İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İNŞAAT PROJELERİNİN KONSEPT AŞAMASINDA ÖN MALİYET TAHMİN MODELİ ÖNERİSİ

YÜKSEK LİSANS TEZİ

Serdar TANRIKULU

İnşaat Mühendisliği Anabilim Dalı

Yapı İşletmesi Programı

HAZİRAN 2026

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İNŞAAT PROJELERİNİN KONSEPT AŞAMASINDA ÖN MALİYET TAHMİN MODELİ ÖNERİSİ

YÜKSEK LİSANS TEZİ

Serdar TANRIKULU
(501221110)

İnşaat Mühendisliği Anabilim Dalı

Yapı İşletmesi Programı

Tez Danışmanı: Prof. Dr. Gül POLAT TATAR
Eş Danışman: Dr. Kerem PEKER

HAZİRAN 2026

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

A PROPOSED PRELIMINARY COST ESTIMATION MODEL FOR CONSTRUCTION PROJECTS AT THE CONCEPTUAL STAGE

M.Sc. THESIS

Serdar TANRIKULU
(501221110)

Department of Civil Engineering

Construction Management Programme

Thesis Advisor: Prof. Dr. Gül POLAT TATAR
Thesis Co-Advisor: Dr. Kerem PEKER

JUNE 2026

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501221110 numaralı Yüksek Lisans Öğrencisi Serdar TANRIKULU, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "İNŞAAT PROJELERİNİN KONSEPT AŞAMASINDA ÖN MALİYET TAHMİN MODELİ ÖNERİSİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı :	**Prof. Dr. Gül POLAT TATAR** İstanbul Teknik Üniversitesi	.....
Eş Danışman :	**Dr. Kerem PEKER** Erdemli Proje Müşavirlik San. Tic. Ltd. Şti.	.....
Jüri Üyeleri :	**Doç. Dr. Atilla DAMCI** İstanbul Teknik Üniversitesi	.....
	Doç. Dr. Onur Behzat TOKDEMİR İstanbul Teknik Üniversitesi	.....
	Prof. Dr. Aslı Pelin GÜRGÜN Yıldız Teknik Üniversitesi	.....

Teslim Tarihi : 07 Mayıs 2026
Savunma Tarihi : 04 Haziran 2026

En Değerli Hazinem Olan Aileme,

ÖNSÖZ

Yüksek lisans eğitimim süresince bilgi ve deneyimlerini benimle paylaşan, her aşamada yol gösterici olan değerli tez danışmanım Prof. Dr. Gül Polat Tatar'a ve yüksek lisans eğitimime başlamama vesile olan değerli eş danışmanım Dr. Kerem Peker'e içten teşekkürlerimi sunarım.

Tez sürecinde ihtiyaç duyduğum çalışma esnekliğini sağlayan başta Kriko.io şirketine ve kurucusu sevgili Uğur Eskici'ye; bu süreçte tez çalışmalarıma zaman ayırabilmem için iş yükünü paylaşarak bana destek olan değerli ekip arkadaşlarım Buğra Sözer ve Ahsen Yıldırım'a, bununla birlikte tüm çalışma arkadaşlarıma destekleri için teşekkürlerimi sunarım.

Süreç boyunca her zaman yanımda olan, ihtiyaç duyduğum her an desteğini esirgemeyen ve motivasyonumu yüksek tutmamda önemli katkı sağlayan sevgili Melisa Özgür'e ve değerli arkadaşlarıma teşekkür ederim.

Son olarak, hayatım boyunca her koşulda yanımda olan, beni her zaman destekleyen ve bugünlere gelmemde en büyük pay sahibi olan sevgili annem Şükran Tanrıkulu'na; bana her zaman güç veren, hem babalık hem de ağabeylik yaparak hayatımda çok özel bir yere sahip olan değerli ağabeyim Ercan Tanrıkulu'na en içten teşekkürlerimi sunarım. İyi ki varsınız.

Haziran 2026

Serdar Tanrıkulu
(Veri ve İçgörü Danışmanı)

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **ix**
İÇİNDEKİLER ..... **xi**
KISALTMALAR ..... **xiii**
SEMBOLLER ..... **xv**
ÖZET ..... **xxi**
SUMMARY ..... **xxiii**
1. GİRİŞ **1**
2. İNŞAAT PROJELERİNİN GENEL ÖZELLİKLERİ **3**
3. İNŞAAT SEKTÖRÜ VE MALİYET TAHMİNİ KAVRAMI **7**
3.1 İnşaat Sektöründe Maliyet Tahmini 7
3.2 Uluslararası İnşaat Projelerinde Maliyet Tahmin Stratejileri 9
3.3 Türk İnşaat Sektöründe Maliyet Tahmin Stratejileri 10
3.4 Maliyet Tahmin Süreçleri 13
4. ÖN MALİYET TAHMİN SÜRECİ **19**
4.1 Maliyet Tahmin Yöntemleri 20
4.1.1 İstatistiksel yöntemler 21
4.1.2 Analojiye dayalı yöntemler 23
4.1.3 Analitik yöntemler 24
4.1.4 Yapay zekâ ve makine öğrenmesi yöntemleri 25
4.1.4.1 Denetimli öğrenme: 28
4.1.4.2 Denetimsiz öğrenme: 29
4.1.4.3 Pekiştirmeli öğrenme: 29
5. ARAŞTIRMA METODOLOJİSİ **31**
5.1 Regresyon Analizi 31
5.2 Decision Tree (DT): 33
5.3 Random Forest(RF): 34
5.4 Support Vector Regression (SVR): 36
5.5 Polynomial Regression 37
5.6 R^2 ve MSE 38
6. ÖN MALİYET TAHMİNİ İÇİN BİR MODEL ÖNERİSİ **41**
6.1 Modelin Genel Yaklaşımı 41
6.2 Modelin Kapsamı ve Odak Noktası 42
6.3 Modelin Faydaları 43
6.4 Modelin Genel Yapısı 44
6.4.1 Projenin yapı tipinin belirlenmesi 44
6.4.2 Veri oluşturma ve düzenleme 44
6.4.3 Parametre seçimi 45

6.4.4 Modelleme aşaması 46
6.4.5 Değerlendirme ve model seçimi 47
6.4.6 Tahmin ve karar süreci 47
6.5 Modelin Uygulama Aşamaları 48
7. ÖN MALİYET TAHMİN MODELİNİN UYGULANMASI: KONUT PROJELERİ ÖRNEĞİ 49
7.1 Proje Kapsamının ve Türünün Tanımlanması 49
7.2 Tarihsel Veri Seti Depolama 49
7.3 Veri Temizleme ve Taşınması 51
7.3.1 Yapı yaklaşık birim maliyetleri incelenmesi: 51
7.4 Yapı Tipine Göre Parametre Seti Oluşturulması 54
7.5 Modelleme Teknikleri Kurma 57
7.6 Model Eğitimi ve Testi 58
7.7 Performans Değerlendirmesi ve Seçim 61
8. SONUÇ VE ÖNERİLER 63
KAYNAKLAR 65
ÖZGEÇMİŞ 73

KISALTMALAR

AACE : Association for the Advancement of Cost Engineering
BIM : Building Information Modeling
DT : Decision Tree
EKAP : Elektronik Kamu Alımları Platformu
ICEC : International Cost Engineering Council
MSE : Mean Squared Error
RF : Random Forest
RSS : Residual Sum of Square
SRM : Structural Risk Minimization
STK : Sivil Toplum Kuruluşları
SVM : Support Vector Machine
SVR : Support Vector Regression
TSS : Total Sum of Square
TÜİK : Türkiye İstatistik Kurumu
YFK : Yüksek Fen Kurulu
Q1 : Birinci Çeyrek Dönem
Q2 : İkinci Çeyrek Dönem
Q3 : Üçüncü Çeyrek Dönem
Q4 : Dördüncü Çeyrek Dönem

SEMBOLLER

b_0	: Sabit terim
$b_1, b_2, \ldots, b_n$	: Model katsayıları
n	: Gözlem sayısı / polinom derecesi
r	: Korelasyon katsayısı
r^2	: Belirleme katsayısı
x	: Bağımsız değişken
$x_1, x_2, \ldots, x_n$	: Bağımsız değişkenler
$x^2, x^3, \ldots, x^n$	: Bağımsız değişkenin üst terimleri
y	: Bağımlı değişken
ε	: Hata bileşeni

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : 2025 yılı yapı sınıf ve gruplarına göre m^2 birim maliyet değerleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2025). **11**
Çizelge 3.2 : Bina tiplerine ve yaşlarına göre amortisman oranları (Türkiye Cumhuriyeti Bankalar Kurulu, 1972). **13**
Çizelge 7.1 : 2011- 2025 yapı yüksekliği 21,50 m ve altındaki yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025). **53**
Çizelge 7.2 : Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025). **53**
Çizelge 7.3 : Yapı yüksekliği 30,50 m ile 51,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025). **54**
Çizelge 7.4 : Örnek eğitim verisi ve genel veri seti r^2 karşılaştırmaları. **58**
Çizelge 7.5 : Örnek test verisine göre model performansları. **58**
Çizelge 7.6 : Rastgele 10 farklı eğitim – test verisine göre model performansları. **60**
Çizelge 7.7 : Model performans sonuçları. **61**

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1 : Freiman eğrisi grafiği (Phaobunjong, 2002) **9**
Şekil 3.2 : Birim fiyatların yayınlanma süreci (Arabacı ve Duyguluer, 2011)..... **10**
Şekil 3.3 : 2025 Yılı Yapı Sınıf ve Gruplarına Göre m^2 Birim Maliyetleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2025). **12**
Şekil 3.4 : Proje süresince maliyet tahmin hatası değişimi (Dandan ve diğ, 2020). **15**
Şekil 3.5 : Bina tasarım süreci safhaları ve karar alanları (Seyyar, 2000)..... **17**
Şekil 4.1 : Makine öğrenmesi tekniklerinin ana kategorileri (Türkyılmaz, 2025).. ..... **27**
Şekil 6.1 : Model yol haritası..... **48**
Şekil 7.1 : EKAP araştırma arayüzü. **50**
Şekil 7.2 : Veri seti oluşturulması. **50**
Şekil 7.3 : Yapı yüksekliği 21,50 m ve altındaki yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025)..... **52**
Şekil 7.4 : Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025). **52**
Şekil 7.5 : Yapı yüksekliği 30,50 m ile 51,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025). **53**
Şekil 7.6 : Korelasyon matrisi. **56**
Şekil 7.7 : Yapı yüksekliği – maliyet regresyon analizi. **57**
Şekil 7.8 : İterasyonlar boyunca lineer regression, random forest, decision tree modellerine ait r^2 değişimleri..... **60**

İNŞAAT PROJELERİNİN KONSEPT AŞAMASINDA ÖN MALİYET TAHMİN MODELİ ÖNERİSİ

ÖZET

İnşaat sektörü, yüksek bütçeli projelerin yürütüldüğü, çok sayıda paydaşın yer aldığı ve belirsizlik düzeyinin yüksek olduğu dinamik bir sektördür. Bu nedenle proje maliyetlerinin doğru tahmin edilmesi; yatırım kararları, fizibilite çalışmaları, teklif hazırlık süreçleri, kaynak planlaması ve proje başarısı açısından büyük önem taşımaktadır. Özellikle proje yaşam döngüsünün başlangıç aşamalarında alınan kararların toplam maliyet üzerinde belirleyici etkisi bulunmaktadır. Ancak bu aşamalarda proje bilgilerinin sınırlı olması nedeniyle, güvenilir maliyet tahminleri yapılmasını zorlaşmaktadır. Bu durum, erken aşamada kullanılabilecek veri temelli ve sistematik tahmin modellerine olan ihtiyacı artırmaktadır.

Bu tez çalışmasının amacı, inşaat projelerinin fikir ve konsept aşamalarında kullanılabilecek makine öğrenmesi tabanlı bir ön maliyet tahmin modeli geliştirmektir. Çalışma kapsamında Türkiye'de kamuya açık kaynaklardan elde edilen konut projelerine ait veriler kullanılmış ve farklı yıllara ait proje maliyetlerinin karşılaştırılabilir hale getirilmesi amacıyla tüm maliyetler, dönüşüm katsayıları kullanarak 2025 yılına taşınmıştır. Veri setinin oluşturulması sürecinde yapı yüksekliği, kat adedi, kat alanı, asansör durumu, bodrum sayısı ve kazı derinliği gibi erken aşamada ulaşılabilir çeşitli değişkenlerden yararlanılmıştır.

Araştırmada öncelikle değişkenler ile proje maliyeti arasındaki ilişkiler korelasyon ve regresyon analizleri aracılığıyla incelenmiştir. Gerçekleştirilen ön analizler sonucunda, maliyet üzerinde açıklayıcı güce sahip olduğu değerlendirilen ve proje başlangıç aşamalarında erişilebilir nitelikte bulunan yapı yüksekliği, kat adedi, kat alanı, bodrum sayısı, asansör durumu ve kazı derinliği değişkenleri modelleme sürecinde bağımsız değişkenler olarak seçilmiştir. Daha sonra Doğrusal Regresyon, Karar Ağacı, Rastgele Orman, Destek Vektör Regresyonu ve Polinom Regresyon algoritmaları kullanılarak farklı tahmin modelleri geliştirilmiştir. Modellerin performansları Belirleme Katsayısı (R^2) ve Ortalama Karesel Hata (MSE) ölçütleri kullanılarak değerlendirilmiştir. Sonuçların belirli bir veri bölünmesine bağlı kalmaması amacıyla analizler farklı eğitim-test ayrımları üzerinden tekrar edilmiştir.

Elde edilen bulgular, yapı yüksekliği, kat adedi ve kat alanı gibi değişkenlerin proje maliyeti üzerinde önemli etkiye sahip olduğunu göstermiştir. Özellikle yapı yüksekliği değişkeni güçlü bir tahminleyici olarak öne çıkmıştır. Kullanılan modeller arasında Rastgele Orman algoritmasının en başarılı ve en dengeli sonuçları verdiği görülmüştür. Doğrusal Regresyon modeli daha istikrarlı sonuçlar üretmesine rağmen karmaşık ilişkileri açıklamada sınırlı kalmıştır. Karar Ağacı modeli bazı senaryolarda başarılı sonuçlar vermiş, ancak veri ayrımlarına karşı daha hassas davranmıştır. Destek Vektör Regresyonu

ve yüksek dereceli Polinom Regresyon modelleri ise diğer yöntemlere göre daha düşük performans göstermiştir.

Sonuç olarak bu çalışma, inşaat projelerinin erken aşamalarında kullanılabilecek hızlı, sistematik ve veri destekli bir maliyet tahmin yaklaşımı sunmaktadır. Geliştirilen modelin; yatırımcılar, yüklenici firmalar ve proje geliştiriciler açısından fizibilite değerlendirme, teklif verme ve stratejik karar alma süreçlerine katkı sağlayabileceği değerlendirilmektedir. Ayrıca çalışma, Türkiye verileri kullanılarak geliştirilen yerel ölçekte bir makine öğrenmesi uygulaması olması bakımından literatüre katkı sunmaktadır.

A PROPOSED PRELIMINARY COST ESTIMATION MODEL FOR CONSTRUCTION PROJECTS AT THE CONCEPTUAL STAGE

SUMMARY

The construction industry is a dynamic sector that involves high-budget projects, many stakeholders, and a considerable level of uncertainty. In addition, construction projects require the coordination of technical, managerial, and financial processes throughout the project lifecycle. For this reason, accurate cost estimation is important for investment decisions, feasibility studies, tender preparation, resource planning, and overall project success. Decisions made during the early stages of a project have a direct impact on total project cost, and the limited amount of available information during these stages makes reliable cost estimation more difficult Therefore, there is an increasing need for systematic and data-driven models that can support decision-making during the early stages of construction projects.

Traditional cost estimation methods in the construction sector are generally based on expert opinion, historical comparisons, unit cost calculations, and statistical evaluations. Although these methods may provide useful results in some situations, they may remain limited when project data become more complex and relationships between variables are not linear. In recent years, developments in artificial intelligence and machine learning have created new opportunities in this field. Machine learning algorithms can learn patterns from historical data, identify hidden relationships among variables, and generate predictions for future cases. As a result, machine learning-based approaches have become increasingly important in construction cost estimation studies.

The main purpose of this thesis is to develop a machine learning-based preliminary cost estimation model that can be used during the idea and conceptual stages of construction projects. The study mainly focuses on the early project phases, where available information is limited but important decisions still need to be made. A reliable estimation model at this stage may provide useful support for investors, contractors, consultants, and project developers.

Within the scope of the study, residential project data obtained from publicly available sources in Türkiye were used. Since the project data belonged to different years, historical project costs could not be compared directly under the same economic conditions. Therefore, ın order to make project costs from different years comparable, all cost data were adjusted to the 2025 cost level by using transformation coefficients.

During the dataset creation process, variables that can generally be obtained during the early project stages were selected. These variables included several parameters that are generally accessible during the early stages of a project, such as building height, number of floors, floor area, elevator status, number of basements, and excavation depth. These parameters were preferred because they are usually known or can be approximately

determined during the conceptual design stage, and because they were commonly present across all examined projects.

At the first stage of the research, the relationships between project cost and candidate variables were examined through correlation and regression analyses. These preliminary analyses were carried out in order to understand the explanatory effect of each variable and to support the variable selection process. Based on these evaluations, building height, number of floors, floor area, number of basements, elevator status, and foundation excavation depth were selected as independent variables in the modeling stage, since they were considered relevant to project cost and were generally available during the early phases of a project.

Afterwards, several prediction models were developed by using Linear Regression, Decision Tree, Random Forest, Support Vector Regression, and Polynomial Regression algorithms. These methods were selected in order to compare the performance of different prediction approaches within the same framework.

Linear Regression was used as a reference model because of its simple structure and interpretability. Decision Tree was included because it can generate understandable rule-based decision structures and model nonlinear patterns. Random Forest was selected because it combines multiple decision trees and generally provides stronger prediction performance. Support Vector Regression was preferred due to its ability to model nonlinear relationships. Polynomial Regression was also tested in order to examine whether higher-order relationships could improve model performance.

Model performances were evaluated by using the Coefficient of Determination (R^2) and Mean Squared Error (MSE). R^2 was used to evaluate explanatory power, while MSE was used to measure prediction error. In order to avoid dependency on a single train-test split, the analyses were repeated with different training-test partitions. This approach helped to obtain more reliable and balanced results.

The findings showed that variables such as building height, number of floors, and floor area had significant effects on project cost. Among these variables, building height became the strongest single predictor. This result indicates that vertical scale and overall building size are among the main factors affecting cost in residential projects.

Among the tested algorithms, the Random Forest model produced the best and most balanced results. The model performed successfully under different data partition scenarios and showed relatively stable outputs. This finding suggests that ensemble learning approaches may provide advantages in construction cost estimation problems where variable relationships are more complex.

Linear Regression generated more stable results, but it remained limited in explaining nonlinear relationships. Although it provided interpretable outputs, its prediction performance was generally lower than Random Forest. The Decision Tree model produced successful results in some scenarios; however, it was more sensitive to changes in the data split. This indicates that single-tree structures may be less stable than ensemble-based models.

Support Vector Regression and high-degree Polynomial Regression models showed lower performance compared with the other methods. This may be related to parameter sensitivity, overfitting risk, or the structural characteristics of the dataset.

As a result, this thesis presents a fast, systematic, and data-supported cost estimation approach for the early stages of construction projects. The proposed model may provide useful support for investors, contractors, and project developers in feasibility evaluations, tender decisions, and strategic planning processes. It may also help companies reduce unnecessary bidding costs by evaluating opportunities before entering detailed tender preparation stages.

In addition, the study contributes to the literature by presenting a local machine learning application developed with Turkish construction data. Many previous studies in this field rely on international datasets or private databases, whereas this study demonstrates the applicability of machine learning methods by using publicly available national data.

Future studies may improve the proposed framework by using larger datasets, different project types, and more advanced artificial intelligence algorithms. Commercial buildings, infrastructure projects, and industrial facilities may also be examined in future research.

1. GİRİŞ

İnşaat sektörü; çok paydaşlı ve belirsizlik düzeyi yüksek projelerden oluşan, zaman zaman içerisinde risklerin de meydana geldiği, çok disiplinli, karmaşık ve dinamik bir yapıya sahiptir (Kerzner, 2017). Projelerin çok sayıda süreçten oluşması ve farklı disiplinleri bir araya getirmesi, sektörde planlama ve koordinasyon faaliyetlerini önemli hale getirmektedir. Bu nedenle projelerin teknik, yönetsel ve finansal açıdan dengeli biçimde ele alınması gerekmektedir.

Sektör, gelişmekte olan ülkelerde ulusal ekonomide değer üretiminin temel unsurlarından biri olarak görülmektedir (Okereke, 2019). Bu durum, inşaat projelerinde alınan kararların yalnızca proje ölçeğinde değil, daha geniş bir ekonomik çerçevede de önem taşıdığını göstermektedir. Özellikle yatırım kararlarının doğru verilmesi ve kaynakların verimli kullanılması sektör açısından önem arz etmektedir.

Bu yapısal özellikler ve sektörün ekonomik büyüklüğü dikkate alındığında, proje maliyetinin özellikle erken aşamalardaki fizibilite değerlendirmelerinde ve karar alma süreçlerinde kritik bir parametre olarak öne çıktığı görülmektedir (Taraf, 2024). Projenin başlangıç safhalarında maliyete ilişkin oluşturulan öngörüler, ilerleyen aşamalardaki planlamalara yön verebilmektedir. Bu nedenle erken aşamada yapılan değerlendirmeler, proje sürecinin önemli unsurlarından biri olarak kabul edilmektedir.

Nitekim maliyet tahmini, inşaat projelerinin temel bir unsurunu temsil etmekte; tahminlerin doğruluğu ve tutarlılığı proje başarısı açısından hayati önem taşımaktadır. Özellikle fizibilite ve konsept aşamalarında yapılan maliyet tahminleri, yatırımın gerçekleştirilip gerçekleştirilmeyeceği kararında kritik rol oynamaktadır (Elmousalami, 2020). Bunun yanında, maliyet tahminleri bütçe planlaması, kaynak kullanımı ve genel proje organizasyonu açısından da karar vericilere katkı sağlayabilmektedir.

Maliyet tahminlerinin doğruluğu; bütçe aşımlarının önlenmesi, teklif stratejilerinin belirlenmesi ve proje başarısının sağlanması açısından hayati önem taşımaktadır (Sayed, ve diğ, 2023). Ancak proje başlangıç aşamalarında bilgi düzeyinin sınırlı olması, maliyet tahmin sürecini zorlaştırabilmektedir. Bu nedenle mevcut verilerden yararlanarak daha sistematik yaklaşımlar geliştirilmesi önem taşımaktadır.

Bu çalışmanın amacı, inşaat projelerinin fikir ve konsept aşamalarında kullanılabilecek, veri temelli bir ön maliyet tahmin modeli geliştirmektir. Çalışmada, geleneksel yöntemlerin sınırlılıkları dikkate alınarak, makine öğrenmesi temelli bir yaklaşım önerilmiş ve erken aşama karar süreçlerine analitik bir destek mekanizması sunulması hedeflenmiştir. Böylece proje paydaşlarının daha hızlı, daha tutarlı ve daha sağlıklı maliyet öngörüleri oluşturabilmesine katkı sağlanması amaçlanmaktadır.

2. İNŞAAT PROJELERİNİN GENEL ÖZELLİKLERİ

Türk Dil Kurumuna (2020)'e göre inşaat, "yapma işi, yapım" olarak tanımlamıştır. Geçmişten günümüze, barınma, yerleşik hayata geçme ve ulaşım gibi ihtiyaçların var olması sebebiyle, "yapma işi" ve "yapım" yani inşaat kavramı hep var olmuştur. Medeniyetin ilerlemesiyle bu ihtiyaçlar artmış ve günümüzde ise birçok farklı çeşide sahip bir yapıya bürümüştür.

İnşaat yapım işleri; bina ve endüstriyel yapılar ile birlikte karayolu, demiryolu, otoyol, havalimanı, liman, rıhtım, tersane, köprü, viyadük, metro, boru iletim hatları, haberleşme ve enerji nakil hatları, barajlar, enerji üretim tesisleri, rafineri tesisleri, sulama yapıları, arazi ıslahı, taşkın kontrolü ve dekapaj çalışmaları da yapım işleri kapsamında değerlendirilip, bu projelere bağlı olarak yürütülen tesisat, imalat, hazırlık, taşıma, tamamlama, büyük onarım, restorasyon, çevre düzenlemesi, sondaj, yıkım, güçlendirme ve montaj faaliyetleri ile benzeri tüm uygulamalar olarak ifade edilmektedir (Kamu İhale Kanunu, 2002, s. 7).

İnşaat sektörü, bina ve mühendislik projelerinin planlanması ve uygulanmasını içeren geniş, karmaşık ve sürekli gelişen bir sektördür. Yeni gelişmelerin yanı sıra, inşaat faaliyetleri mevcut yapıların ve mühendislik çalışmalarının genişletilmesi, tadilatı, bakımı ve onarımı gibi yenileme süreçlerini de içerir (Çelik ve diğ, 2017). Ek olarak inşaat sektörü, birden fazla sektöre istihdam sağlayıp, ekonomik olarak ise günümüzdeki yapısıyla birlikte önemli bir yere sahip olmuştur. 2023 yılına ait TÜİK verilerine göre Türkiye'de inşaat sektörü Gayri Safi Milli Hasılanın %5,5'unu oluştururken, AB-27 ülkelerinde ise bu oran %5,7'dir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2024). Sektör, bir ülkenin ekonomik büyüme ve kalkınma sürecinde stratejik bir rol üstlenmekte olup, Aralık 2019 itibarıyla Mısır ekonomisinde önemli bir pay ile toplam Gayri Safi Milli Hasılanın yaklaşık %8'ini oluşturmaktadır (Sayed ve diğ, 2023).

İnşaat projeleri, bir fikir olarak ortaya çıkan ve fikrin adım adım olgunlaştığı sürecin sonunda, kullanılan ve hizmet veren bir yapıya dönüşümünü kapsayan projelerdir. Çok

disiplinli organizasyon ve koordinasyona, karmaşık ve özgün bir sürece, belirsiz ve dinamik bir yapıya sahip olan inşaat projeleri bu özellikleriyle diğer sektörlerden ayrışmakta, olup kendine özgün bir yapıya sahiptir. İnşaat projeleri; zaman içerisinde risklerin meydana geldiği, benzersiz, belirsiz ve içerisinde çok sayıda paydaşın bulunduğu projeler olarak kabul görmektedir (Kerzner, 2017).

İnşaat projelerinin geliştirme sürecinde yürütülen faaliyetler çoğu zaman çevresel açıdan istenmeyen çeşitli olumsuzluklar ortaya çıkarmaktadır. Özellikle nüfus yoğunluğunun yüksek olduğu kentsel bölgelerde, inşaat çalışmaları çevrede yaşayan bireyler ve faaliyet gösteren işletmeler açısından ciddi rahatsızlıklara neden olabilmektedir. Bu rahatsızlıkların düzeyi büyük ölçüde projenin konumuna bağlı olup, yoğun nüfuslu alanlarda gerçekleştirilen projelerin, nüfus yoğunluğunun daha düşük olduğu bölgelerde yürütülen projelere kıyasla daha belirgin olumsuz etkiler oluşturduğu görülmektedir (Çelik ve diğ, 2017).

İnşaat sektöründe, belirli bir proje kapsamında, onaylı plan, proje ve şartnamelere bağlı kalarak, belirli bir bedel üzerinden yapım işini üstlenen ve bu işi işveren denetimi ile hali hazırda yürürlükte bulunan mevzuata, mühendislik kurallarına ve standartlara uygun olacak bir şekilde tamamlayıp, sözleşmede tanımlanan süre sonuna kadar projeyi kapsamları dahilinde teslim etmeyi kabul eden firmalara yüklenici firmalar denmektedir. Yüklenici firmalar sözleşmelerinde yazılan bedeli, işverenin teslimi kabul etmesi sonrası hak etmektedir. Bu kuruluşların devamlılığı üstlendikleri projelerin sürekliliğiyle belirlenip, asıl amaçları sadece projeyi teslim etmek olmayıp, sözleşmelere, şartnamelere, belirlenen bütçeye ve süreye sadık kalarak bu süreci tamamlayabilmektir. Bu nedenle, bu kuruluşların ihale dokümanlarını temin etme aşamasından teklif hazırlama süreci içerisindeki çalışmaları, proje başarısını doğrudan etkileyen kritik bir öneme sahiptir (Türkiye Borçlar Kanunu, 2011; Huang, 2011).

İnşaat projelerinde, yaşam döngüsünün her adımı önemli olup, projenin başarısı bu döngünün başarısıyla doğrudan ilişkilidir. Yaşam döngüsünün adımları sırasıyla konsept, fizibilite, mühendislik ve dizayn, tedarik ve ihale, yapım, devreye alma (başlatma), işletme ve kullanım olarak özetlenebilmektedir. İlk aşamalarda, yapılacak yatırımın firma açısından sağlayacağı faydalar analiz edilmekte, yatırım kararı alınmakta ve buna bağlı

olarak teklif dokümanları hazırlanarak sunulmaktadır. Teklif kabulü sonrası, proje kapsamına göre, tüm mühendislik ile tasarım sürecine geçilmektedir. Tasarım aşaması sonrası, projenin hayata geçirildiği inşaat, imalat ve devreye alma faaliyetlerini içeren uygulama aşaması başlamaktadır. Bu sürecin sonunda, ortaya çıkan nihai yapı işverene teslim edilecek duruma gelmektedir. Kesin kabul ve sonrası olarak tanımlanan son aşamada ise, yapının işverene resmi olarak teslim edilmesiyle birlikte proje yaşam döngüsü tamamlanmaktadır. Proje yaşam döngüsünün tüm aşamalarında, bütçe, süre ve kalite hedefleri arasında dengeli bir yönetim sağlanması projenin başarısıyla doğrudan ilişkilidir (Taraf, 2024).

Bu tez kapsamında projenin başlangıç aşamalarına dahil olan fikir ve konsept aşamalarındaki detaylara göre, iş veren için yapılacak yatırımın tahmini maliyeti ile bu aşamadaki fikrin projelendirip projelendirilmeme kararına, teklif verecek firmalar için ise benzer şekilde tahmini maliyet hesabı ile firma içerisinde teklif verme ve ihale sürecine hazırlanıp hazırlanmama kararlarına yardımcı olabilecek bir ön maliyet tahmin modelinin geliştirilmesi amaçlanmaktadır. İnşaat sektörünün dinamik bir sektör olması ve iş gücünün önemi düşünüldüğünde oluşturduğumuz bu modelin sektör için hızlı karar alma ve iş gücünden tasarrufa destek sağlayacağı düşünülmektedir.

3. İNŞAAT SEKTÖRÜ VE MALİYET TAHMİNİ KAVRAMI

3.1 İnşaat Sektöründe Maliyet Tahmini

Maliyet, bir ürün veya hizmetin üretilebilmesi için gerekli üretim faktörlerine yapılan tüm harcamaların toplamı olarak tanımlanabilir (Kuruoğlu ve diğ, 2014). Mobilya üretimi yapmak amacıyla inşa edilecek tesis için; çimento, agrega, cıvata, çelik, iş gücü ve enerji gibi tüm girdilerin parasal değeri maliyeti oluşturmaktadır. Bir son ürünün meydana gelmesi, yani bir üretim gerçekleşebilmesi için bir süreç ve bu süreçte kullanılacak kaynaklar gerekmektedir. Ortaya çıkan ürünün maliyeti, kullanılan kaynaklarla doğrudan bağlantılıdır. Sınırlı kaynakların mevcudiyeti ise kaynak kullanımının verimli hale getirilmesini durumunu ortaya çıkarmıştır. Bu durum, maliyet tahminin yapılması ve buna göre süreçlerin izlenmesi gerektiğini göstermiştir (Seyyar, 2000).

Dönemler boyunca bir yapı inşa edilmeden önce proje sonunda yapının ne kadara mal olacağını bilmek istenmektedir. Kaynak kıtlığı kritik bir durum olmadığı 19. Yüzyıl başlarına kadar, kaba bir maliyet tahmini bu ihtiyacı karşılamaktaydı. Fakat endüstri devriminin etkisiyle maliyet tahmini basit bir durum olmaktan çıkmış ve maliyet tahminine verilen önem artmaya başlamıştır (Giritli & Yaman, 1993). Böylelikle maliyet tahminleri ayrı bir parantezde incelenmeye başlanmış ve gelişimini günümüze kadar sürdürmeye devam ettirmiş ve hala da devam ettirmektedir. Özellikle gelişmekte olan ülkelerde inşaat sektörü, ulusal ekonomide değer üretiminin temel unsurlarından biri olarak görülmekte ve toplumda sosyal ile ekonomik yaşam koşullarının iyileştirilmesine katkı sağlayarak yaşam kalitesinin artırılmasında önemli bir rol üstlenmektedir (Okereke, 2019).

Maliyet tahmini, bir inşaat projesinin belirlenen amaçlarını öngörülen süre içerisinde gerçekleştirebilmesi için gerekli olan faaliyetlere ilişkin finansal büyüklüklerin tahmin edilmesini kapsayan bir süreçtir. İnşaat sektörü açısından temel bir işlev niteliği taşıyan bu süreç, maliyetlerin etkin biçimde yönetilmesine olanak tanıyarak projelerin planlanan

bütçe sınırları içinde tamamlanmasına katkı sağlamakta ve bu yönüyle proje başarısında belirleyici bir rol üstlenmektedir (Sayed ve diğ, 2023).

Maliyet tahmini, inşaat projelerinin temel bir unsurunu temsil eder; çünkü proje maliyeti, erken aşamalardaki fizibilite değerlendirmelerinde ve karar alma süreçlerinde kritik bir parametre görevi görür. Maliyet tahminlerinin doğruluğu ve tutarlılığı, özellikle giderek kısıtlanan bütçeler bağlamında, proje başarısı için hayati önem taşır; zira maliyet aşımları önemli bir sorun olmaya devam etmektedir. Aşırı durumlarda, ilk maliyet tahminlerinden önemli sapmalar, inşaat projelerinin askıya alınmasına veya tamamen terk edilmesine neden olabilir (Elmousalami, 2020).

Maliyet tahminlerindeki hatalar, inşaat projeleri üzerinde önemli olumsuz etkilere yol açabilir; zira hatalı tahminler genellikle hem zaman hem de maliyet performansı açısından proje başarısızlığına katkıda bulunur. Proje maliyetleri fazla tahmin edildiğinde, yükleniciler aşırı yüksek ihale fiyatları sunabilir ve bu da teklifleri müşteriler için cazip olmaktan çıkarır veya kabul edilemez hale getirir. Tersine, maliyetlerin düşük tahmin edilmesi, yükleniciler için finansal kayıplara yol açabilir ve proje sahiplerini çeşitli sözleşmesel ve operasyonel zorluklarla karşı karşıya bırakabilir (Sayed ve diğ, 2023).

İnşaat sektörü, üretilen ürünün özgünlüğü ve yüksek maliyeti sebebiyle diğer sektörlerden birtakım farklılıklar barındırmaktadır. Yüksek maliyetleri içinde bulunduran bu sektördeki paydaşlar için maliyet tahmini; yönetim, sürdürülebilirlik ve verimli kaynak kullanımı için kritik bir rol oynamaktadır. (Göktürk, 2007). Ek olarak, inşaat firmaları projeleri talep edilen kaliteyi karşılayıp aynı zamanda kar dahil hesaplanan maliyet tahminine göre tamamlamak durumundadır. Hedeflere ulaşmak için güvenilir ve sağlam bir maliyet tahmini yapılması gerekmektedir. Yüklenici sınıfları için de geçerli olan bu durum sebebiyle yapılan maliyet tahmini, ihaleyi kazandıracak kadar minimum, kar sağlattıracak kadar maksimum olmalıdır (Çelik, 2006).

Maliyet tahminlerinin sonuçları proje sonu maliyetlerle karşılaştırıldığında, proje sonu maliyetine göre yüksek, düşük ya da doğru tahmin olmak üzere 3 farklı durum şeklinde sonuçlanabilmektedir. Şekil 3.1'de gösterilen Freiman eğrisi grafiğinde, bahsedilen bu 3 farklı durum ifade edilmektedir.

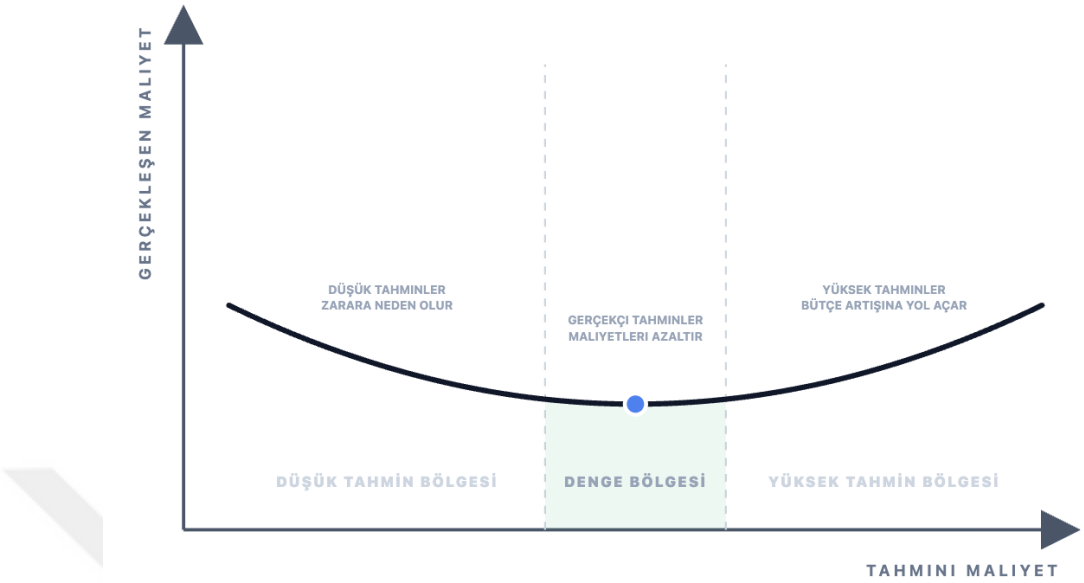

Şekil 3.1 : Freiman eğrisi grafiği (Phaobunjong, 2002).

3.2 Uluslararası İnşaat Projelerinde Maliyet Tahmin Stratejileri

Tarih boyunca birçok imparatorluk inşa ettikleri yapılar için maliyet tahmin stratejileri ve yöntemleri uygulamışlardır. Örnek olarak, Bizans döneminde Roma İmparatorluğunda hazırlanan projeler yapı karakteri, sistemi ve yapım malzemelerine göre tahmini maliyetlerinin çıkartıp, projelerle birlikte yapı sahibine sunulurken, Osmanlı İmparatorluğunda ise yapım ve onarım çalışmaları öncesinde Satraççini ve Keşif Yöntemi adında iki farklı maliyet tahmin yöntemi kullanılmıştır (Yılmaz & Dikmen, 2012).

Günümüzde gelişmekte olan veya gelişmiş olan çoğu ülkede inşaat maliyetlerini tahmin etmek amacıyla veri tabanı bulunan birçok özel ya da bağımsız kamu birimleri mevcuttur. Kamu tabanlı kaynakları kullanan ülkeler için Hindistan ve Japonya hem kamu tabanlı hem de özel kurumlar vasıtasıyla maliyet bilgileri üreten ülkeler için ABD ve İngiltere örnek olarak verilebilir. Ulusalda, “Genel İnşaat Maliyet Kılavuzu” ve “Ticari Birim Fiyat Kataloğu” kamu kurumlarınca kullanılan kaynaklardan birkaçı olmakla birlikte, özel sektörde ise Amerika tabanlı olan REED İnşaat’a ait RSMeans ve BNI ulusal ölçekte yayınlarına en önem verilen firmalar olmaktadır (Arabacı ve Duyguluer, 2011).

3.3 Türk İnşaat Sektöründe Maliyet Tahmin Stratejileri

Türkiye'de, 4734 Kamu İhale Kanuna yürürlüğe girmesi sonrası iş kalemi/iş gücü fiyatları her ne kadar yüklenici teklifi tabanında oluşturuluyor olsa da ihale öncesi kullanılan en kritik kaynak, Yüksek Fen Kurulu Başkanlığı ve Bakanlık yetkisiyle hazırlanan, her yılın başında revize edilerek yayınlanan ve 2886 sayılı Devlet İhale Kanunu'na göre ihale edilen "İnşaat ve Tesisat Birim Fiyatları ve Tarifleri" kaynağıdır (Arabacı ve Duyguluer, 2011).

"İnşaat ve Tesisat Birim Fiyatları ve Tarifleri" her geçen yıl sonunda güncellenerek ve yenilenerek yayınlanmaktadır. Bu değişimler kimi zaman birim fiyat tariflerinin değişmesiyle, kimi zaman ise yeni birim fiyat tariflerinin eklenmesiyle meydana gelmektedir. Böylelikle kütüphane sürekli güncellenmeye ve gelişmeye devam etmektedir. Bahsedilen bu güncellemeler ham madde fiyatı ve işçilik dahil çok sayıda parametreyi barındıran, bakanlığın yetkin kurumlarınca yıl süresince fiyat takibi, veri toplama, fiyat tespiti ve analiz gibi derin araştırma ve değerlendirme sonucunda meydana gelen, güvenilir ve uygulanabilir değerlerdir (Arabacı ve Duyguluer, 2011). Şekil 3.2, bir akış şeması olup, birim fiyatların yayınlanma sürecinin nasıl geliştiğini göstermektedir.

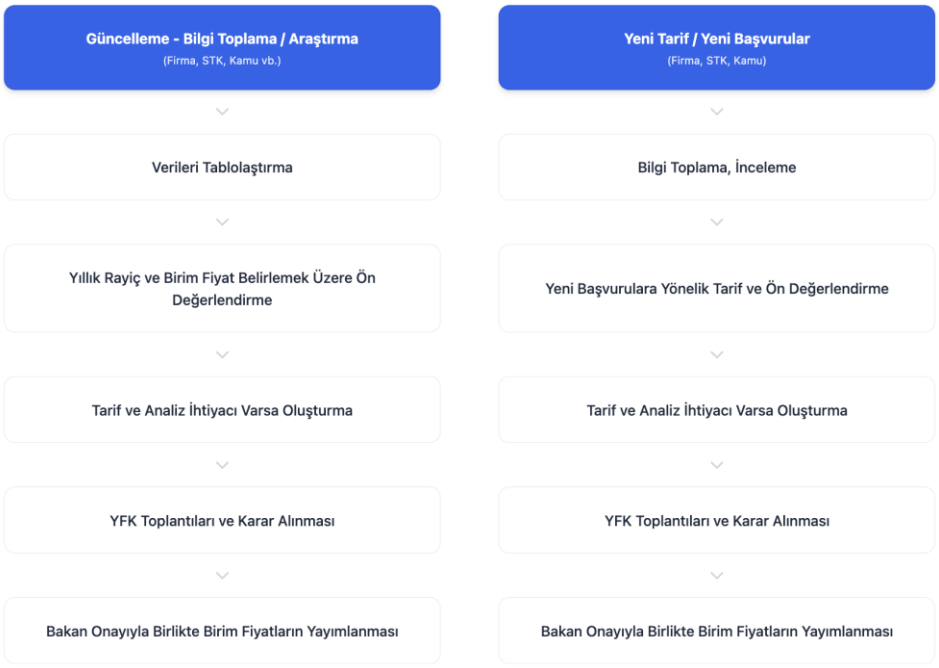

Şekil 3.2 : Birim fiyatların yayınlanma süreci (Arabacı ve Duyguluer, 2011).

Türkiye'deki maliyet tahmin yöntemleri, ICEC ülkelerinden farklı olarak, yalnızca devlet yatırımlarına odaklanan ve bina tipine göre sınıflandırılmış verilere dayanır. Türkiye'de yıllık belirlenen birim fiyatlar, önceden tanımlanmış bina tiplerinin birim alan maliyetini hesaplamak için kullanılır ve benzer tipler, farklı işlevlerine bakılmaksızın aynı maliyetle gruplandırılır. Bu durum 2025'e ait güncel verilerle Çizelge 3.1'de ve Şekil 3.3'de örneklendirilmiştir.

1985 tarihli ve 85/9707 sayılı Bakanlar Kurulu Kararıyla, "Mimarlık ve Mühendislik Hizmetleri Şartnamesi" 3.2 maddesi, mimarlık ve mühendislik hizmet bedellerinin hesaplanmasında dikkate alınacak Yapı Yaklaşık Birim Maliyetlerini düzenlemektedir. Bu maliyetler, yapıların mimari bağlı olduğu sınıf temel alınıp, inşaat genel giderleri ile yüklenici kârı dahil edilerek hesaplanmaktadır ve her yıl Çevre ve Şehircilik Bakanlığı tarafından hazırlanan bir tebliğle Resmî Gazete 'de yayımlandıktan sonra yürürlüğe girmektedir.

Yapılar, beş ana sınıfa ayrılmış olup, birinci sınıf yapılar A, B, C ve D gruplarına, ikinci, üçüncü ve dördüncü sınıf yapılar A, B ve C gruplarına, beşinci sınıf yapılar ise A, B, C, D ve E gruplarına ayrılmaktadır. Şekil 3.3'de ve Çizelge 3.1'de bu sınıflar ve gruplar görülebilmektedir. Konut yapıları genellikle üçüncü sınıf 3B ve 3C grupları ile dördüncü sınıf 4A ve 4B gruplarında yer almaktadır.

Çizelge 3.1 : 2025 yılı yapı sınıf ve gruplarına göre m^2 birim maliyet değerleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2025).

Yapı Sınıfı	Grup	Birim Maliyet (TL/m²)	Örnek Yapılar
I. Sınıf	A	₺2.100,00	Basit hayvancılık yapıları, çardaklar, plastik örtülü seralar vb.
I. Sınıf	B	₺3.050,00	Basit küçükbaş hayvan ağılları, cam seralar vb.
I. Sınıf	C	₺3.300,00	Betonarme ve kâgir su depoları, istinat duvarları vb.
I. Sınıf	D	₺3.900,00	Güneş enerji santralleri (GES) vb.
II. Sınıf	A	₺6.000,00	Deniz iskeleleri, genel amaçlı depolar, hayvan satış yerleri vb.
II. Sınıf	B	₺10.200,00	Betonarme, jeopark ve tema park yapıları, halı sahalar vb.
II. Sınıf	C	₺12.400,00	Bungalov evleri, hal binaları, sanayi tesisleri vb.
III. Sınıf	A	₺17.100,00	Aquaparklar, kayadan oyma konutlar, mahalle konakları vb.
III. Sınıf	B	₺18.200,00	Konutlar (yapı yüksekliği 21,50 m ve altı), apart oteller vb.
III. Sınıf	C	₺19.150,00	Konutlar (yapı yüksekliği 21,50 – 30,50 m arası) vb.
IV. Sınıf	A	₺21.500,00	Konutlar (yapı yüksekliği 30,50 m – 51,50 m arası) vb.
IV. Sınıf	B	₺27.500,00	Konutlar (yapı yüksekliği 51,50 m üstü) vb.
IV. Sınıf	C	₺32.600,00	Adalet sarayları, bakanlık binaları, tatil köyleri vb.
V. Sınıf	A	₺34.400,00	Büyükelçilik binaları, eğitim ve araştırma hastaneleri vb.
V. Sınıf	B	₺35.600,00	Deniz, hava ve kara kuvvetleri komutanlığı tesisleri vb.
V. Sınıf	C	₺39.500,00	Bale, opera ve tiyatro yapıları, müze yapıları vb.
V. Sınıf	D	₺43.400,00	Havalimanı terminal binaları, metro istasyonları vb.
V. Sınıf	E	₺86.250,00	Rüzgâr enerji santralleri (RES) vb.

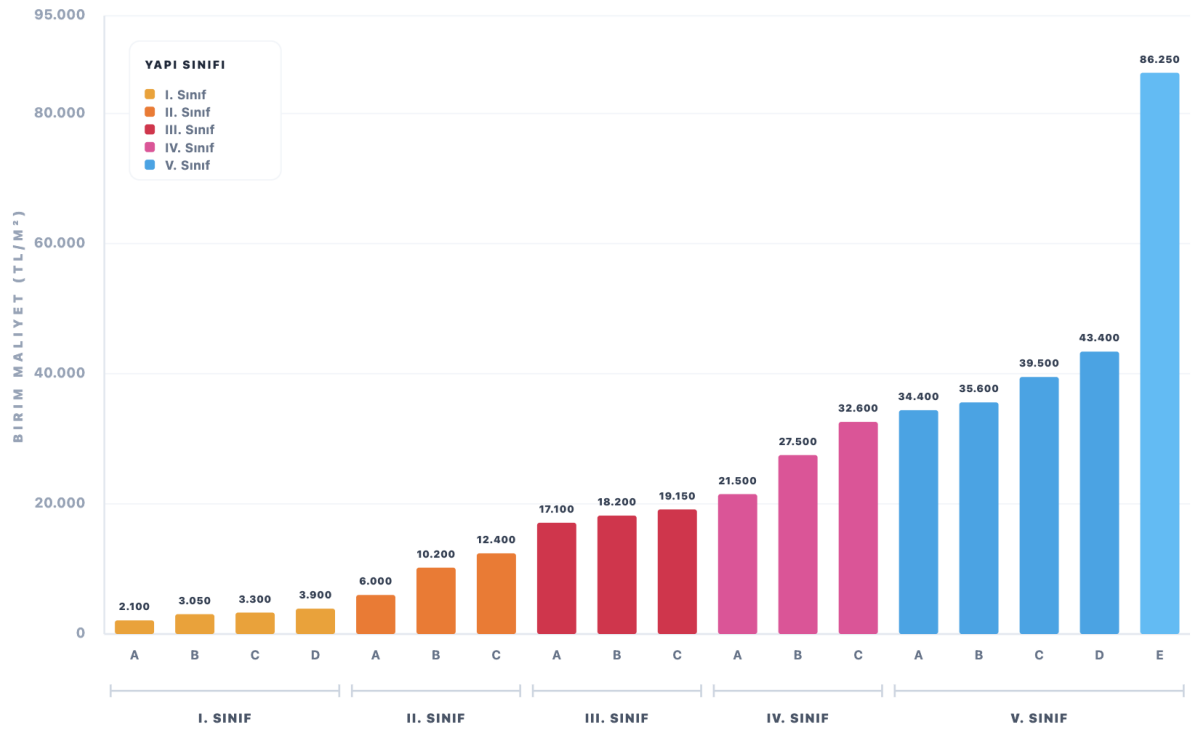

Şekil 3.3 : 2025 Yılı Yapı Sınıf ve Gruplarına Göre m^2 Birim Maliyetleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2025).

Yapılar ömrü boyunca yıpranmaktadır. Yıpranan binalar yıllara ve yıpranma oranlarına bağlı olarak değer kayıpları yaşamaktadırlar. Yapıların özellikle binalar yapım kararları alınırken sadece yapım maliyetlerine değil aynı zamanda amortisman değerlerine de bakılması önem arz etmektedir. Binalar için amortisman binaların zamana ve kullanıma bağlı olarak yıpranması ve aşınması olarak tanımlanır. Yıl bazında belirli aralıklar ile hesaplanan amortisman süresi, binalardan gider olarak düşülmektedir. Çizelge 3.2, bina tipleri ve yaşlarına göre amortisman oranlarını göstermektedir.

Bina maliyeti üç ana aşamada analiz edilir: ilk yatırım aşaması, işletme aşaması ve yıkım veya bertaraf aşaması. İlk yatırım maliyeti, ön hazırlık aşamasından işletmenin başlangıcına kadar olan tüm süreçleri kapsarken, işletme maliyeti binanın kullanım amacından kaynaklanan giderleri içerir. Toplam maliyetin nispeten küçük bir bölümünü oluşturan yıkım veya bertaraf maliyeti ise, kullanım ömrünü tamamlamış binaların kaldırılmasıyla ilgilidir. Bu nedenle, toplam bina maliyeti esas olarak ilk yatırım maliyeti ve işletme maliyetinden oluşmaktadır (Murat Akınbingöl, A. Tanju Gültekin, 2005).

Çizelge 3.2 : Bina tiplerine ve yaşlarına göre amortisman oranları (Türkiye Cumhuriyeti Bankalar Kurulu, 1972).

Yapı Türü Sınıfı	0-3 Yaş	4-5 Yaş	6-10 Yaş	11-15 Yaş	16-20 Yaş	21-30 Yaş	31-40 Yaş	41-50 Yaş	51-75 Yaş	76 ve Üzeri
Çelik karkas betonarme karkas binalar	4%	6%	10%	15%	20%	25%	30%	40%	50%	60%
Yığma kagir, yığma yarı kagir binalar	3%	4%	8%	12%	15%	20%	30%	40%	50%	70%
Ahşap, taş duvarlı (çamur harçlı gecekondular dahil) binalar	6%	8%	12%	18%	25%	32%	40%	50%	70%	90%
Kerpiç ve diğer basit binalar	8%	10%	17%	25%	35%	45%	55%	65%	75%	95%

3.4 Maliyet Tahmin Süreçleri

İnşaat sektöründe yapım maliyetlerinin yüksek seviyelerde seyretmesi ve rekabetin yoğun olması nedeniyle, özellikle bina üretimi gibi uzun süreye yayılan ve girdinin çok olduğu projelerde, nihai maliyetin mümkün olan en kısa sürede ve en yüksek doğrulukla öngörülebilmesi kritik bir gereklilik hâline gelmektedir (Göktürk, 2007).

İnşaat projesi maliyetlerinin tanımlanmış bir doğruluk eşiği içinde tahmin edilmesi gerekmektedir. Bununla birlikte, bir projenin ilk aşamalarında, tahmin doğruluğu genellikle sınırlı ön bilgiler ve mühendislikle ilgili kararlardan kaynaklanan önemli belirsizlik nedeniyle tehlikeye girer (Elmousalami, 2020). Ön tasarım aşamasından ve ihale davetiyelerinin yayınlanmasından sonra, yükleniciler ihale sürecinin bir parçası olarak detaylı maliyet tahminleri hazırlarlar. Sözleşmeyi güvence altına almak için yükleniciler hem rekabetçi hem de güvenilir teklifler sunmayı hedeflerler. Buna göre, maliyet tahmininde en yüksek doğruluk derecesini sağladıkları için detaylı maliyet tahmin yöntemleri benimsenir. Detaylı maliyet tahmininin temel amacı, inşaat projesinin gerçekleştirilmesi için gereken gerçek maliyeti belirlemektir (Sayed ve diğ, 2023).

İnşaat projelerinde maliyet tahmini genellikle iki ana yaklaşıma ayrılır: kavramsal tahmin ve detaylı tahmin. Proje kapsamı ve tanımı daha net bir şekilde belirlendikçe, tahmin yöntemleri kademeli olarak kavramsal yaklaşımlardan daha titiz, veri yoğun tekniklere doğru geçiş yapar. Projenin erken aşamalarında yapılan tahmin, mal sahibinin karar verme sürecinin kritik bir temelini oluşturduğu için özellikle önemlidir. Projenin uygulanabilirliği onaylandıktan sonra, mal sahibi genellikle fonksiyonel gereksinimleri ve

inşaat kalite standartlarını belirlemek için bir tasarım ekibi görevlendirir. Bu aşamada, genellikle konsept maliyet tahmini olarak adlandırılan yaklaşık bir proje maliyeti geliştirilir (Sayed ve diğ, 2023).

Projelerinde maliyetin belirlenmesi süreci, proje ilerleyişine bağlı olarak farklı aşamalar üzerinden yürütülmektedir. Bu çerçevede tahmin süreci üç temel safhada ele alınmaktadır: ön tahmin, ara tahmin ve final tahmin. Ön maliyet tahmini, proje başlamadan önce yapılan değerlendirmeyi ifade ederken; ara maliyet tahmini, proje uygulama sürecinde gerçekleştirilen hesaplamaları kapsamaktadır. Final maliyet tahmini ise projenin kesinleşmesinin ardından yapılan ve tasarım ile hesap çalışmalarının tamamlanmasını takiben uygulanan tahmin aşamasıdır. Bu son aşama, diğer tahmin türlerine kıyasla en güvenilir sonuçların elde edildiği safhayı temsil etmektedir (Arabacı, Duyguluer, 2011).

AACE International (2005) göre ise, proje geliştirme düzeyine bağlı olarak maliyet tahminlerini beş farklı sınıfa ayırmaktadır:

- 1.Sınıf maliyet tahmini, proje tasarımın yaklaşık %50-%100 tamamlandığında hazırlanır ve detaylı birim maliyet bilgilerine dayanır. Bu tahmin öncelikle teklif veya ihale fiyatlarını doğrulamak için kullanılır ve beklenen doğruluk aralığı %10 ile %15 arasındadır.
- 2. Sınıf maliyet tahmini, tasarımın yaklaşık %30-%70 tamamlandığında geliştirilen kesin bir tahmine karşılık gelir. 1. Sınıfa benzer şekilde, detaylı birim maliyetlere dayanır ve teklif ve ihale değerlendirmesi için bir araç görevi görür; beklenen doğruluk aralığı, %15 ile %20 arasındadır.
- 3. Sınıf maliyet tahmini, proje tasarımın yaklaşık %10-%40 tamamlandığında oluşturulan ön bir tahmini temsil eder. Bu tahmin, yarı detaylı birim maliyetlere dayanır ve genellikle bütçe onay aşamalarında uygulanır; doğruluk aralığı %20 ile %30 arasındadır.
- 4.Sınıf maliyet tahmini, tasarımın yaklaşık %1-%15 tamamlanma aşamasında üretilir ve ağırlıklı olarak parametrik modelleme tekniklerini kullanan fizibilite değerlendirmelerinde kullanılır. Bu sınıf için beklenen doğruluk aralığı %30 ile %50 arasındadır.

- 5. Sınıf maliyet tahmini, proje tasarımının %0-%2 aşamasında gerçekleştirilen konsept tahmin aşamasını ifade eder. Bu tahmin yaklaşımı, kapasite faktörlerini, uzman görüşünü, benzer proje verilerini ve parametrik modelleri içerir ve %50 ile %100 arasında değişen bir doğruluk aralığıyla yüksek derecede belirsizliği yansıtır.

Görüldüğü üzere maliyet tahminlerinin doğruluk payları ve karar süreleri birbirinden farklıdır. Güvenilirlik seviyeleri, projeyle ilgili sahip olunan detay seviyelerine göre artmakta ve en fazla detayı içeren birim fiyat metodu, en güvenilir tahmin metodu olduğu görülmektedir.

Maliyet tahmin doğruluğu, bina inşaat projelerinin farklı aşamalarıyla ilişkilendirilmiş ve her bir aşamada ortaya çıkan tahmin hatalarının değişimi gösterilmiştir. Proje süresi ilerledikçe tahmin hatalarının azalma eğilimi gösterdiği ifade edilmiştir (Şekil 3.4). Ayrıca, pozitif ve negatif hata eğrilerinin simetrik olmadığı belirtilmiştir; çünkü inşaat projelerinde özellikle malzeme ve işçilik maliyetleri azalmaktan ziyade artış yönünde değişme eğilimindedir (Dandan ve diğ, 2020).

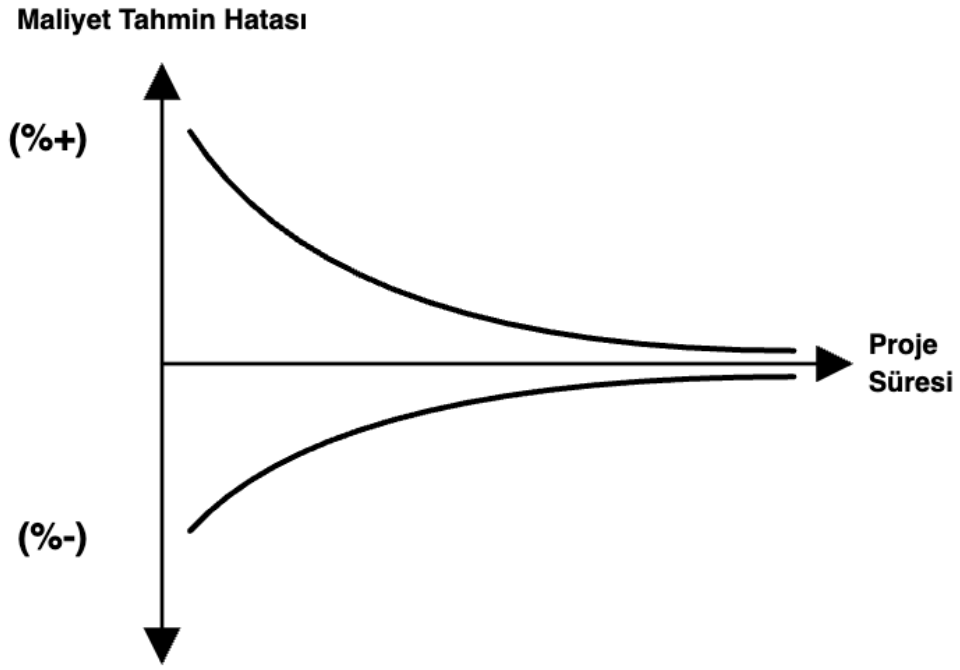

Şekil 3.4 : Proje süresince maliyet tahmin hatası değişimi (Dandan ve diğ, 2020).

İnşaat ekonomisi açısından, en kritik maliyet tahminlerinin karar verme aşamasında ortaya çıktığı genel olarak kabul edilmektedir. Bu aşamada, mal sahibinin (müşterinin) işlevsel, niteliksel ve ekonomik ihtiyaçları ve beklentileri ile bu beklentileri sınırlayan kısıtlamalar açıkça tanımlanır. Mimar için, bina müşterisinin ne kadar harcamaya istekli olduğunu belirlemek ve maliyet ile kalite faktörlerini dengelemek özellikle zorlu bir görevdir. Belirlenen ihtiyaçları karşılamak için çeşitli çözümler geliştirilir ve değerlendirilir. Kullanıcı gereksinimleri ve beklentilerinin büyük ölçüde binanın boyutunu ve kalitesini belirlediği ve maliyetin bu değişkenlerin bir fonksiyonu olduğu göz önüne alındığında, bu aşamanın önemi açıkça ortaya çıkar. Araştırmalar, toplam proje maliyetinin önemli bir bölümünün bu erken aşamada alınan kararlar tarafından belirlendiğini göstermiştir (Göktürk, 2007). Şekil 3.5'de de görüldüğü üzere, proje sürecinin ilk aşamaları olan tasarım sürecinde ihtiyaçların belirlenmesi, fizibilite analizleri, alternatif tasarım çözümleri ve bütçe sınırlarının oluşturulması gibi proje maliyetini etkileyen temel kararlar alınmaktadır.

Yatırımcıların ve yüklenicilerin stratejik ekonomik kararları açısından maliyet tahmini önemli bir yer tutmaktadır. Bu özelliklerinden dolayı maliyet tahmini sadece matematiksel hesapların olduğu teknik açıdan sıyrılıp, sürecin ve sonucun belirlenmesine etki eden karar alma aracı olarak da düşünülmektedir. Maliyet tahmin süreci, projenin başlangıç ve tasarım safhalarında mevcut olan bilgi düzeyine bağlı olarak sürekli güncellenmesi gereken yinelemeli bir yapıya sahiptir ve bu özelliğiyle karar verme mekanizmasının temel bileşenlerinden birini oluşturur. Yapılan maliyet tahminleri, projenin ekonomik açıdan uygulanabilirliğinin ortaya konulmasına ve farklı seçeneklerin karşılaştırılarak değerlendirilmesine olanak tanımaktadır (Project Management Institute, 2017).

Bu doğrultuda, karar verme mekanizmasının en kritik girdilerinden biri olan maliyet tahmininin özellikle proje başlangıç safhalarında taşıdığı önem dikkate alınarak, çalışmanın devamında ön maliyet tahmin süreci kapsamlı biçimde incelenecektir.

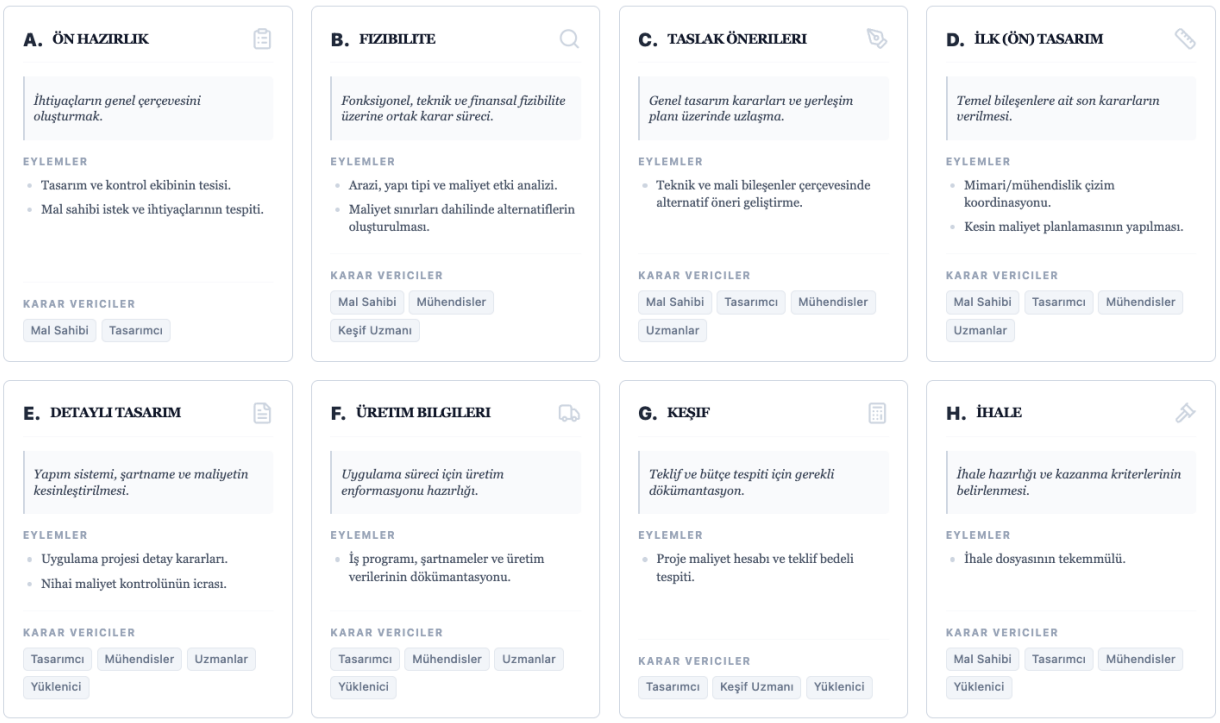

Şekil 3.5 : Bina tasarım süreci safhaları ve karar alanları (Seyyar, 2000).

4. ÖN MALİYET TAHMİN SÜRECİ

Ön maliyet tahminleri, bir inşaat projesinin ekonomik uygulanabilirliğini değerlendirmek ve bütçe gereksinimini ortaya koymak amacıyla kullanılmaktadır. Bu değerlendirme, projenin sonraki aşamalara ilerletilip ilerletilmeyeceğine ilişkin karar sürecinde önemli bir rol üstlenmektedir. Bu nedenle, erken planlama dönemindeki fizibilite çalışmalarının temel bileşenlerinden biri olan bu tahmin yöntemleri, maliyetlerin başlangıç aşamasında anlaşılmasına ve karar mekanizmalarının şekillenmesine katkı sağlamaktadır (Jassim ve diğ, 2025).

Konsept maliyet tahminleri, mevcut proje bilgilerinin sınırlı olduğu ve belirsizlik ve risk seviyelerinin önemli olduğu erken planlama aşamasında kritik bir karar destek mekanizması olarak işlev görür (Elmousalami, 2020). İnşaat projelerinin erken planlama aşamalarında maliyet tahminlerinin hazırlanması, müşterilerin karar alma süreçlerini destekleyen temel unsurlardan biridir (Dandan ve diğ, 2020).

Maliyet tahmini süreci için güvenilir girdi verileri elde etmek, özellikle proje kapsamı henüz net bir şekilde tanımlanmadığında oldukça zordur ve bu durum genellikle yaklaşık ve düşük doğrulukta tahminlerle sonuçlanır. Projenin kapsamı daha ayrıntılı ve net bir şekilde belirlendikçe, girdi bilgilerinin kullanılabilirliği ve kalitesi artar, bu da daha doğru ve güvenilir maliyet tahminleri üretme olasılığını yükseltir (Tayefeh Hashemi ve diğ, 2020).

İnşaat projesinin erken aşamalarında hazırlanan doğru maliyet tahminleri, projenin genel başarısında önemli bir rol oynar (Jin ve diğ, 2014). Benzer şekilde, Dandan ve diğ. (2020), bir bina inşaat projesinin erken tasarım evrelerinde oluşturulan maliyet tahminlerinin isabet düzeyi, projenin sonuçta başarıyla tamamlanıp tamamlanamayacağı üzerinde belirleyici bir etkiye sahip olabileceğini belirtirken, Jassim ve diğ. (2025) ise, maliyet tahmininin, özellikle projenin başlangıç aşamasında, projenin ihale süreci ve genel başarısı üzerinde belirleyici bir etkiye sahip olduğunu, bu nedenle erken dönem tahminlerin doğruluğunun kritik önem taşıyıp, söz konusu doğruluk büyük ölçüde tarihsel

maliyet verilerinin kalitesine ve maliyet uzmanlarının teknik ve mesleki yetkinliğine bağlı olduğu vurgulamaktadır.

Ön maliyet tahmininin sağlıklı bir sonuç verebilmesi için, geçmiş projelerin sayısının zengin ve veri tabanında bulunan proje verilerinin ise güvenilir olmasına ihtiyaç duyulmaktadır. Bu zengin ve güvenilir veri tabanına eşlik edecek diğer 2 ana unsur ise tahmin metodolojisi ve tüm bunların tahmin organizasyonunu sağlayan tahmin uzmanıdır. Süreç, seçilen tahmin yöntemi ve bu yönteme ait algoritmalar ile yürütülüp, yeni projeye ait özellikler metodolojiye uygun ayrıntı olarak tanımlandıktan sonra tüm bu bileşenler uzman tarafından yönetilerek tamamlanmaktadır. Doğru verilerle ve doğru yöntemlerle alınan kararlar sonucu, yapılacak tahmininde doğruluğu yüksek olacaktır (Çıracı, M., 1996).

Bahsedildiği gibi ön maliyet tahmini, bir inşaat projesinin henüz fizibilite değerlendirmesi ve ön tasarım safhasında ele alınan, projenin genel maliyet ön izlemesinin yapıldığı, erken dönem analiz çalışması ve konsept maliyet tahminidir. Bu tahminlerin yapılabilmesi için ise çeşitli yöntemler bulunmaktadır.

4.1 Maliyet Tahmin Yöntemleri

Maliyet tahmin yöntemleri, genel çerçevede iki temel kategori altında incelenmektedir: nitel yöntemler ve nicel yöntemler (Tayefeh Hashemi ve diğ, 2020).

Nitel maliyet tahmin yaklaşımları, tahmin sürecini yürüten uzmanın proje kapsamı, proje özellikleri ve maliyeti etkileyen faktörlere ilişkin bilgi ve deneyimine dayanmaktadır. Bu yaklaşımlar genel olarak uzman görüşüne dayalı yöntemler ile sezgisel kurallara dayalı yöntemler olmak üzere iki grupta ele alınmaktadır. Uzman görüşüne dayalı tahmin, geçmiş uygulamalardan elde edilen deneyimlere ve profesyonel değerlendirmelere dayanmakta; gerektiğinde daha tecrübeli uzmanların görüşleriyle tahmin sonuçlarının doğrulanmasını içermektedir. Sezgisel kurallara dayalı yöntemler ise benzer projelerden edinilen deneyimlerden türetilen pratik ve basitleştirilmiş ilkeleri temel almakta, tahmin sürecini hızlandırmayı amaçlamaktadır. Her iki yaklaşım da sistematik ve analitik modellemelerden ziyade deneyim ve sezgisel muhakemeye dayalı bir çerçeve sunmaktadır. Nicel maliyet tahmin yaklaşımları ise, proje maliyetlerinin belirlenmesi

amacıyla tarihsel verilerin sistemli biçimde toplanması ve analiz edilmesine dayanan, bu süreçte matematiksel modellerin, istatistiksel yöntemlerin ve çeşitli hesaplama araçlarının kullanıldığı yöntemler olarak tanımlanmaktadır. Bu yaklaşımlar, öznel değerlendirmeler yerine ölçülebilir verilere dayanmaktadır. Nicel maliyet tahmin teknikleri genel olarak istatistiksel yöntemler, analojiye dayalı yöntemler ve analitik yöntemler olmak üzere üç ana grupta sınıflandırılmaktadır. Geleneksel yöntemlerin (konvansiyonel metotlar) artık tek başına yeterli olmadığını ve hatalı tahminleri önlemek için makine öğrenmesi tekniklerinin kullanımı tavsiye edilmektedir (Tayefeh Hashemi ve diğ, 2020).

Nicel maliyet tahmin yaklaşımları kapsamında istatistiksel, analitik ve parametrik modeller uzun yıllardır yaygın biçimde kullanılmaktadır. Ancak proje maliyetlerini etkileyen faktörlerin çeşitlenmesi, değişkenler arasındaki doğrusal olmayan ilişkiler ve veri yapısındaki belirsizlikler, geleneksel yöntemlerin bazı durumlarda yetersiz kalmasına yol açabilmektedir. Bu doğrultuda, tarihsel verilerden öğrenebilen, karmaşık ilişkileri modelleyebilen ve daha yüksek tahmin performansı sunabilen yapay zekâ ve makine öğrenmesi tabanlı yöntemler nicel maliyet tahmininde önemli bir alternatif yaklaşım olarak öne çıkmıştır.

4.1.1 İstatistiksel yöntemler

İstatistiksel maliyet tahmin yöntemleri, ayrıntılı bileşen analizine girmeksizin kütle, hacim ve birim maliyet gibi temel belirleyici parametreler esas alınarak proje maliyetinin hesaplanmasına dayanmaktadır. Bu yaklaşımda toplam maliyet, proje özellikleri ile maliyeti etkileyen değişkenler arasındaki ilişkinin matematiksel olarak tanımlanması yoluyla belirlenmektedir. Proje hakkında sınırlı bilginin bulunduğu erken aşamalarda kullanılabilen bu yöntemler, birim, alan ve hacim esaslı hesaplama yaklaşımlarının yanı sıra regresyon analizine dayalı parametrik modeller, fonksiyonel eleman analizleri, simülasyon temelli yöntemler, oran (faktör) yöntemleri ve maliyet-kapasite ilişkilerine dayalı tahmin tekniklerini kapsamaktadır. Bu yöntemlerde proje faaliyetleri temel iş kalemleri veya ana kapsamlar çerçevesinde ayrıştırılmakta olup geliştirilen modeller genellikle teknik özellikler, girdi verileri ile çıktı değişkenleri arasındaki ilişkiler ve sabit katsayılardan oluşmaktadır (Topkaya ve diğ, 2012; Tayefeh Hashemi ve diğ, 2020).

Parametrik maliyet tahmin yöntemleri, istatistiksel tekniklere dayanan nicel yaklaşımlar kapsamında yer almakta ve temelini regresyon analizinden almaktadır. Bu yaklaşım, benzer tamamlanmış projelere ait veriler kullanılarak maliyet ile maliyet tahmincileri arasındaki ilişkinin matematiksel bir model ile ifade edilmesine dayanmaktadır. Maliyet tahmin ilişkileri aracılığıyla bağımsız değişkenler ile maliyet arasında doğrusal veya doğrusal olmayan ilişkiler kurulmakta ve bu ilişkiler regresyon analizleriyle doğrulanmaktadır. Parametrik modeller yalnızca tek bir değişkene dayalı olabileceği gibi birden fazla değişken içeren daha karmaşık yapılarda da oluşturulabilmektedir (Juszczyk, 2017; Göktürk, 2007).

Maliyet tahminine yönelik ilişkiler, geçmiş proje verileri üzerinde regresyon analizi uygulanarak oluşturulmaktadır. Bu ilişkilerin ortaya konulabilmesi için çok sayıda gözleme dayalı istatistiksel çalışmaların yürütülmesi ve çoklu regresyon analizinin kullanılması gerekmektedir (Bostancıoğlu, 1999). Regresyon analizi yalnızca bağımlı değişkenin hesaplanmasında değil, aynı zamanda hata payının ve değişkenler arasındaki ilişkinin gücünün değerlendirilmesinde de kullanılmaktadır (Erdem, 1996). Regresyon modelleri, gözlenen ve tahmin edilen değerler arasındaki farkların karelerini en aza indirmeyi hedefleyen ve en küçük kareler yöntemiyle ilişkileri tanımlayan istatistiksel yaklaşımlardır (Seyyar, 2000).

Parametrik maliyet tahmin yöntemleri çeşitli avantajlar sunmaktadır. Model, kurumun geçmiş deneyimlerini ve inşaat projelerindeki uzmanlık seviyesini yansıtan bir yapı sunmaktadır. Yöntem, maliyet tahmin sürecinin daha kısa sürede ve daha etkin biçimde yürütülmesine olanak tanımaktadır. Ayrıca sistematik ve nicel yapısı sayesinde öznel değerlendirmeleri azaltarak daha tutarlı sonuçlar üretebilmektedir (Phaobunjong, 2002).

Bununla birlikte, yöntemin bazı sınırlılıkları da bulunmaktadır. Bu yöntemin temel sınırlılığı, doğruluğunun büyük ölçüde sağlanan veri miktarına bağlı olmasıdır; proje örnekleri arttıkça tahmin başarısı da yükselmektedir. Yöntem basit yapı tiplerinde başarılı sonuçlar verse de değişkenlerin seçiminin kullanıcıya bırakılması önemli riskler oluşturmaktadır. Kullanıcının bilgi eksikliği ya da yanlış değerlendirmesi, maliyet üzerinde etkili olabilecek önemli bir değişkenin dışlanmasına neden olabilmektedir. Ayrıca modelde yer alan birim fiyatların sabit kabul edilmesi, zamanla geçerliliğini yitiren

sonuçlar üretebilmekte, bu nedenle enflasyona göre düzeltilmesi gerekmektedir (Çelik, 2006).

4.1.2 Analojiye dayalı yöntemler

Benzer (analog) maliyet tahmin modelleri, daha önce tamamlanmış ve karşılaştırılabilir nitelikteki projelerden elde edilen verilerin yeni proje koşullarına uyarlanması esasına dayanmaktadır. Bu yöntemde benzerlik, çoğunlukla maliyet yapıları arasında bulunan fonksiyonel ya da geometrik yakınlıktan kaynaklanmaktadır. Benzer tahmin yaklaşımı, proje maliyetlerinin geçmişte tamamlanmış benzer projelere ilişkin veriler esas alınarak belirlenmesini içerdiği için, maliyet tahmin yöntemleri arasında en basit tekniklerden biri olarak değerlendirilmektedir (Tayefeh Hashemi ve diğ, 2020).

Bu yöntemin uygulanması sırasında proje yöneticilerinin, tahminin güvenilirliğini artırmak amacıyla en uygun ve erişilebilir parametreleri dikkate alması gerekmektedir. Bununla birlikte, benzer tahmin yöntemi genellikle kullanım kolaylığına sahip olmakla birlikte, karmaşıklık ve doğruluk düzeyi açısından görece sınırlı bir yaklaşım olarak kabul edilmektedir (Tayefeh Hashemi ve diğ, 2020).

Benzer projelerle karşılaştırmaya dayalı tahmin yöntemleri, daha önce tamamlanmış ve maliyet verileri bilinen, özellikleri itibarıyla planlanan yapıya yakın projeler esas alınarak; maliyeti etkileyen unsurlardaki farklılıkların dikkate alınması ve gerekli uyarlamaların yapılması yoluyla yeni gerçekleştirilecek yapının yaklaşık maliyetinin belirlenmesini amaçlayan yaklaşımlardır (Özmaden & Erdal, 2020). Bu kapsamda, projenin teknik çizimleri tamamlanmadan önce hazırlık ve fizibilite aşamalarında, benzer özelliklere sahip daha önce tamamlanmış projelerden elde edilen maliyet bilgileri tahmin için referans olarak kullanılabilmektedir (Seyyar, 2000).

Benzer projelere dayalı maliyet tahmin yaklaşımları; erken aşama tahmin teknikleri, eleman bazlı karşılaştırma yöntemleri ve m² esaslı modellemeleri içermektedir. Bu kapsamda RS Means tabanlı uygulamalar ile birim ve toplam maliyet çarpanına dayalı yöntemler de yer almaktadır (Topkaya ve diğ, 2012).

Bu yaklaşımların uygulanmasında genel olarak belirli bir süreç izlenmektedir. İlk aşamada, planlanan yapıyla nitelik bakımından benzerlik gösteren ve gerçekleşmiş

maliyeti bilinen bir referans proje belirlenmektedir. Ardından yeni projeye ait imalat miktarları, kullanılacak malzemeler, yapım teknikleri ve benzeri unsurlardaki farklılıklar dikkate alınarak gerekli uyarlamalar yapılmakta ve bu düzenlemeler sonucunda yeni projenin yaklaşık maliyeti hesaplanmaktadır (Özmaden & Erdal, 2020).

Benzerlik esaslı tahmin yöntemlerinde proje yöneticisi, geçmiş projelerden elde edilen bilgiler ile uzman değerlendirmelerini bir araya getirerek bir maliyet öngörüsü oluşturmaktadır. Yöntem, yalnızca gerçekleşmiş proje maliyetlerini değil, benzer nitelikteki projeler için sunulmuş teklif bedellerini de referans alabilmektedir (Addis, 2023). Bununla birlikte, maliyet tahmininin doğruluğunu ve güvenilirliğini sağlamak amacıyla, referans projeler ile önerilen proje arasındaki konum, saha koşulları, piyasa ortamı, inşaat kalitesi ve benzeri farklılıkların dikkatlice değerlendirilmesi gerekmektedir (Seyyar, 2000).

Ayrıca, fiyat seviyeleri, teknik standartlar, kullanılan teknolojiler ve iş gücü uygulamalarındaki değişimler nedeniyle eski projelere ait verilerin güvenilirliği zamanla azalabilmektedir. Bunun yanında, öngörülemeyen durumlar ve riskler için maliyet tahminine belirli bir ihtiyat payı eklenmesi gerekebilmektedir. Bu pay kimi durumlarda tahmincinin öznel yargılarına, kimi durumlarda ise geçmiş proje deneyimlerine ve beklenen belirsizlik düzeyine bağlı olarak belirlenmektedir. Bu nedenle benzerlik temelli tahmin yaklaşımı, daha çok yapısı basit projelerde genel maliyet aralıklarının belirlenmesi veya başka yöntemlerle elde edilen tahminlerin doğrulanması amacıyla kullanıldığında daha etkili sonuçlar vermektedir (Addis, 2023).

4.1.3 Analitik yöntemler

Analitik maliyet tahmin modelleri, proje maliyetinin her bir süreç veya faaliyet bileşeni için ayrı ayrı ve ayrıntılı biçimde hesaplanmasına dayanan yaklaşımları ifade etmektedir. Bu yöntemde, proje kapsamındaki her bir unsurun maliyeti belirlenmekte ve ardından toplam proje maliyeti, söz konusu bileşenlerin aşağıdan yukarıya doğru birleştirilmesi yoluyla oluşturulmaktadır. Tüm maliyet kalemlerinin sistematik biçimde bir araya getirilmesi sayesinde, analitik yaklaşım genellikle daha az ayrıntı içeren yöntemlere kıyasla daha yüksek doğruluk düzeyine sahip sonuçlar sunmaktadır (Tayefeh Hashemi ve diğ, 2020).

4.1.4 Yapay zekâ ve makine öğrenmesi yöntemleri

Latince kökenli “Intellectus” sözcüğünden türeyen zekâ kavramı için literatürde çeşitli tanımlar yapılmaktadır. Genel çerçevede zekâ; akılcı ve soyut düşünebilme, sözel ve mantıksal akıl yürütme, öğrenme, kişisel deneyimlerden faydalanma, çevresel koşullarla başa çıkabilme ve yeni durumlara uyum sağlayabilme kapasitesi olarak ifade edilmektedir (Gürel & Tat, 2010). Disiplinler arası bakış açısına göre zekâ farklı şekillerde yorumlanmaktadır (Yıldırım & Kaya, 2025). Biyoloji alanında çevreye uyum sağlama, eğitim bilimlerinde öğrenme ve bilgiyi kullanabilme, psikolojide örüntüleri kavrama ve problem çözme, bilgisayar bilimlerinde ise veriyi işleme ve analiz etme kapasitesi olarak ele alınmaktadır (Abdullayeva, 2018; Akhtar, 2005; Gürel & Tat, 2010; Jacob ve diğ, 2024; Sternberg, 2019).

Başlangıçta daha çok ilgi çekici bir araştırma alanı olarak görülen yapay zekâ, gün geçtikçe bağımsız bir bilim dalı niteliği kazanmıştır. Bu gelişmeye paralel olarak üniversitelerde yapay zekâ alanına yönelik bölümler açılmakta ve bu alanda uzmanlaşmış yapay zekâ ya da bilgi mühendisleri yetiştirilmektedir. Yapay zekâ disiplinine genel bir perspektiften bakıldığında; bilginin yapılandırılması, öğrenme süreçleri, problem çözme yaklaşımları, teorem ispatı ve bilimsel keşiflerin modellenmesi gibi çok çeşitli konuları kapsadığı görülmektedir. Bu yetkinliklerle geliştirilen bilgisayar sistemleri, karşılaştıkları problemlere çözüm üretirken insanın düşünme ve problem çözme biçimini taklit etmektedir (Öztemel, 2006).

Yapay zekâ, insan beyninin işleyiş biçimlerinden esinlenilerek geliştirilen ve problem çözmeye yönelik yaklaşımlar sunan bir bilim alanıdır. Bu alan, insanların bilişsel olarak bilgisayarlardan daha başarılı olduğu görevlerin, bilgisayar sistemleri aracılığıyla yerine getirilebilmesini amaçlamaktadır. Temel olarak yapay zekâ, insanın düşünme ve karar verme süreçlerinin analiz edilmesi ve bu süreçlerin çeşitli makineler yardımıyla taklit edilmesine dayanan bir olgu olarak tanımlanmaktadır (Sağıroğlu ve diğ, 2003).

Proje ölçeklerinin büyümesi ve karmaşıklığın artması, geleneksel maliyet tahmin yöntemlerinin sınırlılıklarını daha görünür hâle getirmiştir. Uzman görüşüne, geçmiş verilere ve manuel hesaplamalara dayanan klasik yaklaşımlar, özellikle veri yoğun ve değişken koşullara sahip ortamlarda yeterli doğruluk sağlayamamaktadır. Bu nedenle,

daha güvenilir ve gelişmiş tahmin tekniklerine duyulan ihtiyaç giderek artmıştır. Bu bağlamda yapay zekâ uygulamaları, maliyet tahmin alanında önemli bir dönüşüm yaratmıştır. Özellikle makine öğrenimi ve derin öğrenme temelli modeller, büyük veri setlerini analiz edebilme, karmaşık ve doğrusal olmayan ilişkileri ortaya çıkarabilme ve proje verilerindeki değişimlere bağlı olarak tahminleri güncelleyebilme kapasitesine sahiptir. Geleneksel modellerin sınırlı açıklayıcılığına karşılık, yapay zekâ tabanlı yaklaşımlar hem geçmiş hem de gerçek zamanlı verilerden yararlanarak daha esnek ve uyarlanabilir tahminler sunabilmektedir (Shamim ve diğ, 2025).

Yapay zekâ yaklaşımlarını klasik matematiksel çözüm yöntemlerinden ayıran temel özelliklerden biri, ters problemlerin çözümünde sunduğu üstün yetenektir. Bu özellik sayesinde yapay zekâ temelli yöntemler, inşaat projelerinin yönetimi alanında da geniş bir uygulama potansiyeline sahip olmuş ve farklı çalışmalarda etkin biçimde kullanılmaya başlanmıştır (Dikmen ve diğ, 2009).

Yapay zekâ kavramının gelişmesiyle birlikte farklı uygulama alanlarına yönelik yeni yöntem ve teknikler ortaya çıkmaktadır. Bu kapsamda makine öğrenmesi yaklaşımları, inşaat maliyet tahmini süreçlerine entegre edilerek alternatif modelleme yöntemlerinin geliştirilmesine katkı sağlamaktadır. Makine öğrenmesi uygulamalarında temel amaç, insan müdahalesini en düşük düzeyde tutarak kısa sürede ve yüksek doğruluk oranıyla maliyet tahmini yapabilen sistemler oluşturmaktır.

Makine öğrenmesi ise, geçmişte elde edilen gözlemlerden yararlanarak doğru tahminler üretebilen sistemlerin geliştirilmesini amaçlayan otomatik teknikler bütünü olarak tanımlanmaktadır. Aynı zamanda bu metot, deneyimlerden hareketle öğrenme sürecini kendi kendine iyileştiren ve bu süreci otomatik olarak gerçekleştiren bilgisayar sistemlerinin tasarlanması olarak ifade etmektedir (Özmaden & Erdal, 2020).

Diğer maliyet tahmin yaklaşımlarında olduğu gibi, makine öğrenmesine dayalı modellerde de veri temel bir unsur niteliğindedir. Regresyon modelleri, karar ağaçları ve destek vektör makineleri gibi makine öğrenmesi algoritmaları, geçmiş verilere dayanarak proje maliyetlerinin öngörülmesinde giderek daha yaygın biçimde kullanılmaktadır. Söz konusu yöntemler, değişkenler arasındaki karmaşık ve doğrusal olmayan etkileşimleri analiz edebilme yeteneği sayesinde tahmin sonuçlarının doğruluk ve performans düzeyini

geliştirmektedir (Shamim ve diğ, 2025). Bu kapsamda kullanılan veri setleri genellikle eğitim ve test verileri olmak üzere iki gruba ayrılmakta; eğitim verileri algoritmanın öğrenme sürecinde, test verileri ise oluşturulan modelin performansının değerlendirilmesinde kullanılmaktadır (Özmaden & Erdal, 2020).

Zhou (2021)'e göre Makine öğrenimi algoritmaları, Şekil 4.1'de gösterildiği gibi üç temel kategoriye ayrılabilir; Supervised Learning (Denetimli Öğrenme), (Unsupervised Learning) denetimsiz öğrenme ve (Reinforcement Learning) pekiştirmeli öğrenme.

Şekil 4.1 : Makine öğrenmesi tekniklerinin ana kategorileri (Türkyılmaz, 2025).

4.1.4.1 Denetimli öğrenme:

Denetimli öğrenme, girdiler ve bu girdilere karşılık gelen çıktılarının önceden tanımlı olduğu etiketli veri kümelerinden yararlanarak, bu iki bileşen arasındaki ilişkiyi temsil eden bir fonksiyonun öğrenilmesini amaçlayan bir yaklaşımdır (Xie ve diğ, 2020). Bu öğrenme türünde her bir veri noktası, bir veya birden fazla tahmin edici değişken ile bunlara karşılık gelen bir çıktı değeri içermektedir. Mevcut gözlemlerden elde edilen bilgiler kullanılarak geliştirilen modeller, ileride karşılaşılabilecek yeni veriler için tahmin yapılmasına ya da bağımlı değişken ile tahmin ediciler arasındaki ilişkinin analiz edilmesine olanak tanır (James ve diğ, 2023). Yeterli ve yapılandırılmış veri ile eğitildiğinde, maliyet üzerinde etkili olan değişkenler arasındaki karmaşık ve doğrusal olmayan ilişkileri analiz edebilmektedir (Rasila ve diğ, 2025)

Denetimli öğrenme problemleri genel olarak iki ana başlık altında incelenmektedir: sınıflandırma ve regresyon (Nasteski, 2017). Sınıflandırma yöntemleri, çıktı değişkeninin kategorik yapıda olduğu durumlarda, gözlemlenen verilere dayanarak yeni örneklerin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılmaktadır. Buna karşılık, çıktı değişkeninin sayısal değerlerden oluştuğu durumlarda, gelecekteki değerlerin tahmin edilmesi ve değişkenler arasındaki ilişkilerin ortaya konulması için regresyon yaklaşımları tercih edilmektedir (Türkyılmaz, 2025).

Sınıflandırma teknikleri; cinsiyet belirleme, futbol takımlarının ayrıştırılması, müşteri segmentasyonu ve tıbbi tanı gibi farklı grupların tanımlanmasını gerektiren problemlerde yaygın olarak kullanılmaktadır. Bu kapsamda sıkça başvurulan yöntemler arasında Lojistik Regresyon, K-En Yakın Komşular, Destek Vektör Sınıflandırıcı, Naive Bayes, Karar Ağacı Sınıflandırıcı, Rastgele Orman Sınıflandırıcı ve Yapay Sinir Ağları yer almaktadır (Türkyılmaz, 2025).

Regresyon yöntemleri ise genellikle sürekli veya ayrık sayısal çıktılara sahip problemlerde uygulanmaktadır. Hava durumu tahmini, sınav başarılarının değerlendirilmesi ve pazar satışlarının öngörülmesi gibi alanlarda yaygın kullanım alanı bulan regresyon tekniklerine; Doğrusal Regresyon, Polinom Regresyon, Destek Vektör Regresyonu, Karar Ağaçları, Rastgele Ormanlar, Yapay Sinir Ağları ve Gradyan Artırma Ağaçları örnek olarak verilebilir (Türkyılmaz, 2025).

4.1.4.2 Denetimsiz öğrenme:

Denetimsiz öğrenme yaklaşımı, veri setinde önceden tanımlanmış etiketlerin bulunmadığı durumlarda uygulanmakta ve verilerde gizli olan örüntülerin ortaya çıkarılması yoluyla yapının anlaşılmasını amaçlamaktadır. Bu öğrenme türünde her bir gözlem, belirli bir çıktı değeriyle değil, çok boyutlu bir özellik vektörüyle temsil edilmektedir. Bu durum, denetimsiz öğrenme problemlerini denetimli öğrenmeye kıyasla daha karmaşık hâle getirmektedir (James ve diğ, 2023). Tyagi ve diğ. (2022)'e göre ise denetimsiz öğrenmede temel hedef; veri örnekleri arasındaki benzerlikleri belirleyerek gruplar oluşturmak (kümeleme), veri dağılımının özelliklerini modellemek (yoğunluk tahmini) ya da veri boyutunu azaltarak daha anlamlı temsiller elde etmektir (alt uzay öğrenmesi). Öte yandan, Rasila ve diğ. (2025), denetimsiz makine öğrenmesi algoritmalarının, genellikle çıktı değişkeninin önceden tanımlı olmadığı durumlarda, veri içerisindeki örüntüleri ortaya çıkarmaya yönelik keşifsel analizlerde kullanıldığını; bu kapsamda en yaygın uygulama alanları kümeleme ve aykırı değer belirleme çalışmalarını içerdiğini söylemektedir.

Denetimsiz öğrenmede yaygın olarak kullanılan başlıca yöntemler kümeleme ve boyut indirgeme teknikleridir. Kümeleme analizi, özellikle tüketici segmentasyonu ve pazar hedefleme gibi, sınıf etiketleri önceden tanımlanmamış veri kümelerinde benzer özelliklere sahip gözlemlerin gruplandırılması amacıyla kullanılmaktadır. Bu kapsamda sıkça başvurulan algoritmalar arasında K-ortalamalar, gürültüye duyarlı yoğunluk tabanlı mekânsal kümeleme, Gauss karışım modelleri, spektral kümeleme ve hiyerarşik kümeleme yer almaktadır (Türkyılmaz, 2025).

4.1.4.3 Pekiştirmeli öğrenme:

Pekiştirmeli öğrenme, kökeni davranışçı psikolojiye dayanan ve makine öğrenmesinin alt dallarından biri olarak değerlendirilen bir yaklaşımdır. Bu yöntemde bir yazılım ajanı, belirli bir çevre içinde gerçekleştireceği eylemleri, uzun vadede elde edeceği toplam ödülü en üst düzeye çıkaracak biçimde öğrenir. Ajan, çevre ile sürekli etkileşim kurarak ödül veya ceza şeklinde geri bildirim almakta ve bu geri bildirimler doğrultusunda izlenecek karar politikasını geliştirmektedir (Somvanshi ve diğ, 2016).

Pekiştirmeli öğrenme, özellikle satranç ve Go gibi strateji oyunlarında, robotik uygulamalarda ve otonom araç sistemlerinde etkin bir şekilde kullanılmaktadır. Bunun

yanı sıra makine öğrenmesine dayalı yaklaşımlar, veri işleme süreçlerini sadeleştirmesi, anlaşılabilir çıktılar üretmesi ve farklı değişkenlerin göreli önemini ortaya koyabilmesi nedeniyle önemli avantajlar sunmaktadır. Bu özellikleri sayesinde söz konusu yöntemler, inşaat yönetimi alanında performans değerlendirmesi, verimlilik analizi, iş güvenliği risklerinin öngörülmesi ve maliyet tahmini gibi pek çok farklı uygulama alanında yaygın olarak kullanılmaktadır (Türkyılmaz, 2025).

5. ARAŞTIRMA METODOLOJİSİ

Bu tez kapsamında, değişkenler arasındaki nedensel ilişkilerin istatistiksel yöntemlerle açıklanmasından ziyade, güvenilir ve yüksek doğrulukta tahminler elde edilmesi öncelikli amaç olarak benimsenmiştir. Bu yaklaşım doğrultusunda, açıklayıcı modeller yerine tahmin performansı güçlü olan yöntemlere odaklanılmış ve söz konusu hedef, makine öğrenmesine dayalı algoritmaların tercih edilmesini beraberinde getirmiştir.

5.1 Regresyon Analizi

Regresyon analizi, bağımlı değişken ile onu etkilediği varsayılan bir veya birden fazla bağımsız değişken arasındaki ilişkiyi incelemeye olanak tanıyan yaygın bir istatistiksel yöntemdir. Bu yöntem, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin anlamlılığını test etmeyi, değişkenlerin göreli etkilerini ölçmeyi ve elde edilen ilişkiler doğrultusunda tahminler yapmayı mümkün kılmaktadır. Bağımsız değişkenlerin sonuç değişkeni üzerindeki etkisinin belirlenmesi, karar verme ve öngörü süreçlerinde önemli bir analitik araç sunmaktadır (Sarstedt & Mooi, 2014).

Regresyon analizi, değişkenler arasındaki ilişkileri ortaya koymanın yanı sıra geleceğe yönelik tahminler yapılmasına da imkân tanımaktadır. Belirli bir bağımlı değişken ile onu etkilediği varsayılan bağımsız değişkenlere ilişkin veriler kullanılarak oluşturulan bir regresyon modeli, bu değişkenlerde meydana gelecek değişimlerin sonuç üzerindeki olası etkilerini nicel olarak öngörebilmektedir (Sarstedt & Mooi, 2014). Ampirik verilere dayanarak tahmin ve kestirim yapma, zaman serisi verilerini inceleme ve değişkenler arasındaki ilişkileri değerlendirme amacıyla kullanılmaktadır. Yöntem, gözlemlere en uygun doğru ya da eğriyi oluşturarak tahmin hatasını en aza indirme ilkesine dayanmaktadır (Tyagi ve diğ, 2022). Farklı senaryolar altında bağımsız değişkenlerin belirli oranlarda artırılması veya azaltılması durumunda ortaya çıkabilecek sonuçların hesaplanması, karar verme süreçlerinde alternatiflerin karşılaştırılmasına olanak sağlamaktadır (Sarstedt & Mooi, 2014).

Regresyon analizi, bağımlı (yanıt) değişken ile onu açıklayan veya tahmin eden bağımsız değişkenler arasında matematiksel bir model kurulmasına imkân sağlayan bir yöntemdir. Analiz kapsamında yalnızca bir bağımlı değişkenin incelendiği durumlar tek değişkenli regresyon olarak adlandırılırken, birden fazla bağımlı değişkenin aynı anda ele alındığı durumlar çok değişkenli regresyon olarak tanımlanmaktadır (Fumo & Biswas, 2015).

Tek değişkenli doğrusal regresyon analizi, bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi veriye doğrusal bir denklem uydurarak modellemeyi amaçlayan bir istatistiksel yöntemdir. Birden fazla bağımsız değişkenin bulunduğu durumlarda ise çoklu doğrusal regresyon yaklaşımı kullanılmakta ve her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisi diğer değişkenler sabit tutulurken değerlendirilmektedir. Bununla birlikte, bağımlı ve bağımsız değişkenler arasında istatistiksel olarak anlamlı bir ilişkinin bulunması, nedensellik ilişkisini zorunlu olarak ifade etmez; yalnızca değişkenler arasında anlamlı bir ilişki bulunduğunu göstermektedir. Bu bağlamda regresyon analizi, değişkenler arasındaki ilişkinin karmaşıklık düzeyine bağlı olarak basit doğrusal regresyon ve çoklu doğrusal regresyon olmak üzere iki temel başlık altında incelenmektedir (Fumo & Biswas, 2015).

Basit doğrusal regresyon, yalnızca bir bağımsız değişken içeren bir model yapısını ifade etmektedir. Bu modelde bağımlı değişken ile bağımsız değişken arasındaki ilişki denklem 5.1'deki gibidir.

$$y = \beta_0 + \beta_1 x + \varepsilon \tag{5.1}$$

Denklemde β_0 sabit terimi, β_1 regresyon katsayısını ve ε ise hata bileşenini temsil etmektedir. Basit doğrusal regresyon analizinin temel amacı, bağımsız değişkenin bağımlı değişken üzerindeki etkisini, gözlenen toplam değişim içerisinden ayırt edebilmektir (Maulud & Abdulazeez, 2020).

Çoklu doğrusal regresyon ise, bir bağımlı değişkenin değerini birden fazla bağımsız değişken aracılığıyla tahmin etmeye yönelik istatistiksel bir yöntemdir. Bu yaklaşımın temel amacı, bağımsız değişkenler x ile bağımlı değişken y arasındaki doğrusal ilişkiyi matematiksel bir model çerçevesinde tanımlamaktır. Bu modelde bağımlı değişken ile bağımsız değişken arasındaki ilişki denklem 5.2'deki gibidir.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \cdots + \beta_m x_m + \varepsilon \quad (5.2)$$

Bu eşitlikte β_0 sabit terimi, $\beta_1, \ldots, \beta_m$ katsayıları ve ε hata bileşenini temsil etmektedir. Model parametrelerinin tahmin bölgeler oluşturmayı amaçlar. Böylece veri kümesi, belirli özellik kombinasyonlarına göre ayrıştırılarak çıktı değişkeninin daha doğru biçimde tahmin edilmesi sağlanır (Türkyılmaz, 2025).

5.2 Decision Tree (DT):

Karar Ağacı (Decision Tree), hem sınıflandırma hem de regresyon görevleri için kullanılan denetimli (supervised) bir makine öğrenmesi algoritmasıdır (Fletcher & Islam, 2019). Model, kök düğümden başlayarak veriyi karar kuralları aracılığıyla yinelemeli biçimde alt düğümlere ayırır. Her bölünme adımında, veri safsızlığı ölçütleri (örneğin, entropi veya bilgi kazancı) hesaplanmakta ve en düşük safsızlık değerini sağlayan bölünme tercih edilmektedir. Amaç, hedef değişken açısından daha homojen alt gruplar oluşturmaktır. Süreç, belirlenen durdurma kriterlerine (minimum gözlem sayısı, maksimum ağaç derinliği vb.) ulaşılana kadar devam etmektedir. Aşırı öğrenmeyi önlemek amacıyla ayrıca budama teknikleri uygulanmakta; bu kapsamda ya erken aşamada anlamsız dalların oluşması engellenmekte (ön budama) ya da tam ağaç oluşturulduktan sonra modele katkı sağlamayan dallar çıkarılmaktadır (Lee ve diğ, 2022)

Karar ağaçları, hızlı ve etkin sınıflandırma yapabilme yetenekleriyle öne çıkmaktadır. Yeni veya daha önce görülmemiş kayıtlar kısa sürede sınıflandırılabilmektedir. Ayrıca veri setinde tekrarlı ya da gereksiz özelliklerin bulunması durumunda dahi model çalışabilirliğini sürdürebilmektedir. Uygun aşırı öğrenme kontrol mekanizmalarının (örneğin budama tekniklerinin) uygulanması halinde, belirli düzeyde gürültü içeren veri kümelerinde de kabul edilebilir performans sağlayabilmektedir (Somvanshi ve diğ, 2016).

Bununla birlikte karar ağaçlarının bazı sınırlılıkları bulunmaktadır. Anlamlı bilgi taşımayan değişkenlerin modele dahil edilmesi performansı olumsuz etkileyebilmektedir. Ayrıca veri setindeki küçük değişimler dahi ağacın yapısında önemli farklılıklara yol açarak model kararlılığını azaltabilmektedir. Bunun yanı sıra, benzer alt ağaçların tekrar eden biçimde oluşması modelin gereksiz yere karmaşıklaşmasına neden olabilmektedir (Somvanshi ve diğ, 2016).

Karar ağacı yönteminin avantajları ve dezavantajları literatürde çeşitli çalışmalarda ele alınmıştır (Fletcher & Islam, 2019; Gavankar & Sawarkar, 2015; Lee ve diğ, 2022; Somvanshi ve diğ, 2016).

Başlıca avantajları şu şekilde sıralanabilmektedir:

- Karmaşık matematiksel formüller veya derin istatistik bilgisi gerektirmeden sonuçların insanlar tarafından kolaylıkla yorumlanabilmesine olanak tanımaktadır.
- Hem sayısal hem de kategorik (metinsel) verileri aynı anda işleyebilmesi, yönteme uygulama açısından esneklik kazandırmaktadır.
- Veri hazırlama aşamasında, verilerin normalleştirilmesi veya karmaşık hesaplamalardan geçirilmesi için genellikle daha az çaba gerektirmektedir.
- Bilinmeyen kayıtları çok hızlı bir şekilde sınıflandırabilir.

Bununla birlikte, yöntemin bazı sınırlılıkları da bulunmaktadır:

- Eğitim verilerine çok fazla uyum sağlayarak, görülmemiş yeni verilerde düşük performans sergileyebilmektedir (overfittig).
- Verideki çok küçük değişiklikler ağacın yapısında büyük farklılıklara neden olabilmektedir.
- Algoritma genellikle "açgözlü" (greedy) bir yaklaşım sergilediği için her adımda anlık en iyi sonucu arar ve bu durum uzun vadede en iyi ağaç yapısına ulaşılmasını engelleyebilmektedir.

5.3 Random Forest(RF):

Random Forest (RF), Türkçe literatürde Rastgele Orman olarak adlandırılan ve Leo Breiman tarafından 2001 yılında geliştirilen, istatistiksel öğrenme ve makine öğrenmesi alanlarında yaygın biçimde kullanılan bir topluluk (ensemble) öğrenme algoritmasıdır (Genuer & Poggi, 2020; Schonlau & Zou, 2020). Bu yöntemin temel yaklaşımı, tek bir karar ağacı modeline bağlı kalmak yerine rastgele oluşturulan çok sayıda karar ağacını bir araya getirerek daha güçlü ve daha güvenilir bir tahmin mekanizması oluşturmaktır (Genuer & Poggi, 2020). Random Forest algoritması hem sınıflandırma (kategorik değişkenler) hem de regresyon (sürekli değişkenler) problemlerinde uygulanabilen esnek bir yöntemdir (Fang ve diğ, 2021). Algoritmanın çalışma sürecinde, orijinal eğitim veri

setinden “bootstrap” yöntemi kullanılarak yerine koymalı örnekleme ile rastgele alt veri kümeleri oluşturulmaktadır (Jain ve diğ, 2021). Bu alt veri kümeleri üzerinde ayrı ayrı karar ağaçları eğitilirken, her bir düğümde gerçekleştirilen bölünme işlemlerinde tüm değişkenler yerine rastgele seçilen belirli sayıdaki değişken arasından en uygun bölünme belirlenmektedir (Genuer & Poggi, 2020; Breiman, 2001). Sürecin sonunda regresyon problemlerinde tüm ağaçların ürettiği tahminlerin ortalaması alınarak nihai sonuç elde edilirken, sınıflandırma problemlerinde çoğunluk oylaması yöntemi kullanılarak son karar verilmektedir (Zheng ve diğ, 2023).

Literatürde bu yöntemin; derin temel çukurlarına ilişkin güvenlik risklerinin tahmin edilmesi ve şantiyelerdeki iş güvenliği göstergelerinin belirlenmesi (Zhou ve diğ, 2019), inşaat sürecine ait karbon emisyonlarının tahmini (Fang ve diğ, 2021), Bina Bilgi Modellemesi (BIM) projelerinde işçilik maliyetlerinin öngörülmesi (Huang & Hsieh, (2020), tünel projelerinde maliyet ve süre tahminlerinin yapılması (Mahmoodzadeh ve diğ, 2022) ile konut fiyatları ve birim metrekare maliyetlerinin belirlenmesi (Ashraf ve diğ, 2024) gibi çeşitli çalışmalarda kullanıldığı görülmektedir. Bu çalışmalar, yöntemin inşaat sektöründe giderek artan bir ilgi gördüğünü ortaya koymakta olup, özellikle karmaşık ve çok değişkenli veri setlerinin analiz edilmesi ihtiyacı bu ilginin artmasında önemli bir rol oynamaktadır (Sadikoglu & Demirkesen, 2025; Alazawy ve diğ, 2025). Özellikle maliyet tahminlerindeki belirsizlikleri azaltmak ve daha güvenilir sonuçlar elde edebilmek amacıyla matematiksel modelleme yaklaşımları ile makine öğrenmesi tabanlı yöntemlerin kullanımı giderek yaygınlaşmaktadır. Bu kapsamda Random Forest algoritması, doğrusal olmayan ilişkileri modelleyebilme ve karmaşık veri yapılarıyla etkin biçimde başa çıkabilme kapasitesi sayesinde inşaat maliyet tahmini çalışmalarında öne çıkan yöntemlerden biri olarak değerlendirilmektedir (Sadikoglu & Demirkesen, 2025).

Random Forest modelinin başlıca avantajları şu şekilde sıralanabilmektedir:

- Büyük veri setlerinde, çok sayıda ağaç kullanıldığı ve Law of Large Numbers (Büyük Sayılar Yasası) geçerli olduğu için aşırı öğrenme sorunuyla karşılaşma riski düşüktür (Breiman, 2001; Fang ve diğ, 2021).
- RF, eksik verilerle başa çıkmada oldukça dayanıklı olup, dengesiz dağılmış veriler üzerinde etkili performans sergileyebilmektedir (Zheng ve diğ, 2023).

- Model, hangi girdinin tahmin sonucunu ne derece etkilediğini "değişken önemi" (variable importance) metrikleri ile sunarak karar vericilere stratejik bilgi sağlamaktadır (Huang & Hsieh, 2020).
- Genellikle tekil karar ağaçlarından ve geleneksel doğrusal modellerden daha yüksek doğruluk oranlarına ulaşır (Fang ve diğ, 2021; Genuer & Poggi, 2020).

Bununla birlikte, yöntemin bazı sınırlılıkları da bulunmaktadır:

- Çok sayıda ağacın birleşiminden oluştuğu için tek bir karar ağacı kadar kolay yorumlanamaz ve genellikle "kara kutu" (black-box) olarak nitelendirilir (Schonlau & Zou, 2020).
- Veri setinin çok küçük olduğu durumlarda veya tahmin edilecek yeni projenin eğitim verilerinden çok farklı özellikler taşıması halinde hata payı artabilir (Huang & Hsieh, 2020).
- Modelin performansı ağaç sayısı (ntree) ve her bölünmede denenecek değişken sayısı (mtry) gibi parametrelerin doğru ayarlanmasına bağlıdır (Fang ve diğ, 2021; Zheng e ve diğ, 2023).

5.4 Support Vector Regression (SVR):

Destek Vektör Regresyonu (SVR), Vapnik tarafından geliştirilen Destek Vektör Makineleri (SVM) yaklaşımının regresyon problemlerine uyarlanmış bir türevi olup sayısal değerlerin tahmin edilmesinde kullanılan gözetimli bir makine öğrenmesi algoritmasıdır (Rodríguez-Pérez & Bajorath, 2022). SVR yönteminin temel amacı, Yapısal Risk Minimizasyonu (Structural Risk Minimization - SRM) doğrultusunda yalnızca eğitim verisi üzerindeki hatayı minimize etmekle kalmayıp, modelin genelleme kabiliyetini de artırmaktır. Bu yaklaşımda, tahmin edilen regresyon fonksiyonu etrafında “epsilon-tüpü” (ϵ-tube) olarak adlandırılan bir tolerans aralığı tanımlanmakta; bu aralık içerisinde kalan küçük tahmin hataları dikkate alınmazken, bu sınırın dışında kalan sapmalar cezalandırılarak modelin karmaşıklığı kontrol edilmekte ve genelleme performansı artırılmaktadır (Basak ve diğ, 2007).

Destek vektör makineleri, yapısal risk minimizasyonu yaklaşımıyla genelleme hatasını kontrol altına almayı hedefleyen ve yüksek boyutlu özellik uzaylarında doğrusal olmayan ilişkileri modelleyebilen bir makine öğrenmesi yöntemi olup, özellikle inşaat sektöründe

değişkenler arasındaki karmaşık etkileşimlerin söz konusu olduğu projelerde geleneksel istatistiksel yöntemlerin sınırlılıklarını aşan esnek ve etkili bir modelleme yaklaşımı sunmaktadır (Chandanshive & Kambekar, 2021; Adinyira ve diğ, 2021; Petruseva ve diğ, 2017; Eltoukhy & Nassar, 2021). Sektörel uygulamalarda bu yöntemler; bina inşaat maliyetlerinin erken aşamada tahmini (Chandanshive & Kambekar, 2021), tünel projelerinde zaman ve maliyet performansının belirlenmesi (Jaber ve diğ, 2019) ve proje kârlılığının analiz edilmesi (Adinyira ve diğ, 2021) gibi alanlarda yaygın olarak kullanılmaktadır.

İnşaat verilerinin çoğunlukla sınırlı ve gürültülü yapısına rağmen, SVR algoritmasının az veri ile yüksek genelleme performansı gösterebilmesi bu durumu bir dezavantaj olmaktan çıkararak doğru tahminler yapılmasına olanak sağlamakta ve modelin daha önce karşılaşılmamış verilere karşı sergilediği güçlü uyum yeteneği sayesinde, özellikle proje başlangıcındaki belirsizliklerin yönetiminde güvenilir bir karar destek aracı olarak öne çıkmaktadır (Chandanshive & Kambekar, 2021; Petruseva ve diğ, 2017; Adinyira ve diğ, 2021).

5.5 Polynomial Regression

Polinom regresyonu, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi belirli bir dereceden polinom fonksiyonları aracılığıyla modelleyen denetimli bir öğrenme yöntemidir. Bu yaklaşım, doğrusal model yapısını korurken doğrusal olmayan veri ilişkilerinin analiz edilmesine olanak tanır. Matematiksel olarak model, denklem 5.3'de görüldüğü biçiminde ifade edilmektedir (Sudhaman ve diğ, 2022).

$$y = b_0 + b_1 x + b_2 x^2 + \cdots + b_n x^n \tag{5.3}$$

Denklemde yer alan *y* bağımlı değişkeni, *x* bağımsız değişkeni, *bo* sabit terimi, b_1, b_2, …, b_n model katsayılarını, *n* ise polinom derecesini ifade etmektedir. Aynı zamanda *n* modelin eğrisel yapısının seviyesini belirlemektedir. Değişkenlerin kendisinden ziyade regresyon katsayıları üzerinden tanımlandığı için literatürde "polinom doğrusal regresyon" olarak da adlandırılmaktadır. Özellikle standart doğrusal modellerin karmaşık veri yapılarındaki örüntüleri yeterince temsil edemediği durumlarda ortaya çıkan yetersiz uyum (underfitting) problemini azaltmak amacıyla tercih edilen etkili bir yöntemdir (Sudhaman ve diğ, 2022).

İnşaat mühendisliği ve yönetimi bağlamında polinom regresyonu, risk faktörleri arasındaki doğrusal olmayan etkileşimleri yakalayan tahmin modelleri oluşturmak amacıyla kullanılan stratejik bir matematiksel modelleme aracıdır. Bu yöntem, projelerin erken aşamalarında özellikle köprü gibi altyapı yapılarının maliyetlerinin öngörülmesinde analitik bir temel sunar. Ayrıca, yüksek katlı binalar gibi karmaşık yapılarda kısıtlı parametrik veriler üzerinden maliyet tahmini ve bütçe planlaması yapılmasına imkân tanır. İnşaat projelerinde sıklıkla karşılaşılan gecikme risklerinin öngörülmesi ve süre tahminlerinin yapılması süreçlerinde de bu modellerden yararlanılmaktadır. Veri odaklı bu nicel yaklaşımlar, projelerin erken safhalarında nesnel kriterlere dayalı performans analizi yapılmasına ve risk unsurlarının kantitatif olarak ölçülmesine olanak sağlar (Ranković ve diğ, 2024; Kumi ve diğ, 2024).

5.6 R^2 ve MSE

Regresyon modelin performansını, tahmin yeteneğini ve veri içerisindeki değişkenliği açıklama kapasitesini sayısal olarak ifade eden Belirleme Katsayısı (R^2) ve ortalama karesel hata (Mean Squared Error - MSE) metrikleri, literatürde en sık kullanılan ancak farklı yapısal özelliklere sahip iki önemli performans göstergesi olarak öne çıkmaktadır.

Belirleme katsayısı (R^2), bir regresyon modelinde bağımlı değişkende ortaya çıkan toplam varyansın, bağımsız değişkenler tarafından ne ölçüde açıklandığını gösteren istatistiksel bir ölçüttür (Chicco ve diğ, 2021). Matematiksel olarak R^2, modelin hata kareleri toplamının (Residual Sum of Square -RSS) toplam varyansa (Total Sum of Square - TSS)) oranının birden çıkarılmasıyla hesaplanmakta olup, aynı zamanda korelasyon katsayısının karesi şeklinde de ifade edilebilmektedir (Gupta ve diğ, 2024). Literatürde R^2, modelin veri ile uyum düzeyini (goodness-of-fit) değerlendirmede kullanılan bir performans göstergesi olarak kabul edilmekte ve modelin başarısını ortalama temelli basit bir tahmin ile karşılaştırma olanağı sağlamaktadır. (Chicco ve diğ, 2021; Draper & Smith, 1998). Bununla birlikte, bu metriğin yorumlanması çalışmanın gerçekleştirildiği disipline bağlı olarak farklılık gösterebilmektedir. Örneğin, kontrol edilemeyen değişkenlerin etkisinin daha belirgin olduğu sosyal bilimler ve psikoloji alanlarında 0,10–0,30 aralığındaki R^2 değerleri kabul edilebilir olarak değerlendirilebilirken, mühendislik ve fizik gibi daha

deterministik yapıya sahip disiplinlerde genellikle 0,70 ve üzerindeki değerler yeterli görülmektedir (Gupta ve diğ, 2024).

Ortalama karesel hata (MSE) ise model tarafından üretilen tahmin değerleri ile gerçek gözlem değerleri arasındaki farkların karelerinin ortalaması olarak tanımlanan bir performans ölçütüdür (Dumre ve diğ, 2024). MSE'nin temel özelliği, hata değerlerinin karesinin alınması nedeniyle büyük hataların küçük hatalara kıyasla daha yüksek ağırlıkla değerlendirilmesidir (Mohan, 2025). Bu özellik, metriğin aykırı değerlere karşı hassas olmasına yol açmakta ve veri setindeki uç gözlemlerin model performansı üzerindeki etkisini artırmaktadır (Kowalskie, 2025). Bununla birlikte, MSE değerinin bağımlı değişkenin karesi cinsinden ifade edilmesi, sonuçların doğrudan yorumlanmasını zorlaştırmakta ve farklı ölçeklere sahip modeller arasında karşılaştırma yapılmasını güçleştirmektedir (Hassanat ve diğ, 2024).

R^2 ve MSE metrikleri arasındaki temel ayrım, R^2'nin modelin açıklayıcılık düzeyini oransal olarak ifade etmesi, MSE'nin ise tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasına dayanmaktadır (Oredein ve diğ, 2011; Redell, 2019). Modelin açıklayıcılığını değerlendirmek ve bağımsız değişkenlerin etkisini analiz etmek amacıyla R^2 metriği daha ön plana çıkarken, buna karşılık, tahmin doğruluğunun artırılması ve hata minimizasyonunun öncelikli olduğu durumlarda MSE daha uygun bir ölçüt olarak tercih edilmektedir (Piepho, 2018; Mohan, 2025). Bu nedenle literatürde, model performansının daha kapsamlı ve çok boyutlu bir şekilde değerlendirilebilmesi amacıyla farklı performans metriklerinin birlikte kullanılması önerilmektedir (Khoshvaght ve diğ, 2025).

6. ÖN MALİYET TAHMİNİ İÇİN BİR MODEL ÖNERİSİ

6.1 Modelin Genel Yaklaşımı

Bölüm 2 ve bölüm 3.1'de bahsedildiği üzere, inşaat projeleri; fikir geliştirme, tasarım, ihale, yapım ve işletme aşamalarından oluşan çok disiplinli ve karmaşık süreçlerdir. Bu süreç içerisinde özellikle fikir aşamasındayken ortaya konulan maliyet projeksiyonları, proje kararlarının şekillenmesinde kritik bir rol oynamaktadır. Erken aşamada yapılan maliyet tahminleri, kısıtlı veri ve yüksek belirsizlik içermesi nedeniyle zor olmakla birlikte, proje fizibilitesi ve yatırım kararları açısından büyük önem taşımaktadır.

Şekil 3.5'e göre ise, inşaat projelerinde tasarım süreci, projenin temel ihtiyaçlarının belirlendiği ön hazırlık aşaması ve projenin teknik, ekonomik ve yasal açıdan uygulanabilirliğinin değerlendirildiği fizibilite çalışmaları ile başlamaktadır. Devam eden süreçte, konsept tasarım çalışmaları ile projenin genel formu ve fonksiyonel kurgusu ortaya konulmakta; ardından ön proje (avan proje) ve uygulama projeleri hazırlanarak yapıya ilişkin teknik detaylar, malzeme seçimleri ve sistem çözümleri netleştirilmektedir. Bu aşama, mimari, statik, mekanik ve elektrik projelerinin bütüncül olarak ele alındığı ve üretime yönelik teknik bilgilerin oluşturulduğu kapsamlı bir tasarım döngüsünü kapsamaktadır. Son aşamada ise, elde edilen proje dokümanları doğrultusunda keşif ve metraj çalışmaları gerçekleştirilmekte, birim fiyat analizleri yapılarak projenin yaklaşık maliyeti hesaplanmakta ve ihale dokümanları hazırlanmaktadır. Bu süreç ile birlikte, projenin yapım öncesi tüm teknik, idari ve mali hazırlıkları tamamlanarak uygulama aşamasına geçiş için gerekli altyapı oluşturulmaktadır.

Belirtilen süreçlerde, özellikle konsept tasarım aşamasında birçok kritik bilgi henüz netleşmemiş olup bu aşamada genellikle:

- Detaylı uygulama projeleri bulunmamaktadır.
- Kesin metraj bilgileri mevcut değildir.
- Teknik sistemler (mekanik, elektrik vb.) tam olarak belirlenmemiştir.

- Malzeme seçimleri net değildir.
- Nihai tasarım kararları verilmemiştir.

Buna karşılık, aşağıdaki bilgiler ise genellikle mevcuttur:

- Yapı tipi (konut, ticari vb.)
- Kat sayısı ve yaklaşık yapı yüksekliği
- Toplam inşaat alanı
- Arsa bilgileri ve imar kısıtları
- Genel tasarım yaklaşımı

Konsept tasarım aşamasında yapılacak maliyet tahmini önemli bir karar problemini beraberinde getirmektedir. Zira, proje ile ilgili birçok teknik ve detay bilgi henüz netleşmemiş olmasına rağmen, bu kısımda yapılacak tahmine göre yatırımcılar ve karar vericiler tarafından yüksek maliyetli ve geri dönüşü zor kararların alınması gerekmektedir. Bu aşamada alınan kararlar; projeye yatırım yapılıp yapılmayacağı, ihaleye girilip girilmeyeceği ve proje için kaynak tahsis edilip edilmeyeceği gibi kritik stratejik seçimleri kapsayıp yapılan tahminlerin doğruluğu ve güvenilirliği kritik bir önem arz etmektedir.

Konsept tasarım aşamasında mevcut sınırlı parametreler kullanılarak daha güvenilir maliyet tahminleri üretebilen model yaklaşımlarının geliştirilmesi, literatürde önemli bir araştırma boşluğu (research gap) olarak değerlendirilmiş olup, bu boşluğu doldurmak amacıyla konsept tasarım aşamasında maliyet tahminine yönelik daha esnek, veri temelli ve karmaşık ilişkileri modelleyebilen bir maliyet tahmin modeli geliştirilmeye çalışılmıştır.

6.2 Modelin Kapsamı ve Odak Noktası

Bu çalışma kapsamında, inşaat projelerinin fikir ve konsept aşamalarında kullanılabilecek, veri temelli, yüksek doğruluklu ve genellenebilir bir ön maliyet tahmin modeline odaklanılmaktadır. Verilerin sınırlı olması, belirsizliklerin yüksek olması, yapılacak tahminler sonucu alınacak kararların etkilerinin büyük olması gibi durumlar

düşünüldüğünde, önerilecek modelin, detaylı mühendislik hesabına ihtiyaç duymadan, sınırlı parametreleri kullanarak, güvenilir maliyet tahmini üretmesi hedeflenmektedir.

Çalışmada, geleneksel yöntemlerin sınırlılıkları göz önünde bulundurulduğunda, makine öğrenmesi temelli bir yaklaşım benimsenmiştir. Önerilen model, farklı proje tipolojilerine uyum sağlayabilen esnek bir yapıya sahip olup erken aşama karar süreçlerine analitik bir destek mekanizması sunmayı hedeflemektedir.

Bu doğrultuda model geliştirme sürecinde aşağıdaki temel yaklaşım benimsenmektedir:

- Model, farklı yapı türleri (konut, ticari, endüstriyel vb.) için kolayca uyarlanabilir (adaptive) bir yapıda kurgulanmalıdır.
- Parametre setleri, projenin özgün niteliklerine göre değişkenlik gösterebilmelidir.
- Hem parametrik yöntemler hem de makine öğrenmesi teknikleri birlikte kullanılmalıdır.
- Model yalnızca tahmin üretmekle kalmamalı, aynı zamanda karar destek mekanizması olarak çalışmalıdır.
- Veri seti, kullanıcı tarafından farklı kaynaklardan oluşturulabilir, geliştirilebilir ve modele entegre edilebilir.
- Bu yaklaşım, geleneksel sezgisel ve deneyim temelli yöntemlerin ötesine geçerek, veri odaklı ve analitik bir karar verme süreci sağlamaktadır.

6.3 Modelin Faydaları

Önerilen modelin kullanımı ile, özellikle erken aşama karar süreçlerinde önemli avantajlar sağlayacağı düşünülmektedir. İnşaat projelerinde, ihale sürecine girilmeden önce gerçekleştirilen ön değerlendirmeler, firmalar açısından kritik bir filtre mekanizması oluşturmaktadır (Çaydar, 2025). Önerilen model kullanılarak, mevcut sınırlı proje bilgileri ile yaklaşık maliyeti hızlı bir şekilde tahmin edilip, teklif hazırlama sürecine girmenin ekonomik açıdan rasyonel olup olmadığını değerlendirilebilmektedir. Bu durum, gereksiz iş gücü, zaman ve maliyet kayıplarının önüne geçilmesine katkı sağlamaktadır.

Bununla birlikte modelin, kaynak yönetimi açısından da önemli faydalar sunacağı düşünülmektedir. İnsan kaynağı, mühendislik kapasitesi ve zaman gibi sınırlı kaynakların daha verimli kullanılabilmesi, doğru proje seçimi ile doğrudan ilişkilidir (Budayan, 2017). Model kullanımı ile birlikte yaratılması beklenen faydalardan bir tanesini de konsept aşamada yapılan maliyet tahminlerinin, firmaların stratejilerine, kaynaklarına ve kapasitelerine uyan projelere odaklanmasına destek olmaktır.

Yatırım kararları açısından değerlendirildiğinde, modelin sunduğu hızlı ve veri temelli maliyet tahminleri, proje fizibilitesinin daha sağlıklı bir şekilde analiz edilmesine olanak tanımaktadır. Bu yaklaşım ile model, çeşitli proje senaryolarının birbiriyle kıyaslanmasını mümkün kılarak yatırımcıların en rasyonel tercihi yapmalarına rehberlik eder. Ayrıca model, tasarım sürecine de katkı sağlayarak konsept tasarım safhasındaki farklı tasarım alternatiflerinin maliyet üzerindeki etkilerinin analiz edilmesine imkân tanımakta, bu doğrultuda daha ekonomik ve optimize edilmiş çözümlerin geliştirilmesine destek olmaktadır.

Son olarak, erken aşamada gerçekleştirilen bu tür tahminler, ilerleyen aşamalarda ortaya çıkabilecek bütçe sapmalarının minimize edilmesine katkı sağlamaktadır (Liu ve diğ, 2024). Bu yönüyle model, yalnızca bir tahmin aracı olmanın ötesinde, karar destek mekanizması olarak değerlendirilebilecek bütüncül bir yaklaşım sunmaktadır.

6.4 Modelin Genel Yapısı

6.4.1 Projenin yapı tipinin belirlenmesi

Maliyeti oluşturan ana parametreler, yapı tipine göre değişiklik göstermektedir. Bu sebeple, modelin başlangıç noktası olarak, projenin yapı tipi belirlenmelidir. İnşaat sektöründe, konut, ticari ve endüstriyel gibi çeşitli yapı tipleri bulunmakta olup, modelin ilk adımı ele alınan projenin hangi kategoriye ait olduğunun netleştirilmesidir.

6.4.2 Veri oluşturma ve düzenleme

İkinci adım olarak, seçilen parametrelerle uyumlu veri setinin oluşturulmasıdır. Modelin başarısı yalnızca algoritmaya değil, büyük ölçüde veri kalitesine bağlıdır. Özellikle erken aşama maliyet tahmini literatüründe, tarihsel verilerin toplanması, temizlenmesi,

standardize edilmesi ve karşılaştırılabilir hale getirilmesi temel gerekliliklerden biri olarak öne çıkmaktadır (Zhang ve diğ, 2025; Ji ve diğ, 2010).

Bu bileşende modeli kullanan kullanıcıdan beklenen adımlar şunlardır:

- Geçmiş projelerden toplanan maliyet ve parametre verilerinin eksik, tutarsız veya hatalı gözlemlerini ayıklamak
- Değişken adlarını ve ölçü birimlerini standardize etmek
- Farklı yıllara ait maliyetleri ortak bir referans yıla taşınması
- Gerekiyorsa enflasyon, döviz ve bölgesel fiyat farklılıklarını dikkate almak

Bu kısımdaki amaç, modelin eğitileceği veri tabanını mümkün olduğunca temiz, tutarlı ve karşılaştırılabilir hale getirmektir.

6.4.3 Parametre seçimi

Üçüncü adımda ise, seçilen yapı tipine özel, maliyet parametrelerinin belirlenmesi gerekmektedir. Çalışmada önerilen modelin temel prensiplerinden biri, sabit olan ve tüm projelerde aynı şekilde uygulanan bir parametre listesi yerine, yapı tipine özgü olarak değişiklik gösterebilecek dinamik bir parametre yapısı benimsemesidir. Böylelikle modeli kullanan kullanıcıların farklı kombinasyonlarla tahminlerini gerçekleştirmesi ve daha özgür bir şekilde hareket etmesi mümkün olmaktadır. İnşaat sektöründe erken aşama maliyet tahmini çalışmalarında da "cost drivers" yani maliyet sürücülerinin doğru belirlenmesi, model performansının temel belirleyicilerinden biri olarak ele alınmaktadır (Zahran ve diğ, 2014).

Bu doğrultuda şu yaklaşım önerilmektedir:

1. Yapı tipinde maliyeti en çok etkileyen parametrelerin seçilmesi
2. Parametreleri veri erişilebilirliğine göre filtrelenmesi
3. Konsept tasarım aşamada gerçekten bilinebilen değişkenlere öncelik verilmesi

Bu kısımda, farklı yapı türlerinde öne çıkan parametreler aşağıdaki şekilde örneklendirilebilir:

- Konut projelerinde temel tipi, kat alanı, kat sayısı, asansör sayısı gibi parametreler ön plana çıkabilmektedir (Pateriya & Tegar, 2018).
- Endüstriyel yapılarda açıklık mesafesi, yapının alanın veya saçak yüksekliği özellikleri daha belirleyici olabilir (Gušić ve diğ, 2024; Alshibani ve diğ, 2025)
- Ticari yapılarda kullanım yoğunluğu, mekanik sistem ihtiyacı, otopark kapasitesi veya kat alanı dağılımı daha etkili olabilir.

Dolayısıyla modelin genel yapısı, "tek liste" mantığına değil, "uyarlanabilir parametre matrisi" mantığına dayanmaktadır.

6.4.4 Modelleme aşaması

Dördüncü adım, düzenlenmiş veri setini ve belirlenen parametrelerin kullanılarak tahmin modelinin kurulmasıdır. Oluşturulan modelin kullanımında tek bir ya da belirli bir yöntem zorunlu tutulmayıp, aksine veri setine göre farklı yöntemlerin kullanılması ve bu yöntemlerin karşılaştırılması önerilmektedir. Çünkü inşaat maliyet problemlerinde hem doğrusal ilişkiler hem karmaşık, doğrusal olmayan ilişkiler mevcut olabilmektedir (Chen ve diğ, 2025). Güncel araştırmalar, regresyon tekniklerinin yanında Random Forest, sinir ağları ve diğer makine öğrenmesi yöntemlerinin erken aşama maliyet tahmininde güçlü sonuçlar verebildiğini göstermektedir (Meharie & Shaik, 2020; Aslay, 2024).

Bu aşmada ise izlenebilecek adımlar şu şekildedir:

- Başlangıç aşamasında doğrusal regresyon gibi temel bir referans model kurulur
- Decision Tree, Random Forest veya benzeri yöntemler ve/veya alternatif yöntemler geliştirilir
- Veri seti train/test yapılabilmesi için eğitim ve alt kümelere ayrılır
- Farklı modellerin sonuçları karşılaştırılır

Böylelikle, yalnızca modelin kurulması değil, aynı zamanda en uygun yaklaşımın veri temelli bir şekilde seçilebilmesi mümkün olmaktadır (Meharie & Shaik, 2020; Aslay, 2024).

6.4.5 Değerlendirme ve model seçimi

Beşinci adım, oluşturulan modellerin performanslarının değerlendirilmesi ve bu değerlendirmelere göre uygun modelin seçilmesidir. Bu kısımda R^2 ve MSE gibi performans metrikleri model karşılaştırmaları için kullanılabilmektedir. Bölüm R^2 ve MSE'de de belirtildiği gibi, bu metriklerin maliyet tahmin modellerinin doğruluklarının ve hata düzeylerinin değerlendirilmesinde yaygın bir biçimde kullanıldığı görülmektedir. Bununla birlikte son dönemlerdeki çalışmalar ise, maliyet tahminlerinde risk ve güvenirliğin de ham doğruluk kadar önemli olduğunu vurgulamaktadır (Chen ve diğ, 2025).

- Bu aşamada ise izlenebilecek adımlar şu şekildedir:
- Her model için R^2 hesaplanır
- Her model içim MSE hesaplanır
- Farklı veri bölünmelerine göre model kararlılığı incelenir
- Yalnızca yüksek doğruluk veren modeller değil, aynı zamanda en tutarlı model seçilir

Bu kısımdaki amaç, yalnızca çalışan bir model değiş, güvenilen ve tekrarlanabilen bir model önermektir.

6.4.6 Tahmin ve karar süreci

Son adım ise, model sonuçlarının gerçek kararlarda kullanımına karar verilmesidir. Elde edilen sonuçlar, yalnızca bir sayıdan ibaret olmayıp, konsept tasarım aşamasında stratejik kararların desteklenmesi için kullanılmalıdır. Bu kapsamda modelin çıktıları şu amaçlarla kullanılabilir:

- İhaleye girme/girmeme kararları
- Teklif hazırlama için kaynak ayırma kararı
- Proje fizibilitesinin ön değerlendirmesi
- Alternatif tasarım senaryolarının karşılaştırılması
- Yüksek riskli projelerin erken aşamada elenmesi
- Yatırım ve bütçe sınırların ön kontrolü

Bu nedenle modelin son katmanı bir tahmin motorundan çok, “erken aşama karar destek aracı” olarak düşünülmelidir.

6.5 Modelin Uygulama Aşamaları

Model, takip edilmesi gereken belirli aşamaları olan farklı kullanıcılar tarafından farklı amaçlarla kullanıp geliştirebilen, standart bir rehber olarak kurgulanmaktadır. Modelin sistematik bir şekilde hayata geçirilmesi için kullanılması önerilen yol haritası Şekil 6.1’deki gibidir. Kullanıcılar bu yol haritasını takip ederek modeli başarıyla kurgulayabileceklerdir.

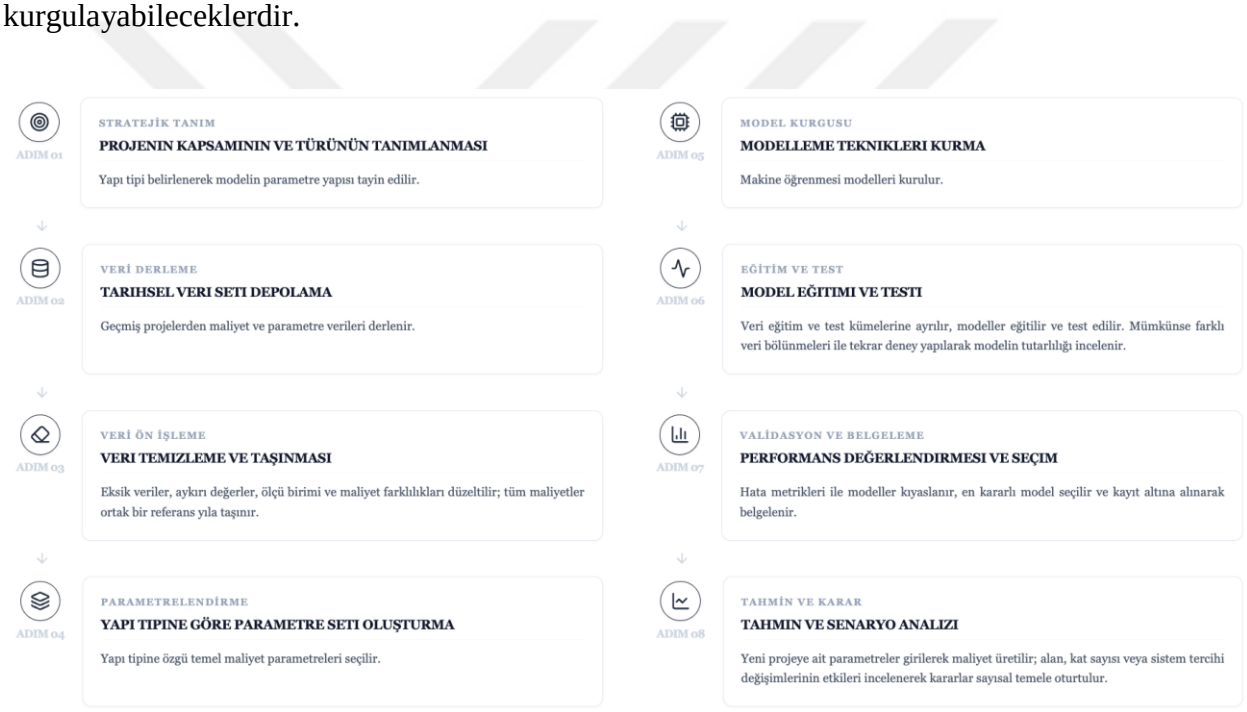

Şekil 6.1 : Model yol haritası.

7. ÖN MALİYET TAHMİN MODELİNİN UYGULANMASI: KONUT PROJELERİ ÖRNEĞİ

Önerilen yaklaşımın pratikte nasıl uygulanabileceğini göstermek için bir vaka çalışması yapıldı. Bu çalışmada modelin her aşaması teker teker uygulanmış olup, örneğin incelenmesiyle birlikte, kullanıcının modeli daha kolay uygulayabilmesi hedeflenmiştir.

7.1 Proje Kapsamının ve Türünün Tanımlanması

Modelin uygulama adımlarından ilk adım olarak proje kapsamının ve türünün tanımlanması yani yapı tipinin belirlenmesidir. Örnek çalışmamızda, tarafımızca ulaşılabilmesi en mümkün projeler, yapı tipi, konut olan projeler olmuştur. Bu nedenle bu çalışmada yapı tipi olarak konut projeleri seçilmiştir.

7.2 Tarihsel Veri Seti Depolama

Modelin uygulama adımlarından. 2.'si seçilen yapı tipine uygun geçmişten günümüze olan projelerin veri seti oluşturmak amacıyla depolanmasıdır. Bu kısımda örnek çalışmanın veri seti, 2010–2025 yılları arasında kamuya açık olarak yayımlanmış konut projelerine ait ihale ve proje verileri Elektronik Kamu Alımları Platformu (EKAP) üzerinden temin edilmiştir. Şekil 7.1, EKAP sitesinin araştırma yapılan arayüzünü göstermektedir.

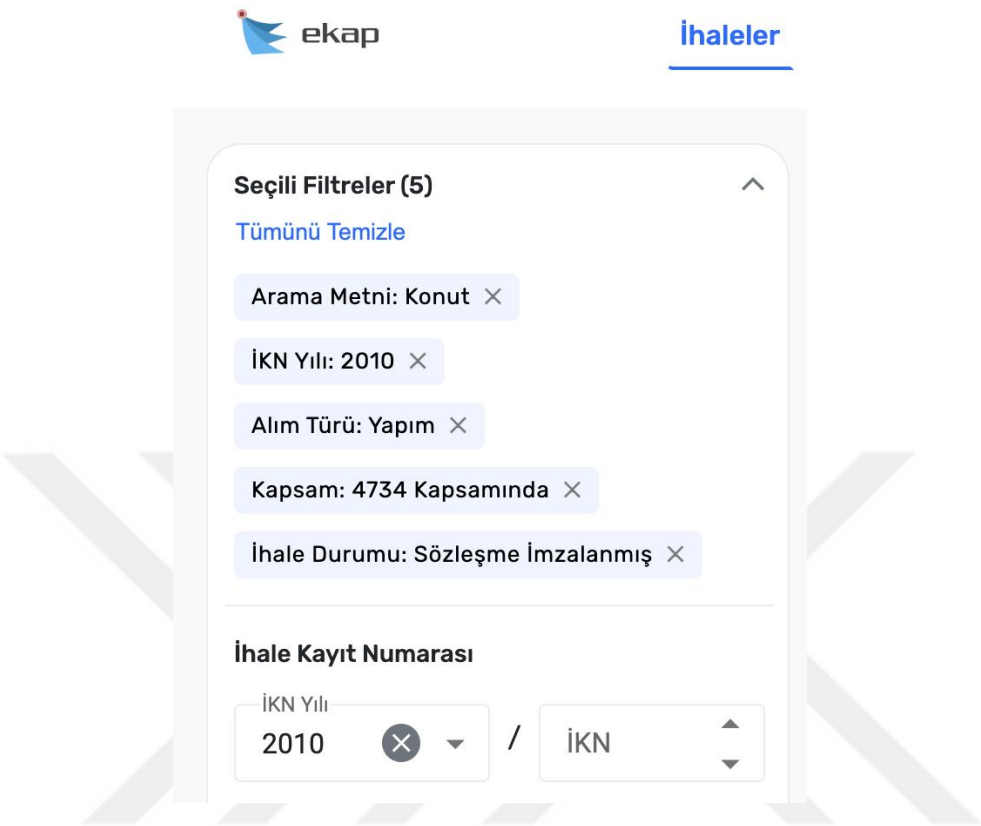

Şekil 7.1 : EKAP araştırma arayüzü.

İncelenen projeler yalnızca konut yapılarını kapsamakta olup, her projeye ait ihale bedeli ve teknik özellikler veri setine dahil edilmiştir. Bu süreç sonunda yalnızca konut projelerinden oluşan bir ham veri seti oluşturulmuştur. Bu veri seti oluşturulurken her proje incelenmiş ve projelerden elde edilen verilere göre teknik özellikler; kategori, proje adı, tip, lokasyon, yıl, blok, temel tipi, yapı sınıfı, beton sınıfı, zemin tipi, kat adedi, yapı şekli, daire büyüklüğü, kazı derinliği, kat yüksekliği, bodrum, çatı katı, dublex çatı, kat alanı, inşaat alanı, asansör ve kattaki daire adedi sütunlarından oluşturulmuştur. Projelerde, ilgili sütun ile ilgili bilgi mevcut ise bu hücreler doldurulmuş olup, bilgi mevcut değil ise ilgili hücre boş bırakılmıştır. Şekil 7.2, oluşturulan ham veri setinin proje teknik özelliklerine göre ayrıştırılmasına bir örnek olarak verilmiştir.

Kategori	Proje Adı	Lokasyon	Yıl	Temel Tipi	BLOK	Kat Alanı	İnşaat Alanı	Beton Sınıfı	Kat Yüksekliği	Kazı Derinliği	Asansör

Şekil 7.2 : Veri seti oluşturulması.

7.3 Veri Temizleme ve Taşınması

Modelin uygulama adımlarından 3. adım verilerin temizlenmesi ve farklı yıllara ait maliyetlerin ortak bir yıla taşınmasıdır. Farklı yıllara ait maliyet verilerinin karşılaştırılabilir hale getirilebilmesi amacıyla maliyetler 2025 yılı fiyat seviyesine uyarlanmıştır. Bu kapsamda, Çevre Şehircilik ve İklim Değişikliği Bakanlığını tarafından yayımlanan Yapı Yaklaşık Birim Maliyetleri tabloları kullanılmıştır.

Bu veri kaynağı kullanılarak dönüşüm katsayıları hesaplanmış ve geçmiş yıllara ait proje maliyetleri 2025 yılı bazına taşınmıştır. Böylece modelleme sürecinde homojen ve karşılaştırılabilir bir maliyet veri seti elde edilmiştir.

7.3.1 Yapı yaklaşık birim maliyetleri incelenmesi:

Farklı yıllara ait proje maliyetlerinin karşılaştırılabilir hale getirilebilmesi amacıyla, maliyetlerin ortak bir referans yıla dönüştürülmesi gerekmektedir. Bu doğrultuda T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından Resmî Gazete ‘de yayımlanan ve genellikle yıllık periyotlarda, bazı durumlarda ise yıl içerisinde revize edilen Mimarlık ve Mühendislik Hizmet Bedellerinin Hesabında Kullanılacak Yapı Yaklaşık Birim Maliyetleri Hakkında Tebliğ dokümanları kullanılmıştır. Çalışma kapsamında, 2011-2025 yılları arasındaki tebliğlerde yer alan birim maliyet verileri derlenmiş ve analiz edilmek üzere tablolaştırılmıştır.

Yapı yaklaşık birim maliyetlerinin belirlenmesinde kullanılan yapı sınıfı ve grup tanımları yıllar içerisinde değişiklik gösterebilmektedir. Bu durum, farklı yıllara ait verilerin doğrudan karşılaştırılmasını güçleştirmektedir. Bu nedenle, çalışmada konut yapıları, yapı yüksekliği kriteri esas alınarak yeniden sınıflandırılmıştır.

Bu kapsamda konutlar üç ayrı sınıf altında ele alınmıştır:

a. Yapı yüksekliği 21,50 m ve altındaki yapılar,
b. Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapılar (30,50 m dâhil),
c. Yapı yüksekliği 30,50 m ile 51,50 m arasında olan yapılar (51,50 m dâhil).

Oluşturulan bu sınıflandırma doğrultusunda farklı yıllara ait birim maliyet verileri Şekil 7.3, Şekil 7.4 ve Şekil 7.5’ de sunulmuştur. Ancak, yıllar arasında meydana gelen fiyat değişimleri nedeniyle bu verilerin doğrudan karşılaştırılması mümkün olmamaktadır. Bu

nedenle, dönemler arası karşılaştırılabilirliğin sağlanması amacıyla tüm maliyet verileri 2025 yılı referans alınarak dönüştürülmüştür. Bu kapsamda, her bir yılın birim maliyet değeri 2025 yılı maliyetine oranlanarak dönüşüm katsayıları hesaplanmış ve elde edilen bu katsayılar kullanılarak maliyetler ortak bir referans düzeyine taşınmıştır. Söz konusu dönüşüm sonucunda elde edilen, yapı tiplerine göre düzenlenmiş katsayı tabloları ise Çizelge 7.1, Çizelge 7.2 ve Çizelge 7.3 'de sunulmaktadır. Bu yaklaşım ile, yıllar arasında değişkenlik gösteren yapı sınıfı tanımlarının neden olduğu uyumsuzluk giderilmiş ve veri seti homojen hale getirilerek karşılaştırılabilirlik sağlanmıştır.

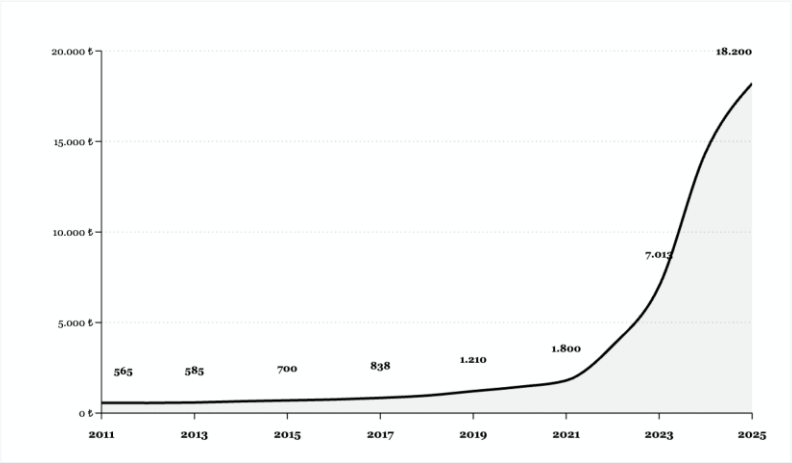

YIL	MALIYET (₺/M²)
2025	18.200,00
2024	14.400,00
2023	7.012,50
2022	3.731,25
2021	1.800,00
2020	1.450,00
2019	1.210,00
2018	966,00
2017	838,00
2016	750,00
2015	700,00
2014	650,00
2013	585,00
2012	560,00
2011	565,00

Şekil 7.3 : Yapı yüksekliği 21,50 m ve altındaki yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

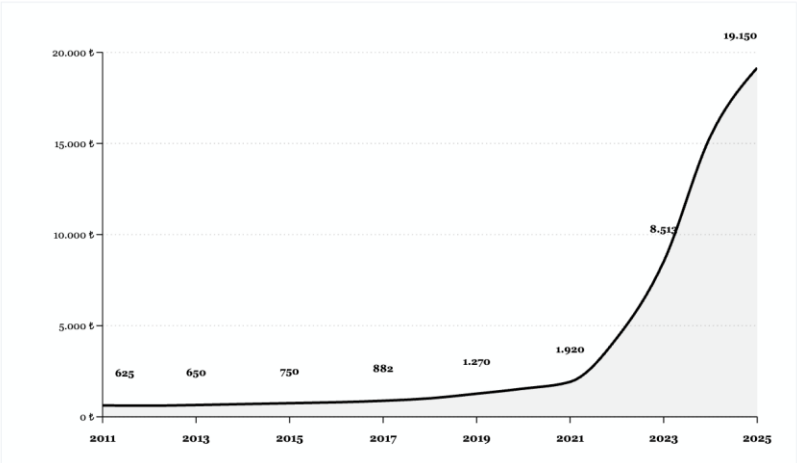

YIL	MALIYET (₺/M²)
2025	19.150,00
2024	15.400,00
2023	8.512,50
2022	4.332,50
2021	1.920,00
2020	1.550,00
2019	1.270,00
2018	1.016,00
2017	882,00
2016	800,00
2015	750,00
2014	700,00
2013	650,00
2012	615,00
2011	625,00

Şekil 7.4 : Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

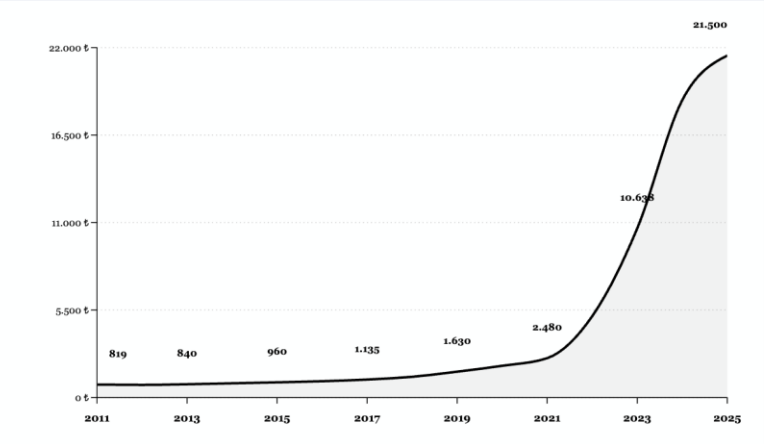

YIL	MALIYET (₺/M²)
2025	21.500,00
2024	18.700,00
2023	10.637,50
2022	5.118,75
2021	2.480,00
2020	2.000,00
2019	1.630,00
2018	1.308,00
2017	1.135,00
2016	1.030,00
2015	960,00
2014	900,00
2013	840,00
2012	800,00
2011	819,00

Şekil 7.5 : Yapı yüksekliği 30,50 m ile 51,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

Çizelge 7.1 : 2011- 2025 yapı yüksekliği 21,50 m ve altındaki yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

Yıl	Q1	Q2	Q3	Q4	Ortalama
2011	32,21	32,21	32,21	32,21	32,21
2012	32,50	32,50	32,50	32,50	32,50
2013	31,11	31,11	31,11	31,11	31,11
2014	28,00	28,00	28,00	28,00	28,00
2015	26,00	26,00	26,00	26,00	26,00
2016	24,27	24,27	24,27	24,27	24,27
2017	21,72	21,72	21,72	21,72	21,72
2018	18,84	18,84	18,84	18,84	18,84
2019	15,04	15,04	15,04	15,04	15,04
2020	12,55	12,55	12,55	12,55	12,55
2021	10,11	10,11	10,11	10,11	10,11
2022	6,07	6,07	4,26	3,91	5,08
2023	2,87	2,87	2,02	2,02	2,44
2024	1,26	1,26	1,26	1,26	1,26
2025	1,00	1,00	1,00	1,00	1,00

Çizelge 7.2 : Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

Yıl	Q1	Q2	Q3	Q4	Ortalama
2011	30,64	30,64	30,64	30,64	30,64
2012	31,14	31,14	31,14	31,14	31,14
2013	29,46	29,46	29,46	29,46	29,46
2014	27,36	27,36	27,36	27,36	27,36
2015	25,53	25,53	25,53	25,53	25,53
2016	23,94	23,94	23,94	23,94	23,94

Çizelge 7.2 (devam) : Yapı yüksekliği 21,50 m ile 30,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

Yıl	Q1	Q2	Q3	Q4	Ortalama
2017	21,71	21,71	21,71	21,71	21,71
2018	18,85	18,85	18,85	18,85	18,85
2019	15,08	15,08	15,08	15,08	15,08
2020	12,35	12,35	12,35	12,35	12,35
2021	9,97	9,97	9,97	9,97	9,97
2022	5,98	5,98	4,18	3,02	4,79
2023	2,81	2,81	1,88	1,88	2,34
2024	1,24	1,24	1,24	1,24	1,24
2025	1,00	1,00	1,00	1,00	1,00

Çizelge 7.3 : Yapı yüksekliği 30,50 m ile 51,50 m arasında olan yapıların yaklaşık maliyet değişimleri (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2011-2025).

Yıl	Q1	Q2	Q3	Q4	Ortalama
2011	26,25	26,25	26,25	26,25	26,25
2012	26,88	26,88	26,88	26,88	26,88
2013	25,60	25,60	25,60	25,60	25,60
2014	23,89	23,89	23,89	23,89	23,89
2015	22,40	22,40	22,40	22,40	22,40
2016	20,87	20,87	20,87	20,87	20,87
2017	18,94	18,94	18,94	18,94	18,94
2018	16,44	16,44	16,44	16,44	16,44
2019	13,19	13,19	13,19	13,19	13,19
2020	10,75	10,75	10,75	10,75	10,75
2021	8,67	8,67	8,67	8,67	8,67
2022	5,24	5,24	3,66	3,36	4,38
2023	2,44	2,44	1,73	1,73	2,08
2024	1,15	1,15	1,15	1,15	1,15
2025	1,00	1,00	1,00	1,00	1,00

7.4 Yapı Tipine Göre Parametre Seti Oluşturulması

Modelin uygulama adımlarından 4. adım yapı tipine göre parametre seti oluşturulmasıdır. Bu aşamada projelerden elde edilen teknik ve nicel değişkenler üzerinde regresyon ve korelasyon analizleri uygulanmıştır. Yapılan analizler sonucunda modele dahil edilecek parametre seti aşağıdaki altı değişkene indirgenmiştir:

- Kat alanı
- Yapı yüksekliği

- Kat adedi
- Bodrum
- Asansör adedi
- Kazı derinliği

Bu parametreler, maliyet üzerinde istatistiksel olarak anlamlı etki gösteren değişkenler olarak belirlenmiştir. Parametrik yöntemlerin doğruluğu büyük ölçüde veri miktarına ve değişken seçimine bağlıdır; yanlış parametre seçimi model başarısını düşürebilmektedir (Çelik, 2006).

Şekil 7.6' de, seçilen parametreler üzerinde yapılan korelasyon analizi sonuçlarına göre, 2025 yılına taşınmış blok maliyeti ile bağımsız değişkenler arasındaki ilişkiler incelenmiştir. Yapı yüksekliğinin (r = 0,85) maliyet ile en güçlü pozitif ilişkiye sahip değişken olduğu görülmektedir. Bunu sırasıyla kat adedi (r = 0,80), kat alanı (r = 0,75) ve asansör değişkeni (r = 0,72) izlemektedir. Bu bulgular, yapının hem düşey hem de yatay büyüklüğünü temsil eden parametrelerin maliyet üzerinde belirleyici rol oynadığını göstermektedir. Buna karşılık, bodrum kat sayısı (r = -0,04) ve kazı derinliği (r = 0,01) değişkenlerinin maliyet ile olan ilişkilerinin oldukça düşük seviyede kaldığı tespit edilmiştir. Bu durum, incelenen veri setinde maliyet değişkenliğinin büyük ölçüde yer üstü yapı elemanlarından kaynaklandığını ortaya koymaktadır.

Diğer yandan Şekil 7.6'da bağımsız değişkenler arasındaki ilişkiler incelendiğinde, bodrum kat sayısı ile kazı derinliği arasında çok yüksek düzeyde pozitif bir korelasyon (r = 0,96) bulunduğu görülmektedir. Benzer şekilde, yapı yüksekliği ile kat adedi arasında güçlü bir ilişki (r = 0,88) tespit edilmiş olup, bu iki değişkenin yapısal olarak birbirine bağlı olduğu anlaşılmaktadır. Ayrıca, asansör değişkeni ile kat adedi arasındaki yüksek korelasyon (r = 0,78), kat sayısındaki artışın düşey sirkülasyon ihtiyacını artırdığını ve bunun da asansör gereksinimi üzerinden maliyete dolaylı olarak yansıdığını göstermektedir.

Şekil 7.7'de verilen regresyon analizi örneğine göre, elde edilen eğim katsayısı ($3{,}119\times10^{6}$), yapı yüksekliği ile proje maliyeti arasında pozitif yönlü ve anlamlı bir ilişki bulunduğunu göstermektedir. Bu katsayıya göre, yapı yüksekliğinde meydana gelen her 1

metrelik artışın, proje maliyetinde ortalama yaklaşık 3,12 milyon TL'lik bir artışa karşılık geldiği anlaşılmaktadır. Bu durum, yapı yüksekliğinin maliyet üzerindeki etkisinin önemli ve belirleyici bir faktör olduğunu ortaya koymaktadır. Modelde yer alan sabit terim ise (-1,332×10^7) ise regresyon doğrusunun matematiksel olarak tanımlanabilmesi için gerekli bir parametre olup, bağımsız değişkenin sıfır olduğu noktadaki teorik maliyet değerini ifade etmektedir. Ancak, inşaat projeleri açısından fiziksel bir karşılığı bulunmamakta olup, modelin geçerlilik aralığı içerisinde yorumlanması gerekmektedir.

Benzer şekilde Şekil 7.7'deki diğer bir değer olan R^2 değeri ise, yapı yüksekliğinin maliyet üzerindeki açıklayıcılık düzeyini gösterip belirleyicilik katsayısı (R^2) 0,7196 olarak hesaplanmıştır. Bu değer, proje maliyetindeki toplam varyansın yaklaşık %71,96'sının yalnızca yapı yüksekliği değişkeni ile açıklanabildiğini göstermektedir. Elde edilen bu oran, tek değişkenli bir model için yüksek bir açıklayıcılık düzeyine işaret etmekte ve modelin güvenilirliğini desteklemektedir.

Şekil 7.6 : Korelasyon matrisi.

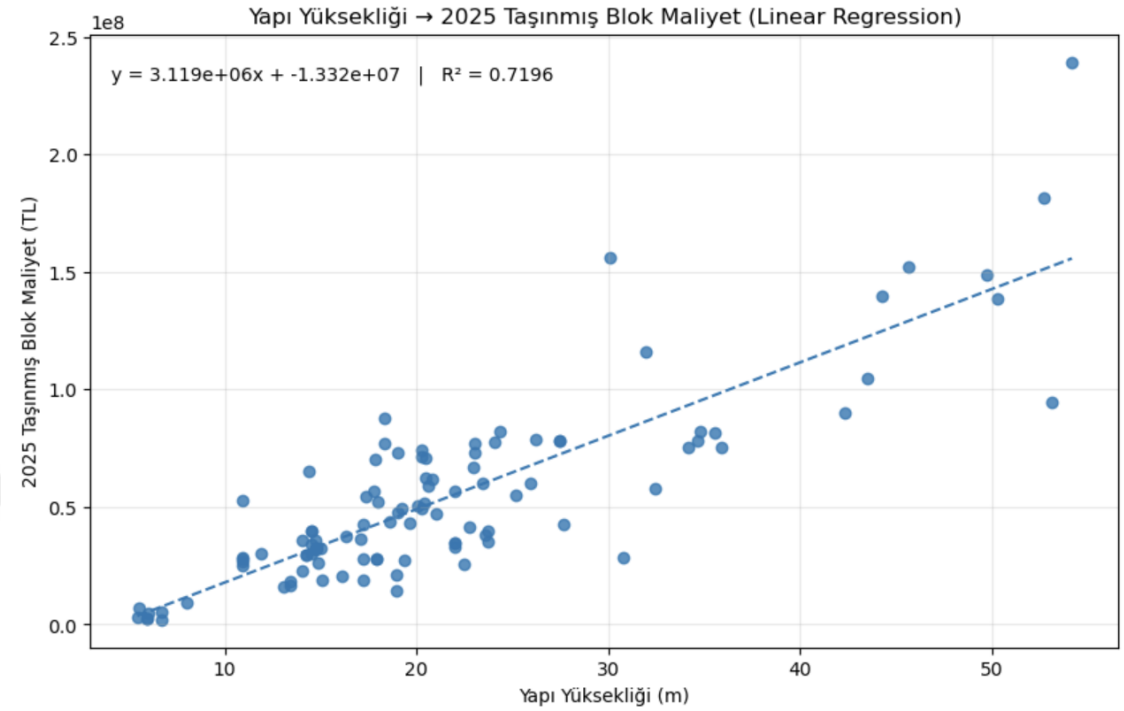

Şekil 7.7 : Yapı yüksekliği – maliyet regresyon analizi.

7.5 Modelleme Teknikleri Kurma

Modelin uygulama adımlarından 5. adım modelleme teknikleri kurmadır. Bu kısım kapsamında modelleme sürecinde makine öğrenmesi yaklaşımlarına yönelinmiştir. Makine öğrenmesi, geçmiş gözlemlerden öğrenerek minimum insan müdahalesi ile tahmin yapabilen sistemlerin geliştirilmesini amaçlamaktadır (Özmaden & Erdal, 2020). Veri setinin büyüklüğü ve yapısı dikkate alınarak aşağıdaki denetimli öğrenme algoritmaları kullanılmıştır:

- Linear Regression
- Random Forest
- Support Vector Regression
- Decision Tree
- Polynominal Regression (deg:2)

7.6 Model Eğitimi ve Testi

Modelin uygulama adımlarından 6. adım model eğitimi ve testidir.

İlk aşamada, farklı regresyon modellerinin veri seti üzerindeki başlangıç performanslarını karşılaştırmak amacıyla eğitim verisi ve tüm veri seti üzerinden R^2 değerleri hesaplanmıştır (Çizelge 7.4). Bu sayede modellerin açıklama güçleri ön değerlendirmeye tabi tutulmuş, ayrıca performans sıralamaları oluşturularak hangi modellerin sonraki analiz aşamalarında daha ayrıntılı incelenmesi gerektiği belirlenmiştir. Ancak bu tablo, tek bir veri bölünmesine dayandığı için model kararlılığı ve genelleme performansı açısından nihai değerlendirme aracı olarak kullanılmamış, sonraki aşamada tekrar eden train–test bölünmeleri ile desteklenmiştir.

Çizelge 7.4 : Örnek eğitim verisi ve genel veri seti r^2 karşılaştırmaları.

Model Adı	R^2 (Eğitim)	R^2 (Tüm Veri)	Sıralama (Eğitim)	Sıralama (Tüm Veri)	Ortalama Sıralama
Decision Tree (DT)	0,9656	0,9526	1	2	1,5
Random Forest (RF)	0,9646	0,9537	2	1	1,5
Polynomial	0,9379	0,9088	3	3	3,0
Linear Regression (LR)	0,8517	0,8656	4	4	4,0
Support Vector Regression (SVR)	-0,0670	-0,0667	5	5	5,0

Test kümesinde model performanslarının proje bazında daha ayrıntılı incelenebilmesi amacıyla, her bir gözlem için yüzdesel hata oranları hesaplanmış ve modeller karşılaştırmalı olarak değerlendirilmiştir (Çizelge 7.5). Bu tablo sayesinde yalnızca genel performans düzeyi değil, aynı zamanda modellerin farklı projelerdeki hata dağılımları ve tutarlılıkları da gözlemlenmiştir. Elde edilen sonuçlar, Random Forest modelinin test grubunda daha düşük ve dengeli hata oranları ürettiğini, buna karşılık SVR ve Polynomial Regression modellerinin bazı gözlemlerde oldukça yüksek sapmalar gösterdiğini ortaya koymuştur. Bu bulgu, model değerlendirmesinde yalnızca R^2 değerlerinin değil, proje bazlı hata davranışlarının da dikkate alınması gerektiğini göstermektedir.

Çizelge 7.5 : Örnek test verisine göre model performansları.

Kod	Gerçek Değer (₺)	Hata% LR	Hata% RF	Hata% SVR	Hata% PR	Hata% DT
0	115.816.264	6,87	12,87	62,48	7,28	32,89
1	9.554.143	40,12	19,56	354,81	8,43	58,57
2	4.732.573	136,32	47,42	818,17	9,68	16,37

Çizelge 7.5 (devam) : Örnek test verisine göre model performansları.

Kod	Gerçek Değer (₺)	Hata% LR	Hata% RF	Hata% SVR	Hata% PR	Hata% DT
3	138.443.170	8,49	11,65	68,61	23,66	0,81
4	18.686.692	59,32	3,59	132,53	11,16	11,31
5	29.761.301	16,99	6,06	46,01	11,15	8,09
6	37.255.057	18,86	2,35	16,64	1,78	13,65
7	152.007.204	11,87	11,60	71,41	3,92	8,18
8	104.844.850	24,49	32,85	58,55	48,48	21,73
9	34.638.576	13,15	0,33	25,45	4,91	12,43
10	2.281.378	526,63	43,15	1804,68	52,63	73,49
11	89.793.158	17,28	6,11	51,61	2,29	14,61
12	40.033.980	7,60	13,05	8,54	1,92	19,64
13	18.525.541	15,96	17,16	134,56	18,01	10,54
14	28.039.826	41,18	5,63	54,97	32,45	8,17
15	81.595.968	23,35	2,15	46,75	54,02	4,75
16	65.310.813	17,40	27,30	33,47	37,01	0,38
17	25.697.246	2,81	8,20	69,10	13,39	18,03
18	35.215.164	5,74	9,85	23,39	4,96	13,87
19	57.732.917	23,88	6,06	24,73	5,55	10,86
20	53.021.146	51,19	49,85	18,05	48,10	54,91
Ortalama Hata (%)		50,93	16,04	186,88	19,09	19,68

Çizelge 7.6, modellerin performansının tek bir veri bölünmesine bağlı kalıp kalmadığını değerlendirmek amacıyla oluşturulmuştur. Bu kapsamda veri seti, 10 farklı random state kullanılarak tekrar eden şekilde train–test olarak bölünmüş ve her bir bölünmede modellerin test performansları R^2 metriği ile hesaplanmıştır. Böylece modellerin yalnızca ortalama performansı değil, aynı zamanda farklı veri dağılımlarına karşı ne kadar stabil davrandığı analiz edilmiştir.

Elde edilen sonuçlar ve Şekil 7.8, incelendiğinde Random Forest modelinin çoğu veri bölünmesinde yüksek ve tutarlı performans sergilediği görülmektedir. Linear Regression modeli genel olarak stabil sonuçlar üretirken, Decision Tree modelinin bazı bölünmelerde performansının belirgin şekilde değiştiği gözlemlenmiştir. Polynomial Regression modelinde ise veri bölünmelerine bağlı olarak oldukça değişken sonuçlar elde edilmiş, bazı durumlarda aşırı düşük performans değerleri görülmüştür. SVR modeli ise çoğu bölünmede düşük veya negatif performans üretmiştir. Bu bulgular, Random Forest modelinin genelleme kabiliyeti açısından diğer modellere kıyasla daha güvenilir bir yapı sunduğunu göstermektedir.

Çizelge 7.6 : Rastgele 10 farklı eğitim – test verisine göre model performansları.

Sıra	Rastgelelik Durumu	Linear Regression	Random Forest	SVR	Polynomial	Decision Tree
1	0	0,842	0,777	-0,199	0,044	0,496
2	1	0,804	0,768	-0,155	0,856	0,793
3	2	0,674	0,723	-0,250	0,728	0,425
4	3	0,801	0,832	0,000	0,585	0,313
5	4	0,776	0,842	-0,039	0,527	0,021
6	5	0,798	0,758	-0,134	0,812	0,591
7	6	0,873	0,913	-0,204	0,806	0,809
8	7	0,849	0,895	-0,031	-17,476	0,768
9	8	0,874	0,860	-0,098	-12,866	0,775
10	9	0,592	0,638	-0,146	0,640	0,249

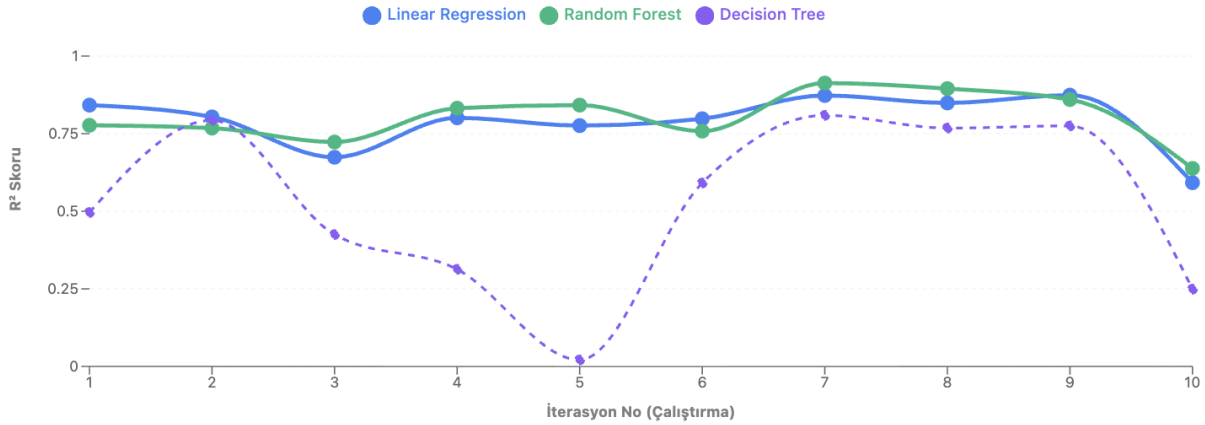

Şekil 7.8 : İterasyonlar boyunca lineer regression, random forest, decision tree modellerine ait r^2 değişimleri.

Sonuç olarak bu aşamada, model performansının daha güvenilir ve genellenebilir biçimde değerlendirilebilmesi amacıyla train–test ayrımı yöntemi tekrarlı olarak uygulanmış ve analizler 10 farklı train–test kombinasyonu üzerinden gerçekleştirilmiştir. Bu yaklaşım sayesinde model sonuçlarının belirli bir veri bölünmesine bağımlı kalmasının önüne geçilmiştir. Denetimli öğrenme kapsamında regresyon tabanlı algoritmalar tercih edilmiş olup, model eğitimi için veri seti eğitim ve test olmak üzere ikiye ayrılmıştır (James ve diğ, 2023). Modellerin performansları R^2 (belirleme katsayısı) ve MSE (hata sapmaları) ölçütleri üzerinden değerlendirilmiş, ayrıca farklı veri bölünmelerinde elde edilen sonuçlar dikkate alınarak modellerin kararlılığı ve genelleme kabiliyetleri analiz edilmiştir.

7.7 Performans Değerlendirmesi ve Seçim

Modelin uygulama adımlarından 7. adım performans değerlendirmesi ve seçimdir.

Tekrarlı train–test bölünmeleri sonucunda elde edilen ortalama performans değerleri Çizelge 7.7'de incelendiğinde, Random Forest modelinin en yüksek ortalama R^2 değeri ve düşük standart sapma ile en dengeli performansı sunduğu görülmektedir. Linear Regression modeli ikinci sırada yer almakta ve düşük varyans değeri ile stabil bir model davranışı sergilemektedir. Decision Tree modelinin ortalama performansı daha düşük olup, yüksek standart sapma değeri modelin veri bölünmelerine karşı daha duyarlı olduğunu göstermektedir. SVR modelinin ortalama performansı negatif gerçekleşmiş, Polynomial Regression modelinde ise çok yüksek standart sapma ve aşırı düşük ortalama değerler gözlemlenmiştir. Bu sonuçlar, özellikle Random Forest modelinin hem açıklama gücü hem de kararlılık açısından diğer modellere kıyasla daha güvenilir bir yapı sunduğunu ortaya koymaktadır.

Çizelge 7.7 : Model performans sonuçları.

Model Tanımı	Ortalama R^2	Standart Sapma	Sıralama (Ort.)
Random Forest	0,801	0,084	1
Linear Regression	0,788	0,090	2
Decision Tree	0,524	0,272	3
Suppor Vector	-0,126	0,083	4
Polynomial	-2,534	6,752	5

Çalışma sonucunda geliştirilen model, konsept aşamasındaki konut projeleri için ön maliyet tahmini amacıyla kullanılabilecek bir tahmin aracı sunmaktadır. Model, oluşturulan veri setine dayalı olarak geliştirilmiş olup; farklı yapı tipleri, veri setleri veya parametre kombinasyonları için uyarlanabilir bir çerçeve sunmaktadır. Bu yönüyle çalışma, erken tasarım aşamasında karar vericilere maliyet öngörüsü sağlayan veri temelli bir yaklaşım önermektedir.

8. SONUÇ VE ÖNERİLER

Bu çalışma kapsamında önerilen makine öğrenmesi tabanlı model, konut projelerinde erken aşama maliyet tahminine yönelik geleneksel parametrik yaklaşımların sınırlılıklarını azaltmayı ve farklı makine öğrenmesi modellerinin performanslarını karşılaştırarak, veri temelli bir tahmin mekanizması sunmayı amaçlamaktadır.

Analiz bulguları, maliyet oluşumunun özellikle yapı yüksekliği, kat sayısı, kat alanı ve asansör sayısı gibi projenin ölçeğini ve düşey gelişimini temsil eden değişkenlerle güçlü bir ilişki sergilediğini göstermektedir. Buna karşılık, bodrum sayısı ve kazı derinliği gibi parametrelerin tek başına maliyet değişimini açıklama gücünün daha sınırlı olduğu görülmüştür.

Parametrik ve regresyon temelli yöntemlerin erken aşama maliyet tahminlerinde etkili bir şekilde kullanılabildiği literatürde de belirtilmekte olup (Yang & Moon, 2022), bu çalışmada elde edilen bulgular da bu yaklaşımı desteklemektedir. Bununla birlikte, makine öğrenmesi algoritmalarının karmaşık ve doğrusal olmayan ilişkileri modelleyebilme kapasitesinin tahmin performansını artırabildiği ifade edilmektedir (Shamim ve diğ, 2025). Bu kapsamda gerçekleştirilen model karşılaştırmaları sonucunda, Random Forest modelinin hem yüksek açıklayıcılık düzeyi hem de farklı veri bölünmelerinde sergilediği istikrarlı performans sayesinde en dengeli sonuçları sağlayan yöntem olduğu belirlenmiştir.

Çalışma kapsamında geliştirilen model, konsept aşamasındaki konut projelerinde ön maliyet tahmini yapılmasına olanak tanıyan bir tahmin aracı niteliği taşımaktadır. Model, oluşturulan veri seti temel alınarak geliştirilmiş olup farklı yapı türleri, veri kümeleri veya parametre kombinasyonlarına uyarlanabilecek esnek bir yapı sunmaktadır. Bu yönüyle çalışma, erken tasarım aşamasında karar vericilere maliyet öngörüsü sağlayan veri temelli bir yaklaşım önermekte ve proje geliştirme sürecinde daha bilinçli planlama yapılmasına katkı sağlamaktadır. Ayrıca gelecekte veri setinin genişletilmesi, farklı proje türlerinin

modele dahil edilmesi ve daha gelişmiş makine öğrenmesi yöntemlerinin uygulanması ile tahmin doğruluğunun daha da artırılması mümkün olabilecektir.

KAYNAKLAR

AACE International. (2005, February 2). *Cost estimate classification system – As applied in engineering, procurement, and construction for the process industries (Recommended Practice No. 18R-97).* AACE International.

Abdullayeva, L. (2018). Ergenlerde sosyal zekânın gelişiminde çevresel faktörler. *Akademik Tarih ve Düşünce Dergisi*, 5(14), 234–247.

Addis, G. (2023). *Impact of integrated land use planning on road infrastructure development in Addis Ababa City* (Doctoral dissertation, Addis Ababa University, School of Graduate Studies).

Adinyira, E., Adjei, E. A. G., Agyekum, K., & Fugar, F. D. K. (2021). Application of machine learning in predicting construction project profit in Ghana using support vector regression algorithm (SVRA). *Engineering, Construction and Architectural Management, 28*(5), 1491–1514.

Akhtar, Z. B. (2025). Artificial intelligence (AI) informatics within pattern recognition: An investigative exploration. *Int J Math Expl & Comp Edu, 2*(2), 1–15.

Alazawy, S. F. M., Ahmed, M. A., Raheem, S. H., Imran, H., Bernardo, L. F. A., & Pinto, H. A. S. (2025). Explainable machine learning to predict the construction cost of power plant based on random forest and shapley method. *CivilEng*, *6*(2), 21.

Alshibani, A., Almuhtaseb, O., Mohammed, A., & Ghaithan, A. M. (2025). A regression-based model for parametric cost estimation of industrial steel structures. *Journal of Civil Engineering and Management, 31*(1), 71–84.

Arabacı, F., & Duyguluer, F. (2011). *Tarif, analiz ve birim fiyatlar*. Bayındırlık ve İskân Bakanlığı Yüksek Fen Kurulu Başkanlığı.

Ashraf, A., Rady, M., & Mahfouz, S. Y. (2024). Price prediction of residential buildings using random forest and artificial neural network. *HBRC Journal, 20*(1), 23–41.

Aslay, S. E. (2024). Estimating contract value using structural parameters: A machine learning approach with data preprocessing. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 15*(3), 755–765.

Basak, D., Pal, S., & Patranabis, D. C. (2007). Support vector regression. Neural Information Processing: *Letters and Reviews, 11*(10), 203–224.

Breiman, L. (2001). Random forests. *Machine Learning, 45*(1), 5-32.

Bostancıoğlu, E. (1999). *Konut binalarının ön tasarım evresinde maliyeti etkileyen faktörler ve faktörlere dayalı bir maliyet tahmin yöntemi* (Doktora tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü).

Budayan, C. (2017). İstanbul bölgesinde çalışan inşaat firmalarında proje portföy yönetimi uygulamaları. *Politeknik Dergisi, 20*(3), 699–709.

Chandanshive, V. B., & Kambekar, A. R. (2021). Prediction of building construction project cost using support vector machine. *Industrial Engineering and Strategic Management, 1*(1), 31-42.

Chen, L., Tiang, S. S., Chong, K. S., Sharma, A., Berghout, T., & Lim, W. H. (2025). Predicting construction costs with machine learning: A comparative study on ensemble and linear models. *Journal of Electronics, Electromedical Engineering, and Medical Informatics, 7*(3), 624–645.

Chen, L., Xu, C., Lim, W. H., Sharma, A., Tiang, S. S., Chong, K. S., … & Khafaga, D. S. (2025). Transparent and reliable construction cost prediction using advanced machine learning and explainable AI. *Engineering Science and Technology, an International Journal, 70*, Article 102159.

Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science, 7*, e623.

Çaydar, T. (2025). *Intentionally biased bootstrap aggregated artificial intelligence method for construction management prediction* (Master's thesis, Middle East Technical University, Turkey).

Çelik, L. Y. (2006). *Türkiye'de inşaat sektöründe kullanılan ön maliyet tahmini yöntemleri* (Yüksek lisans tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü).

Çelik, T., Kamali, S., & Arayici, Y. (2017). Social cost in construction projects. *Environmental impact assessment review, 64*, 77-86.

Çıracı, M. (1996). *Konutlarda maliyet tahmini için bir model* (Konut Araştırmaları Dizisi No. 6). T.C. Başbakanlık Toplu Konut İdaresi Başkanlığı.

Dandan, T. H., Sweis, G., Sukkari, L. S., & Sweis, R. J. (2020). Factors affecting the accuracy of cost estimate during various design stages. *Journal of Engineering, Design and Technology, 18*(4), 787-819.

Dikmen, S. U., Ateş, O., Akbiyikli, R., & Sönmez, M. (2009). A review of utilization of soft computing methods in construction management. *Managing IT in Construction/Managing Construction for Tomorrow*, 703–710.

Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (Vol. 326). John Wiley & Sons.

Dumre, P., Bhattarai, S., & Shashikala, H. K. (2024, November). Optimizing linear regression models: A comparative study of error metrics. In *2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS)* (pp. 1856-1861). IEEE.

Elmousalami, H. H. (2020). Artificial intelligence and parametric construction cost estimate modeling: State-of-the-art review. *Journal of Construction Engineering and Management, 146*(1), 03119008.

Eltoukhy, M. G., & Nassar, A. H. (2021). Using support vector machine (SVM) for time and cost overrun analysis in construction projects in Egypt. *International Journal of Civil Engineering and Technology*, *12*(3), 5-22.

Erdem, A. E. (1996). *Konut projelerinde ön tasarım aşamasında fonksiyonel elemanlara dayalı maliyet tahmini için bir model geliştirilmesi* (Yüksek lisans tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü).

Fang, Y., Lu, X., & Li, H. (2021). A random forest-based model for the prediction of construction-stage carbon emissions at the early design stage. *Journal of Cleaner Production*, *328*, Article 129657.

Fletcher, S., & Islam, M. Z. (2019). Decision tree classification with differential privacy: A survey. *ACM Computing Surveys (CSUR)*, *52*(4), 1-33.

Fumo, N., & Biswas, M. R. (2015). Regression analysis for prediction of residential energy consumption. *Renewable and sustainable energy reviews*, *47*, 332-343.

Gavankar, S., & Sawarkar, S. (2015, December). Decision tree: Review of techniques for missing values at training, testing and compatibility. In *2015 3rd international conference on artificial intelligence, modelling and simulation (AIMS)* (pp. 122-126). IEEE.

Genuer, R., & Poggi, J. M. (2020). Random forests. In *Random forests with R* (pp. 33-55). Cham: Springer International Publishing.

Giritli, H., & Yaman, H. (1993). Teklif fiyatını etkileyen faktörler. *İnşaat mühendisliğinde gelişmeler: 1. teknik kongre bildirileri kitabı* (Cilt 1, ss. 529–537). Doğu Akdeniz Üniversitesi, Gazi Mağusa, KKTC.

Göktürk, İ. (2007). *İnşaat sektöründe fizibilite aşamasında maliyet tahmini yapmakta karşılaşılan zorluklar ve çözüm önerileri üzerine bir değerlendirme* (Yüksek lisans tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü).

Gušić, I., Hodžić, B., & Šljivić, A. (2024). Factors that influence the costs of load-bearing structures in prefabricated concrete halls: A case study from Bosnia and Herzegovina. *E3S Web of Conferences* (Vol. 508, Article 08015). EDP Sciences.

Gürel, E., & Tat, M. (2010). Multiple intelligence theory: From unitary intelligence conception to multiple intelligence approach. *The Journal of International Social Research, 3*(11), 336–356.

Hassanat, A. B., Alqaralleh, M. K., Tarawneh, A. S., Almohammadi, K., Alamri, M., Alzahrani, A., ... & Alhalaseh, R. (2024). A novel outlier-robust accuracy measure for machine learning regression using a non-convex distance metric. *Mathematics*, *12*(22), 3623.

Huang, C. H., & Hsieh, S. H. (2020). Predicting BIM labor cost with random forest and simple linear regression. *Automation in Construction*, *118*, 103280.

Huang, X. (2011). An analysis of the selection of project contractor in the construction management process. *International journal of business and management*, *6*(3), 184.

Jaber, F. K., Al-Zwainy, F. M., & Hachem, S. W. (2019). Optimizing of predictive performance for construction projects utilizing support vector machine technique. *Cogent Engineering*, *6*(1), 1685860.

Jacob, A. M., Sneed, K. B., & Pathak, Y. (2024). A possibility of application of human cognitive psychology to artificial intelligence to improve dermatological diagnostics and its accuracy. *Nur Primary Care*, *8*(1), 1–6.

Jain, P., Choudhury, A., Dutta, P., Kalita, K., & Barsocchi, P. (2021). Random forest regression-based machine learning model for accurate estimation of fluid flow in curved pipes. *Processes*, *9*(11), Article 2095.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An introduction to statistical learning: With applications in Python*. Springer.

Jassim, H. S., Hasan, M. F., Altaee, M. J., & Gamil, Y. (2025). A model for preliminary cost estimation in buildings construction projects. *Frontiers in Built Environment*, *11*.

Ji, S. H., Park, M., Lee, H. S., & Yoon, Y. S. (2010, June). Data preprocessing method for cost estimation of building projects. *Proceedings of the 27th International Symposium on Automation and Robotics in Construction (ISARC 2010).*

Jin, R., Han, S., Hyun, C., & Kim, J. (2014). Improving accuracy of early stage cost estimation by revising categorical variables in a case-based reasoning model. *Journal of Construction Engineering and Management*, *140*(7), 04014025.

Juszczyk, M. (2017). The challenges of nonparametric cost estimation of construction works with the use of artificial intelligence tools. *Procedia engineering*, *196*, 415-422.

Kamu İhale Kanunu (No. 4734). (2002). *T.C. Resmî Gazete* (Sayı: 24648). https://www.mevzuat.gov.tr/

Kerzner, H., & Saladis, F. P. (2017). *Project management workbook and PMP/CAPM exam study guide*. John Wiley & Sons.

Khoshvaght, H., Permala, R. R., Razmjou, A., & Khiadani, M. (2025). A critical review on selecting performance evaluation metrics for supervised machine learning models in wastewater quality prediction. *Journal of Environmental Chemical Engineering*, *13*(6), Article 119675.

Kowalskie, A. (2025). The impact of outliers on linear regression models: Detection and correction strategies. *OTS Canadian Journal*, *4*(6), 108–118.

Kumi, L., Jeong, J., & Jeong, J. (2024). Systematic review of quantitative risk quantification methods in construction accidents. *Buildings*, *14*(10), 3306.

Kuruoğlu, M., Sarı, A., & Özyıldız, G. (2014). Genç mühendis ve mimarlara yönelik, pratik keşif çalışmalarında kullanabilecekleri, yapıların birim imalat pozları açısından incelenmesi ve değerlendirilmesi. *3. Proje ve Yapım Yönetimi Kongresi Bildiriler Kitabı* (6–8 Kasım 2014).

Lee, C. S., Cheang, P. Y. S., & Moslehpour, M. (2022). Predictive analytics in business analytics: decision tree. *Advances in Decision Sciences*, *26*(1), 1-29.

Liu, H., Cheng, J. C., & Anumba, C. J. (2024). A graph neural network approach to conceptual cost estimation. *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction, 41*, 815–821. IAARC Publications.

Mahmoodzadeh, A., Nejati, H. R., & Mohammadi, M. (2022). Optimized machine learning modelling for predicting the construction cost and duration of tunnelling projects. *Automation in Construction, 139*, Article 104305.

Maulud, D., & Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of applied science and technology trends*, *1*(2), 140-147.

Meharie, M. G., & Shaik, N. (2020). Predicting highway construction costs: Comparison of the performance of random forest, neural network and support vector machine models. *Journal of Soft Computing in Civil Engineering*, *4*(2), 103–112.

Mohan, R. (2025). Loss functions in artificial intelligence and machine learning: A comprehensive overview. *International Journal of Computer Trends and Technology, 73*(7), 39–43. https://doi.org/10.14445/22312803/IJCTT-V73I7P105

Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, *4*(51-62), 56.

Okereke, R. A. (2019). Factors for preliminary cost estimation of building project in the Nigerian construction industry. *J. Sci. Eng. and Tech.*, *6*(1), 97–109.

Oredein, A. I., Olatayo, T. O., & Loyinmi, A. C. (2011). On validating regression models with bootstraps and data splitting techniques. *Global Journal of Science Frontier Research, 11*(6), 1–6.

Özmaden, M. Ş., & Erdal, M. (2020). Konut yapılarının maliyet tahmininde kullanılan yöntemlerin performans analizi. Konya *Journal of Engineering Sciences*, *8*(4), 970–985.

Öztemel, E. (2006). *Yapay sinir ağları*. Papatya Yayıncılık.

Pateriya, P., & Tegar, J. P. (2018). Estimation of construction cost of building projects using artificial neural network. *Journal of Emerging Technologies and Innovative Research (JETIR), 5*(8), 1106–1113.

Petruseva, S., Zileska-Pancovska, V., Žujo, V., & Brkan-Vejzović, A. (2017). Construction costs forecasting: comparison of the accuracy of linear regression and support vector machine models. *Technical gazette*, *24*(5), 1431-1438.

Phaobunjong, K. (2002). *Parametric cost estimating model for conceptual estimating of building construction projects* (Doctoral dissertation, The University of Texas at Austin, Graduate School).

Piepho, H. P. (2018). *A coefficient of determination (R^2) for linear mixed models* (arXiv Preprint No. arXiv:1805.01124). arXiv.

Project Management Institute. (2017). *A guide to the project management body of knowledge (PMBOK® guide)*. https://www.pmi.org/standards/pmbok

Ranković, N., Rankovic, D., Ivanovic, M., & Lazic, L. (2024). *Recent advances in artificial intelligence in cost estimation in project management*. Springer Cham.

Rasila, K. A. M., Mahakalanda, L., & Edirisooriya, M. W. (2025). Predicting cost elements of construction projects using supervised machine learning techniques. *Proceedings of the 13th World Construction Symposium* (p. 1112).

Redell, N. (2019). Shapley decomposition of R-squared in machine learning models. *arXiv preprint arXiv:1908.09718*.

Rodríguez-Pérez, R., & Bajorath, J. (2022). Evolution of support vector machine and regression modeling in chemoinformatics and drug discovery. *Journal of Computer-Aided Molecular Design, 36*(5), 355–362.

Sadikoglu, E., & Demirkesen, S. (2025, July). Review of Machine Learning and Artificial Intelligence Use for Cost Estimation in Construction Projects. In *EC3 Conference 2025* (Vol. 6, pp. 0-0). European Council on Computing in Construction.

Sağıroğlu, Ş., Erler, M., & Beşdok, E. (2003). *Mühendislikte yapay zekâ uygulamaları-I: Yapay sinir ağları.*

Sarstedt, M., & Mooi, E. (2014). *A concise guide to market research*. Springer.

Sayed, M., Abdel-Hamid, M., & El-Dash, K. (2023). Improving cost estimation in construction projects. *International Journal of Construction Management*, *23*(1), 135-143.

Schonlau, M., & Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, *20*(1), 3-29.

Seyyar, B., 2000. *Bina Tasarım sürecinde bilgisayar destekli maliyet tahmin sistemleri* (Yüksek Lisans Tezi, İ.T.Ü. Fen bilimleri Enstitüsü, İstanbul).

Shamim, M. M. I., Hamid, A. B. B. A., Nyamasvisva, T. E., & Rafi, N. S. B. (2025). Advancement of artificial intelligence in cost estimation for project management success: A systematic review of machine learning, deep learning, regression, and hybrid models. *Modelling*, *6*(2), Article 35.

Somvanshi, M., Chavan, P., Tambade, S., & Shinde, S. V. (2016, August). A review of machine learning techniques using decision tree and support vector machine. In *2016 international conference on computing communication control and automation (ICCUBEA)* (pp. 1-7). IEEE.

Sternberg, R. J. (2019). A theory of adaptive intelligence and its relation to general intelligence. *Journal of Intelligence, 7*(4), Article 23.

Sudhaman, K., Akuthota, M., & Chaurasiya, S. K. (2022). A review on the different regression analysis in supervised learning. *Bayesian Reasoning and Gaussian Processes for Machine Learning Applications*, 15-32.

Taraf, F. (2024). İnşaat projelerinde kaliteyi en çok etkileyen aşamanın analitik hiyerarşi prosesi (AHP) ile belirlenmesi. *Journal of Turkish Operations Management*, *8*(2), 374-396.

Tayefeh Hashemi, S., Ebadati, O. M., & Kaur, H. (2020). Cost estimation and prediction in construction projects: A systematic review on machine learning techniques. *SN Applied Sciences*, *2*(10), 1703.

T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2024). *Gayri safi yurtiçi hasılanın sektörel dağılımı.* https://cevreselgostergeler.csb.gov.tr/gayri-safi-yurtici-hasilanin-sektorel-dagilimi-85707.

T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2025, 31 Ocak). *Mimarlık ve mühendislik hizmet bedellerinin hesabında kullanılacak 2025 yılı yapı yaklaşık birim maliyetleri hakkında tebliğ*. Resmî Gazete (Sayı: 32799)

Türkiye Cumhuriyeti Bakanlar Kurulu. (1972, 15 Mart). *Emlak vergisine matrah olacak vergi değerlerinin takdirine ilişkin tüzük. T.C. Resmî Gazete* (Sayı: 14129). https://www.mevzuat.gov.tr/MevzuatMetin/2.5.73995.pdf

Türk Borçlar Kanunu. (2011, 11 Ocak). Genel hükümler. *T.C. Resmî Gazete* (Sayı: *27836*).

T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2011–2025). *Mimarlık ve mühendislik hizmet bedellerinin hesabında kullanılacak yapı yaklaşık birim maliyetleri hakkında tebliğler*. T.C. Resmî Gazete.

Topkaya, E., Yönez, E., Kuruoğlu, M., & Çelik, L. Y. (2012). İnşaat sektöründe kullanılan ön maliyet tahmin yöntemlerinin karşılaştırılması. *Engineering Sciences, 7*(1), 263–272.

Türkyılmaz, A. H. (2025). *Risk-based cost estimation in construction by employing machine learning techniques* (Doctoral dissertation, Istanbul Technical University, Graduate School, Department of Civil Engineering, Structure Engineering Programme).

Tyagi, K., Rane, C., Sriram, R., & Manry, M. (2022). Unsupervised learning. In *Artificial intelligence and machine learning for edge computing* (pp. 33–52). Academic Press.

Yang, S.-W., Moon, S.-W., Jang, H., Choo, S., & Kim, S.-A. (2022). Parametric Method and Building Information Modeling-Based Cost Estimation Model for Construction Cost Prediction in Architectural Planning. *Applied Sciences*, *12*(19), 9553. https://doi.org/10.3390/app12199553

Yıldırım, H., & Kaya, L. G. (2025). New approaches and theories in understanding intelligence and cognitive ability processes. *Duzce University Journal of Science and Technology, 13*(2), 913-931.

Yılmaz, I., & Dikmen, S. Ü. (2012). Osmanlı döneminde kullanılan yaklaşık maliyet tahmin yöntemleri. *Engineering Sciences*, *7*(1), 73-83.

Zahran, M., Hosny, H., & Sand, A. (2014). Parametric cost estimating of sterile building using artificial neural network & genetic algorithm model. *International Journal of Engineering and Technology Research, 2*, 129–136.

Zhang, J., Yuan, J., Mahmoudi, A., Ji, W., & Fang, Q. (2025). A data-driven framework for conceptual cost estimation of infrastructure projects using XGBoost and Bayesian optimization. *Journal of Asian Architecture and Building Engineering, 24*(2), 751–774.

Zheng, Z., Zhou, L., Wu, H., & Zhou, L. (2023). Construction cost prediction system based on Random Forest optimized by the Bird Swarm Algorithm. *Mathematical Biosciences and Engineering*, *20*(8), 15044-15074.

Zhou, Y., Li, S., Zhou, C., & Luo, H. (2019). Intelligent approach based on random forest for safety risk prediction of deep foundation pit in subway stations. *Journal of Computing in Civil Engineering*, *33*(1), Article 05018004.

Zhou, Z. H. (2021). Machine learning. Springer Nature.

Xie, Y., Ebad Sichani, M., Padgett, J. E., & DesRoches, R. (2020). The promise of implementing machine learning in earthquake engineering: A state-of-the-art review. *Earthquake spectra*, *36*(4), 1769-1801.

ÖZGEÇMİŞ

Ad-Soyad **:** Serdar Tanrıkulu

ÖĞRENİM DURUMU:

- **Lisans** **:** 2022, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, İnşaat Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2022 – 2025 yılları arasında inşaat sektöründe ulusal ve uluslararası projelerde kalite kontrol mühendisi, saha şefi ve şantiye şefi pozisyonlarında görev almıştır.
- 2025 yılı itibariye teknoloji sektörüne yönelmiş olup, halihazırda dijital danışmanlık hizmeti sunan bir firmada veri ve içgörü danışmanı ile web ve mobil uygulama analisti olarak çalışmaktadır.