review on Knowledge Extraction from Text and Scope in Agriculture Domain. *Artificial Intelligence Review*, 56(5), 4403-4445.
- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., Akinjobi, J. (2017). Supervised Machine Learning Algorithms: Classification and Comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Önder, H. H. (2003). Uzaktan Eğitimde Bilgisayar Kullanımı ve Uzman Sistemler. *TOJET: The Turkish Online Journal of Educational Technology*, 2(3), 142-146.
- Özdemir, Ş., Örsü, S. (2019). Makine Öğrenmesinde Yeni Bir Bakış Açısı: Otomatik Makine Öğrenmesi (AutoML). *Journal of Information Systems and Management Research*, 1(1), 23-30.
- Özsel Akipek, F. (2004). Bilgisayar Teknolojilerinin Mimarlıkta Tasarım Geliştirme Amaçlı Kullanımları. Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 154522.
- Öztemel, E. (2003). *Yapay Sinir Ağları* (1). İstanbul: Papatya Yayıncılık Eğitim.
- Öztemel, E., (2020). Yapay Zekâ ve İnsanlığın Geleceği. Şeker, M., Bulduklu, Y., Korkut, C., Doğrul, M. (Ed.), *Bilişim Teknolojileri ve İletişim* (1) (95-112). Ankara: Türkiye Bilimler Akademisi.
- Painter, J. R., Mair, G. M., Clarkson, T. G. (1994). Computer-integrated Engineering Systems. Smith, E. H., (Ed.), *Mechanical Engineer's Reference Book* (1) (5-1). Oxford: Butterworth-Heinemann.
- Pargent, F., Schoedel, R., Stachl, C. (2023). Best Practices in Supervised Machine Learning: A Tutorial For Psychologists. *Advances in Methods and Practices in Psychological Science*, 6(3), 1-35.
- Payet, M., David, M., Lauret, P., Amayri, M., Ploix, S., Garde, F. (2022). Modelling of Occupant Behaviour in Non-Residential Mixed-Mode Buildings: the Distinctive Features of Tropical Climates. *Energy and Buildings*, 259, 1-15.

- Peng, W., Gero, J. S. (2007). Computer-Aided Design Tools That Adapt. in *Computer-Aided Architectural Design Futures (CAADFutures) 2007*, Avustralya, 11-13 Temmuz 2007.
- Płoszaj-Mazurek, M., Ryńska, E., Grochulska-Salak, M. (2020). Methods to Optimize Carbon Footprint of Buildings in Regenerative Architectural Design with the Use of Machine Learning, Convolutional Neural Network, and Parametric Design. *Energies*, 13(20), 5289.
- Qian, W., Xu, Y., Li, H. (2022). a Self-Sparse Generative Adversarial Network for Autonomous Early-Stage Design of Architectural Sketches. *Computer-Aided Civil and Infrastructure Engineering*, 37(5), 612-628.
- Qian, W., Yang, F., Mei, H., Li, H. (2023). Artificial Intelligence-Designer for High-Rise Building Sketches with User Preferences. *Engineering Structures*, 275, 1-15.
- Quevedo, T. C., Geraldi, M. S., Melo, A. P. (2023). Applying Machine Learning to Develop Energy Benchmarking for University Buildings in Brazil. *Journal of Building Engineering*, 63, 1-18.
- Rebala, G., Ravi, A., Churiwala, S. (2019). *An Introduction to Machine Learning* (1). Cham: Springer.
- Rhee, J., Cardoso Llach, D., & Krishnamurti, R. (2019). Context-rich Urban Analysis Using Machine Learning-a Case Study in Pittsburgh, *37th eCAADe and the 23rd SIGraDi*, Portekiz, 11-13 Eylül 2019.
- Rodellar, J., Alférez, S., Acevedo, A., Molina, A., Merino, A. (2018). Image Processing And Machine Learning in the Morphological Analysis of Blood Cells. *International journal of laboratory hematology*, 40 (S1), 46-53.
- Rodriguez, M. Z., Comin, C. H., Casanova, D., Bruno, O. M., Amancio, D. R., Costa, L. D. F., Rodrigues, F. A. (2019). Clustering Algorithms: A Comparative Approach. *PloS one*, 14(1), 1-34.
- Russell, S., Norvig, P. (2010). *Artificial Intelligence: A Modern Approach* (3). New Jersey: Prentice Hal.
- Sammur, C., Webb, G. I. (Eds.). (2011). *Encyclopedia of machine learning*. Springer Science & Business Media.
- Samtaş, G., Gülesin, M. (2011). Sayısal Görüntü İşleme ve Farklı Alanlardaki Uygulamaları. *Ejovoc (Electronic Journal of Vocational Colleges)*, 2(1), 85-97.
- Samuel, A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers, *IBM Journal of Research and Development*, 3(3), 210-229.

- Sarawagi, S. (2008). Information Extraction. *Foundations and Trends in Databases*, 1(3), 261-377.
- Sarcar, M. M. M., Rao, K. M., Narayan, K. L. (2008). *Computer Aided Design And Manufacturing*(1). India: PHI Learning Pvt. Ltd..
- Sarker, I. H. (2021). Deep Learning: a Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), 1-20.
- Sebestyen, A., Tyc, J. (2020, September). Machine Learning Methods in Energy Simulations for Architects and Designers. *38th eCAADe*, Alanya, 16-17 Eylül 2020.
- Seker, S. E. (2015). Doğal Dil İşleme (Natural Language Processing). *YBS Ansiklopedi*, 2(4), 14-31.
- Sen, P. C., Hajra, M., Ghosh, M. (2020). Supervised Classification Algorithms in Machine Learning: a Survey and Review. *First International Conference on Emerging Technology in Modelling and Graphics*, India, 6-8 Eylül 2018.
- Seyyarer, E., Ayata, F., Uçkan, T., Karci, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kıyaslanması. *Computer Science*, 5(2), 90-98.
- Shafavi, S. N. S., Dehnavi, A. N., Zomorodian, Z. S., Tahsildoost, M., Korsavi, S. S., Mohaghegh, S. (2023). Façade Design of Side-Lit Spaces for Different Climates and Surroundings by Machine Learning and NSGAIII. *Building and Environment*, 245, 1-17.
- Shinde, P. P., Shah, S. (2018). a Review of Machine Learning and Deep Learning Applications. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, India, 16-18 Ağustos 2018.
- Singaravel, S., Suykens, J., Geyer, P. (2018). Deep-Learning Neural-Network Architectures and Methods: Using Component-Based Models in Building-Design Energy Prediction. *Advanced Engineering Informatics*, 38, 81-90.
- Singh, M. M., Deb, C., Geyer, P. (2022). Early-Stage Design Support Combining Machine Learning and Building Information Modelling. *Automation in Construction*, 136, 1-18.
- Solyali, D. (2020). a Comparative Analysis of Machine Learning Approaches for Short-/Long-Term Electricity Load Forecasting in Cyprus. *Sustainability*, 12(9), 1-34.
- Srivastava, S., Chakraborty, C., Sarkar, M. K. (2024). Leveraging Machine Learning And Dimensionality Reduction For Sports And Exercise Sentiment Analysis. *Measurement: Sensors*, 33, 1-9.

- Sun, C., Zhou, Y., Han, Y. (2022). Automatic Generation of Architecture Facade for Historical Urban Renovation Using Generative Adversarial Network. *Building and Environment*, 212, 1-13.
- Sun, M., Zhang, F., Duarte, F., Ratti, C. (2022). Understanding Architecture Age and Style Through Deep Learning. *Cities*, 128, 1-13.
- Şahinaslan, E., Günerkan, M., Şahinaslan, Ö. (2023). Makine Öğrenmesinde Kategorik Veri Kodlama Tekniğinin Kullanımına Alternatif Bir Çözüm Yöntemi. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 1-11.
- Şen, Z. (2004). *Yapay Sinir Ağları* (1). İstanbul: Su Vakfı.
- Takhmasib, M., Lee, H. J., Yi, H. (2023). Machine-Learned Kinetic Façade: Construction and Artificial Intelligence Enabled Predictive Control for Visual Comfort. *Automation in Construction*, 156, 1-24.
- Takizawa, A., Furuta, A. (2017). 3D Spatial Analysis Method with First-Person Viewpoint by Deep Convolutional Neural Network with Omnidirectional RGB and Depth Images, *35th International Conference on Education and Research in Computer Aided Architectural Design in Europe (eCAAD)*, İtalya, 20-22 Eylül 2017.
- Tamke, M., Nicholas, P., Zwierzycki, M. (2018). Machine Learning for Architectural Design: Practices and Infrastructure. *International Journal of Architectural Computing*, 16(2), 123-143.
- Tang, J., Hong, M., Zhang, D. L., Li, J. (2008). *Emerging Technologies of Text Mining: Techniques and Applications* (1) (1-33). Pensilvanya: IGI Global.
- Tiwari, A. (2022). Supervised Learning: From Theory to Applications. Pandey, R., Khatri, S. K., Singh, N. K., Verma, P. (Ed.), *Artificial Intelligence and Machine Learning for EDGE Computing* (1) (23-32). Cambridge: Academic Press.
- Tungut, H. B. (2022). *Algoritma ve Programlama Mantığı* (18). İstanbul: Kodlab.
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433-460.
- Urbiet, M., Urbiet, M., Laborde, T., Villarreal, G., Rossi, G. (2023). Generating BIM Model From Structural and Architectural Plans Using Artificial Intelligence. *Journal of Building Engineering*, 78, 1-20.
- URL-1: <https://www.techcareer.net/blog/computer-vision-nedir-nerelerde-kullanilir>, (Ziyaret tarihi: 27 Nisan 2024).
- URL-2: <https://www.ibm.com/topics/machine-learning>, (Ziyaret tarihi: 24 Nisan 2024).

- URL-3:<https://learn.microsoft.com/en-us/dotnet/machine-learning/resources/tasks>, (Ziyaret tarihi: 27 Nisan 2024).
- URL-4: <https://www.seldon.io/machine-learning-optimisation> (Ziyaret tarihi: 26 Mayıs 2024).
- URL-5:<https://www.analyticsvidhya.com/blog/2019/08/11-important-model-evaluation-error-metrics/> (Ziyaret tarihi: 26 Mayıs 2024).
- URL-6: <https://medium.com/@sevgicann.kilic/makine-%C3%B6%C4%9Freniminde-de%C4%9Ferlendirme-metrikleri-a024a2426809> (Ziyaret tarihi: 26 Mayıs 2024).
- URL-7:<https://www.folio3.ai/blog/object-recognition-explained/> (Ziyaret tarihi: 26 Mayıs 2024).
- URL-8:<https://medium.com/@venunagender2111/what-is-machine-learning-0583ca054e52>, (Ziyaret tarihi: 27 Nisan 2024).
- URL-9:<https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>, (Ziyaret tarihi: 27 Nisan 2024).
- URL-10:<https://karmaadvisory.com/deep-learning-basics/>, (Ziyaret tarihi: 28 Nisan 2024).
- URL-11:<https://medium.datadriveninvestor.com/machine-learning-in-10-minutes-354d83e5922e>, (Ziyaret tarihi: 1 Mayıs 2024).
- Ustalar, A., Şentürk, A., Eler, N. (2023). Spor Bilimlerinde Yapay Zekâ Kullanım Alanları. Akın, S., Erzeybek, M. S., (Ed.), *Küreselleşen Dünyada Spor Bilimleri II* (1) (19-36). İzmir: Duvar Yayınları.
- Uzun, C., Cangür, R. E. (2023). An Ontological Assessment Proposal for Architectural Outputs of Generative Adversarial Network. *Construction Innovation*.
- Uzun, C., Çolakoğlu, M. (2019). Architectural Drawing Recognition-A Case Study for Training the Learning Algorithm with Architectural Plan and Section Drawing Images, *37th eCAADe and the 23rd SIGraDi*, Portekiz, 11-13 Eylül, 2019.
- Van Der Maaten, L., Postma, E. O., van den Herik, H. J. (2009). Dimensionality Reduction: A Comparative Review. *Journal of Machine Learning Research*, 10(66-71), 1-22.
- Vatansever, B., Aydın, H., Çetinkaya, A. (2021). Genetik Algoritma Yaklaşımıyla Öznitelik Seçimi Kullanılarak Makine Öğrenmesi Algoritmaları ile Kalp Hastalığı Tahmini. *Journal of Science, Technology and Engineering Research*, 2(2), 67-80.

- Venkatraj, V., Dixit, M. K., Yan, W., Caffey, S., Sideris, P., Aryal, A. (2023). Toward the Application of a Machine Learning Framework for Building Life Cycle Energy Assessment. *Energy and Buildings*, 297, 1-14.
- Vergunova, N., Blinova, M. (2018). CAD/CAM/CAE-Systems in Design of Architectural Environment. *Architectural Studies*, 4(1), 111-116.
- Vieira, S., Pinaya, W. H. L., Mechelli, A. (2020). Main Concepts in Machine Learning. Mechelli, A., Vieira, S. (Ed.), *Machine Learning* (1) (21-44). Cambridge: Academic Press.
- Wang, L., Liu, J., Zeng, Y., Cheng, G., Hu, H., Hu, J., Huang, X. (2023). Automated Building Layout Generation Using Deep Learning and Graph Algorithms. *Automation in Construction*, 154, 1-21.
- Wang, W., Lin, Q., Chen, J., Li, X., Sun, Y., Xu, X. (2021). Urban Building Energy Prediction at Neighborhood Scale. *Energy and Buildings*, 251, 1-14.
- Wang, Y., Cui, Z., Ke, R. (2023). *Machine Learning for Transportation Research and Applications* (1) (25-40). Amsterdam: Elsevier.
- Wilkinson, S., Hanna, S., Hesselgren, L., Mueller, V. (2013). Inductive Aerodynamics, *31st International Conference on Education and research in Computer Aided Architectural Design in Europe (eCAAD)*, Hollanda, 18-20 Eylül 2013.
- Wu, N. H., Dimopoulou, M., Hsieh, H. H., Chatzakis, C. (2019). Rawbot-a Digital System for AR Fabrication of Bamboo Structures Through the Discrete Digitization of Bamboo, *37th eCAADe and the 23rd SIGraDi*, Portekiz, 11-13 Eylül 2019.
- Xiang, L., Cai, M., Ren, C., Ng, E. (2021). Modeling Pedestrian Emotion in High-Density Cities Using Visual Exposure and Machine Learning: Tracking Real-Time Physiology and Psychology in Hong Kong. *Building and Environment*, 205, 1-15.
- Xu, R., Wunsch, D. (2005). Survey Of Clustering Algorithms. *IEEE Transactions On Neural Networks*, 16(3), 645-678.
- Yan, S., Zhang, Y., Sun, H., Wang, A. (2023). a Real-Time Operational Carbon Emission Prediction Method for the Early Design Stage of Residential Units Based on a Convolutional Neural Network: a Case Study in Beijing, China. *Journal of Building Engineering*, 75, 1-13.
- Yang, X. S. (2019). *Introduction to Algorithms for Data Mining and Machine Learning* (1) (1-18). Cambridge: Academic Press.
- Yergök, D., Acı, M. (2019). Toplu Yemek Üretiminde Günlük Talep Tahmini için Alternatif Bir Yaklaşım: Öğrenci Regresyon. *Avrupa Bilim ve Teknoloji Dergisi*, 64-73.

- Yetkin, O., Gönenç Sorguç, A. (2019). Design Space Exploration of Initial Structural Design Alternatives via Artificial Neural Networks, *37th eCAADe and the 23rd SIGraDi*, Portekiz, 11-13 Eylül 2019.
- Yoon, Y. R., Lee, Y. R., Kim, S. H., Kim, J. W., Moon, H. J. (2022). a Non-Intrusive Data-Driven Model for Detailed Occupants' Activities Classification in Residential Buildings Using Environmental and Energy Usage Data. *Energy and Buildings*, 256, 1-14.
- Zhang, H., Yu, T. (2020). Taxonomy of Reinforcement Learning Algorithms. Dong, H., Ding, Z., Zhang, H. (Ed.) *Deep Reinforcement Learning: Fundamentals, Research and Applications* (1) (125-133). Singapore: Springer.
- Zhang, H., Zhang, L., Jiang, Y. (2019). Overfitting and Underfitting Analysis for Deep Learning Based End-to-end Communication Systems, *2019 11th International Conference on Wireless Communications and Signal Processing*, Çin, 23-25 Ekim 2019
- Zhang, H.K., Qiu, S., Suh, J. W., Luo, D., Zhu, Z. (2024) *Machine Learning and Deep Learning in Remote Sensing Data Analysis*, Elsevier, <https://www.sciencedirect.com/science/article/pii/B9780443132209000081> (Ziyaret tarihi: 26 Mayıs 2024).
- Zhang, Q., Yang, L. T., Chen, Z., Li, P. (2018). A Survey On Deep Learning for Big Data. *Information Fusion*, 42, 146-157.
- Zhang, R., Liu, D., Shi, L. (2022). Thermal-Comfort Optimization Design Method for Semi-Outdoor Stadium Using Machine Learning. *Building and Environment*, 215, 1-20.
- Zhang, Y., Xiao, B., Al-Hussein, M., Li, X. (2022). Prediction of Human Restorative Experience for Human-Centered Residential Architecture Design: a Non-Immersive VR-DOE-Based Machine Learning Method. *Automation in Construction*, 136, 1-18.
- Zheng, H., Moosavi, V., Akbarzadeh, M. (2020). Machine Learning Assisted Evaluations in Structural Design and Construction. *Automation in Construction*, 119, 1-17.
- Zheng, H., Yuan, P. F. (2021). a Generative Architectural and Urban Design Method Through Artificial Neural Networks. *Building and Environment*, 205, 1-16.
- Zhu, X. J. (2005). Semi-supervised Learning Literature Survey. *University of Wisconsin-Madison Department of Computer Sciences*, 1530, 1-39.
- Zou, H., Ge, J., Liu, R., He, L. (2023). Feature Recognition of Regional Architecture Forms Based on Machine Learning: a Case Study of Architecture Heritage in Hubei Province, China. *Sustainability*, 15(4), 1-27.

KİŞİSEL YAYIN VE ESERLER

Topuz, B., Alp, N. Ç. (2023). Machine Learning in Architecture, *Automation in Construction*, 154, 1-15.



ÖZGEÇMİŞ

Beyza Topuz lise öğrenimini Başiskele Anadolu Lisesi'nde okul birinciliği ile tamamlayarak 2017 yılında Kocaeli Üniversitesi Mimarlık ve Tasarım Fakültesi Mimarlık Bölümü'nü kazandı. Lisans döneminde Mimarlıkta Sayısal Tasarım Kulübü'nün kurucu başkanı olarak öğrenci kulübü organizasyonlarında görev aldı. 2021 yılında mimarlık bölümünden mezun olarak, 2022 yılında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Mimarlık Anabilim Dalı'nda Yüksek Lisans eğitiminde başladı. Yüksek lisans sürecinde mimarlık ve makine öğrenmesi üzerinde çalışmalar yapmıştır.

