T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

İNŞAAT PROJELERİ İÇİN DİJİTAL İKİZ UYGULAMA MODELİ OLUŞTURULMASI

Muhammet YILDIRIM

DANIŞMAN
Dr. Öğr. Üyesi Ömer GİRAN

İnşaat Mühendisliği Anabilim Dalı

İnşaat Mühendisliği Programı

Aralık, 2024

TEZ KABUL VE ONAYI

Muhammet YILDIRIM tarafından, **Dr. Öğr. Üyesi Ömer GİRAN** danışmanlığında hazırlanan **İNŞAAT PROJELERİ İÇİN DİJİTAL İKİZ UYGULAMA MODELİ OLUŞTURULMASI** başlıklı bu çalışma, jürimiz tarafından **18/12/2024** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	Sonuç
DANIŞMAN	Dr. Öğr. Üyesi Ömer GİRAN İstanbul Üniversitesi-Cerrahpaşa İnşaat Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Prof. Dr. Ümit IŞIKDAĞ Mimar Sinan Güzel Sanatlar Üniversitesi Mimarlık Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Erdem DAMCI İstanbul Üniversitesi-Cerrahpaşa İnşaat Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Doç. Dr. Cemil AKÇAY İstanbul Üniversitesi Mimarlık Anabilim Dalı		☒ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Osman Hürol TÜRKAKIN İstanbul Üniversitesi-Cerrahpaşa İnşaat Mühendisliği Anabilim Dalı		☒ Kabul ☐ Ret

BEYAN

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

Muhammet YILDIRIM

(İmza)

Aileme ithaf ediyorum…

BÜTÇE DESTEKLERİ

İNŞAAT PROJELERİ İÇİN DİJİTAL İKİZ UYGULAMA MODELİ OLUŞTURULMASI

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Doktora süresi boyunca her alanda değerli tecrübeleri ve desteği için danışman hocam Sayın Dr. Ömer GİRAN'a sonsuz teşekkürlerimi sunarım.

Tez izleme komitesindeki bulunan kıymetli hocalarım Sayın Prof. Dr. Ümit IŞIKDAĞ'a ve Sayın Dr. Erdem DAMCI'ya doktora sürecinde öneri ve tavsiyeleriyle değerli katkılarından dolayı teşekkür ediyorum.

Son olarak, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan anne ve babama karşılıksız emekleri için, kardeşlerime ise tezimde ve hayatımın her alanında, özellikle zor zamanlarımda beni yüreklendirdikleri ve destekledikleri için şükranlarımı sunarım.

Aralık 2024 **Muhammet YILDIRIM**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xi**
SİMGE VE KISALTMA LİSTESİ ..... **xiv**
ÖZET ..... **xvi**
ABSTRACT ..... **xviii**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **3**
2.1. DİJİTAL İKİZ KAVRAMI VE KÖKENİ 4
2.2. ENTEGRASYON DÜZEYİ VE DİJİTAL İKİZ PARADİGMA 5
2.3. DİJİTAL İKİZ UYGULAMA TEKNOLOJİLERİ 8
2.4. DİĞER SEKTÖRLERDE DİJİTAL İKİZ 11
2.4.1. Havacılık ve Uzay 11
2.4.2. Üretim 13
2.4.3. Sağlık 14
2.5. İNŞAAT PROJELERİNİN YAŞAM DÖNGÜSÜ AŞAMASINDA DİJİTAL İKİZ UYGULAMASI 15
2.5.1. Planlama ve Tasarlama Aşaması 16
2.5.2. Yapım Aşaması 18
2.5.3. İşletme ve Bakım Aşaması 20
2.5.4. Yıkım ve İyileştirme Aşaması 22
3. YÖNTEM **23**
3.1. MALZEME 23
3.2. VERİ İŞLEMDE KULLANILAN ARAÇ VE YAZILIMLAR 24

3.2.1. Sinir Ağı 25
3.2.2. NARX 26
3.2.3. NARNN 28
3.2.4. İstatistiksel Modeller 30
4. BULGULAR 35
4.1. İNŞAATTA DİJİTAL İKİZ MODELİNİN OLUŞTURMASI 35
4.1.1. Model Oluşturması 35
4.1.2. Model Doğrulaması 54
4.2. KİRİŞ ÜZERİNDEN UYGULAMA 56
4.2.1. Basamaklı Aşama 58
4.2.1.1. İstatistiksel Modeller 58
4.2.1.2. Sinir Ağı 75
4.2.1.3. NARX 80
4.2.1.4. NARNN 84
4.2.2. Basamaksız Aşama 89
4.2.2.1. İstatistiksel Modeller 89
4.2.2.2. Sinir Ağı 104
4.2.2.3. NARX 108
4.2.2.4. NARNN 112
4.3. İLERİYE TAHMİN 117
4.3.1. İstatistiksel Modeller 117
4.3.2. Sinir Ağı 123
4.3.3. NARX 125
4.3.4. NARNN 127
5. TARTIŞMA 130
6. SONUÇ VE ÖNERİLER 133
KAYNAKLAR 136
EKLER 151
İNTİHAL RAPORU İLK SAYFASI 153
ETİK KURUL İZİN YAZISI 154
KURUM İZNİ YAZILARI 155
ÖZGEÇMİŞ 156

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: DM, DS ve DT'de Veri Akışı. **6**

Şekil 2.2: DT paradigması. **8**

Şekil 3.1: Çalışmada kullanılan betonarme kirişi. **23**

Şekil 3.2: Gerinim ölçüm cihazı. **24**

Şekil 3.3: Sinir ağı uyumunun mimari çerçevesi. **26**

Şekil 3.4: NARX'ın mimari çerçevesini. **28**

Şekil 3.5: NARNN'ın mimari çerçevesi. **30**

Şekil 3.6: DT oluşturma süreci. **34**

Şekil 4.1: İnşaat sektöründe DT çerçevesi. **37**

Şekil 4.2: İnşaat projenin aşamaları. **38**

Şekil 4.3: Planlama ve tasarım aşamasında DT çerçevesi. **40**

Şekil 4.4: Yapım aşamasında DT çerçevesi. **42**

Şekil 4.5: İşletme ve bakım aşamasında DT çerçevesi. **44**

Şekil 4.6: Yıkım aşamasında DT çerçevesi. **46**

Şekil 4.7: Proje yaşam döngüsünde paydaşların DT platformu. **49**

Şekil 4.8: Planlama ve tasarım aşamasında DT modeli aracılığıyla paydaşların ilişikleri. **50**

Şekil 4.9: Yapım aşamasında DT Modeli dahilinde paydaşlar etkileşimleri. **52**

Şekil 4.10: İşletme ve bakım aşamasında DT Modeli dahilinde paydaşlar etkileşimleri. **53**

Şekil 4.11: Yıkım aşamasında DT Modeli dahilinde paydaş etkileşimleri. **54**

Şekil 4.12: Kiriş üzerinden işletme aşamasında DT modeli. **57**

Şekil 4.13: Basamaklı aşamasında ilk haftanın gerilme dağıtımı. **58**

Şekil 4.14: Basamaklı aşamasında ikinci haftanın gerilme dağıtımı. **61**

Şekil 4.15: Basamaklı aşamasında üçüncü haftanın gerilme dağıtımı. **63**

Şekil 4.16: Basamaklı aşamasında dördüncü haftanın gerilme dağıtımı. **66**

Şekil 4.17: Basamaklı aşamasında beşinci haftanın gerilme dağıtımı. **68**

Şekil 4.18: Basamaklı aşamasında altıncı haftanın gerilme dağıtımı. **71**

Şekil 4.19: Basamaklı aşamasında altı haftanın gerilme dağıtımı. **73**

Şekil 4.20: Basamaksız aşamasında ilk haftanın gerilme dağıtımı. **90**

Şekil 4.21: Basamaksız aşamasında ilk 15 günün gerilme dağıtımı. **92**

Şekil 4.22: Basamaksız aşamasında bir ayın gerilme dağıtımı. **95**

Şekil 4.23: Basamaksız aşamasında iki ayın gerilme dağıtımı. **97**

Şekil 4.24: Basamaksız aşamasında üç ayın gerilme dağıtımı. **100**

Şekil 4.25: Basamaksız aşamasında altı ayın gerilme dağıtımı. **102**

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Tez çalışmasında kullanılan regresyon algoritmaları. **33**

Tablo 4.1: Basamaklı aşamasında ilk haftanın regresyon sonuçları. **59**

Tablo 4.2: Basamaklı aşamasında ikinci haftanın regresyon sonuçları. **61**

Tablo 4.3: Basamaklı aşamasında üçüncü haftanın regresyon sonuçları. **64**

Tablo 4.4: Basamaklı aşamasında dördüncü haftanın regresyon sonuçları. **66**

Tablo 4.5: Basamaklı aşamasında beşinci haftanın regresyon sonuçları. **69**

Tablo 4.6: Basamaklı aşamasında altıncı haftanın regresyon sonuçları. **71**

Tablo 4.7: Basamaklı aşamasında altı haftanın regresyon sonuçları. **74**

Tablo 4.8: Basamaklı aşamasında ilk haftanın sinir ağının sonuçları. **76**

Tablo 4.9: Basamaklı aşamasında ikinci haftanın sinir ağının sonuçları. **76**

Tablo 4.10: Basamaklı aşamasında üçüncü haftanın sinir ağının sonuçları. **77**

Tablo 4.11: Basamaklı aşamasında dördüncü haftanın sinir ağının sonuçları. **77**

Tablo 4.12: Basamaklı aşamasında beşinci haftanın sinir ağının sonuçları. **78**

Tablo 4.13: Basamaklı aşamasında altıncı haftanın sinir ağının sonuçları. **79**

Tablo 4.14: Basamaklı aşamasında altı haftanın sinir ağının sonuçları. **79**

Tablo 4.15: Basamaklı aşamasında ilk haftanın NARX'ın sonuçları. **80**

Tablo 4.16: Basamaklı aşamasında ikinci haftanın NARX'ın sonuçları. **81**

Tablo 4.17: Basamaklı aşamasında üçüncü haftanın NARX'ın sonuçları. **81**

Tablo 4.18: Basamaklı aşamasında dördüncü haftanın NARX'ın sonuçları. **82**

Tablo 4.19: Basamaklı aşamasında beşinci haftanın NARX'ın sonuçları. **82**

Tablo 4.20: Basamaklı aşamasında altıncı haftanın NARX'ın sonuçları. **83**

Tablo 4.21: Basamaklı aşamasında altı haftanın NARX'ın sonuçları. **84**

Tablo 4.22: Basamaklı aşamasında ilk haftanın NARNN'ın sonuçları. **85**

Tablo 4.23: Basamaklı aşamanın ikinci haftanın NARNN'ın sonuçları. **85**

Tablo 4.24: Basamaklı aşamanın üçüncü haftanın NARNN'ın sonuçları. **86**

Tablo 4.25: Basamaklı aşamanın dördüncü haftanın NARNN'ın sonuçları. **86**

Tablo 4.26: Basamaklı aşamanın beşinci haftanın NARNN'ın sonuçları. **87**

Tablo 4.27: Basamaklı aşamanın altıncı haftanın NARNN'ın sonuçları. **88**

Tablo 4.28: Basamaklı aşamanın altı haftanın NARNN'ın sonuçları. **88**

Tablo 4.29: Basamaksız aşamasında ilk haftanın regresyon sonuçları. **90**

Tablo 4.30: Basamaksız aşamasında ilk 15 günün regresyon sonuçları. **93**

Tablo 4.31: Basamaksız aşamasında bir ayın regresyon sonuçları. **95**

Tablo 4.32: Basamaksız aşamasında iki ayın regresyon sonuçları. **98**

Tablo 4.33: Basamaksız aşamasında üç ayın regresyon sonuçları. **100**

Tablo 4.34: Basamaksız aşamasında altı ayın regresyon sonuçları. **103**

Tablo 4.35: Basamaksız aşamasında ilk haftanın sinir ağının sonuçları. **105**

Tablo 4.36: Basamaksız aşamasında ilk 15 günün sinir ağının sonuçları. **106**

Tablo 4.37: Basamaksız aşamasında bir ayın sinir ağının sonuçları. **106**

Tablo 4.38: Basamaksız aşamasında iki ayın sinir ağının sonuçları. **107**

Tablo 4.39: Basamaksız aşamasında üç ayın sinir ağının sonuçları. **107**

Tablo 4.40: Basamaksız aşamasında altı ayın sinir ağının sonuçları. **108**

Tablo 4.41: Basamaksız aşamasında ilk haftanın NARX'ın sonuçları. **109**

Tablo 4.42: Basamaksız aşamasında ilk 15 günün NARX'ın sonuçları. **110**

Tablo 4.43: Basamaksız aşamasında bir ayın NARX'ın sonuçları. **110**

Tablo 4.44: Basamaksız aşamasında iki ayın NARX'ın sonuçları. **111**

Tablo 4.45: Basamaksız aşamasında üç ayın NARX'ın sonuçları. **111**

Tablo 4.46: Basamaksız aşamasında altı ayın NARX'ın sonuçları. **112**

Tablo 4.47: Basamaksız aşamanın ilk haftanın NARNN'ın sonuçları. **113**

Tablo 4.48: Basamaksız aşamanın ilk 15 günün NARNN'ın sonuçları. **114**

Tablo 4.49: Basamaksız aşamanın bir ayın NARNN'ın sonuçları. **114**

Tablo 4.50: Basamaksız aşamanın iki ayın NARNN'ın sonuçları. **115**

Tablo 4.51: Basamaksız aşamanın üç ayın NARNN'ın sonuçları. **115**

Tablo 4.52: Basamaksız aşamanın altı ayın NARNN'ın sonuçları. **116**

Tablo 4.53: Bir haftalık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini. . **117**

Tablo 4.54: Altı haftalık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **119**

Tablo 4.55: Üç aylık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **121**

Tablo 4.56: Bir haftalık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **123**

Tablo 4.57: Altı haftalık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **124**

Tablo 4.58: Üç aylık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini. ... **125**

Tablo 4.59: Bir haftalık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini... **125**

Tablo 4.60: Altı haftalık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **126**

Tablo 4.61: Üç aylık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **127**

Tablo 4.62: Bir haftalık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **128**

Tablo 4.63: Altı haftalık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini. **128**

Tablo 4.64: Üç aylık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.... **129**

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
ABM	: Faaliyet Tabanlı Yönetim
AI	: Yapay Zekâ
AFRL	: Hava Kuvvetleri Araştırma Laboratuvarı
AR	: Artırılmış Gerçeklik
BIM	: Bina Bilgi Modelleme
BMS	: Bina Yönetim Sistemi
BP	: Geri Yayılım
DM	: Dijital Model
DS	: Dijital Gölge
DT	: Dijital İkiz
FM	: Tesisler İşletmesi
GIS	: Coğrafi Bilgi Sistemi
GPR	: Gauss Süreci Regresyonu
GPS	: Küresel Konumlandırma Sistemi
HPP	: Yüksek Basınçlı İşleme
HVAC	: Isıtma, Havalandırma ve İklimlendirme
IOT	: Nesnelerin İnterneti
LSTM	: Uzun-Kısa Süreli Bellek
MR	: Karma Gerçeklik
MSE	: Ortalama Kare Hatası
NARNN	: Doğrusal Olmayan Otoregresif Sinir Ağı
NARX	: Dışsal Girdili Doğrusal Olmayan Otoregresif Ağ
PLM	: Ürün Yaşam Döngüsü Yönetimi
RFID	: Radyo Frekanslı Tanımlama
RMSE	: Kök Ortalama Kare Hatası
RPA	: Robotik Süreç Otomasyonu
SCs	: Akıllı Kentler
SDT	: Senkronize Dijital İkiz

SVM : Destek Vektör Makineleri

TLS : Yersel Lazer Tarama

VR : Sanal Gerçeklik

WSN : Kablosuz Sensör Ağı

XR : Genişletilmiş Gerçeklik

ÖZET

DOKTORA TEZİ

İNŞAAT PROJELERİ İÇİN DİJİTAL İKİZ UYGULAMA MODELİ OLUŞTURULMASI

Muhammet YILDIRIM

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

İnşaat Mühendisliği Programı

Danışman : Dr. Öğr. Üyesi Ömer GİRAN

Tez çalışması, inşaat projeleri için bir dijital ikiz modeli oluşturmayı amaçlamaktadır. Bu çalışmanın ilk aşamasında, dijital ikiz modelleri projenin yaşam döngüsü sırasında oluşturulmuş ve daha sonra bir anket kullanılarak validasyonu yapılmıştır. Ardından, çalışma laboratuvar deneyi için tasarlanmış betonarme bir kirişe uygulanmıştır. Ayrıca, uygulanan yük, sıcaklık ve bağıl nem nedeniyle betonarme kirişte meydana gelen gerilme gerçek zamanlı olarak sensörler kullanılarak toplanmıştır. Model, matematiksel kavramlar ve makine öğrenimi algoritmaları kullanılarak oluşturulmuştur. Sinir ağı, NARX, NARNN ve regresyon modelleri bu çalışmada dijital ikiz modelini kurmak için kullanılan modellerdir. Ayrıca, çalışmada iki aşamalı bir analiz yöntemi kullanılmıştır. İlk aşamanın amacı modellerin etkinliğini değerlendirmektir. Bu aşamada veri kümesinin yüzde altmışı eğitim kümesi ve yüzde otuzu test kümesi olarak ayrılmıştır. Analiz, altı haftalık basamaklı aşamada her hafta ayrı ayrı ve ardından altı hafta boyunca yapılmıştır. Ayrıca, analiz basamaksız aşamanın bir hafta, 15 gün, bir ay, iki ay, üç ay ve altı ayı üzerinden yapılmıştır. İkinci aşama analizinde, modeller bir haftalık, altı haftalık ve üç aylık bir kümeyi eğiterek bir sonraki hafta boyunca gerilme

değerlerini tahmin etmek için uygulanmıştır. Bir haftalık veri setinin eğitim sonuçları, GPR'nin 0,67508 R^2 ile en iyi model olduğunu göstermektedir. NARX, 0,816135 R^2 ile altı haftalık bir veri setinin eğitimi sırasında en iyi sonuçları temsil etmektedir. Üç aylık bir veri kümesi eğitilirken, sinir ağı ve NARNN sırasıyla 0,879067 ve 0,880006 R^2 ile en iyi sonuçları göstermektedir. Sonuçlar, eğitim veri kümesi boyutunun artırılmasının test sonuçlarının doğruluğunda bir artışa yol açtığını göstermektedir. Son olarak, gerilmenin gelecekteki değerini tahmin ederken uygulanan yük, sıcaklık ve bağıl nem yerine diğer faktörleri dikkate almak daha doğru sonuçlar elde edilmesini sağlayabilir.

Aralık 2024 , 175 sayfa.

Anahtar kelimeler: Dijital İkiz, İnşaat, Makine Öğrenimi, Sinir Ağları, Regresyon

ABSTRACT

Ph.D. THESIS

GENERATION OF A DIGITAL TWIN APPLICATION MODEL FOR CONSTRUCTION PROJECTS

Muhammet YILDIRIM

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Civil Engineering

Program of Civil Engineering

Supervisor: Assist. Prof. Dr. Ömer GİRAN

Thesis study aims to generate a digital twin model for construction projects. In the first phase of this study, the digital twin models were generated during the project's lifecycle and then validated using a questionnaire survey. Then, the study was implemented in a reinforced concrete beam designed for the laboratory experiment. Moreover, the strain happened in the reinforced concrete beam due to the applied load, temperature, and relative humidity data collected using sensors in real-time. The model was established using mathematical concepts and machine learning algorithms. Neural network, NARX, NARNN, and regression models were used in this study to establish the digital twin model. Furthermore, the study uses a two-phase analysis method. The purpose of the first phase is to evaluate the models' efficiency. At this phase, the dataset has been divided into seventy percent as a training set and thirty percent as a testing set. The analysis

was done in the six-week cascade phase over each week separately and then over the six weeks. Moreover, the analysis was done over one week, 15 days, one month, two months, three months, and six months of the stepless phase. In the second phase analysis, the models were implemented to forecast the values of the strain during the next week by training a set of one week, a set of six weeks, and a set of three months. The results of training a one-week dataset show that GPR was the best model with R^2 of 0.67508. NARX represents the best results during training a six-week dataset with R^2 of 0.816135. While training a three-month dataset, neural network and NARNN indicate the best results with R^2 of 0.879067 and 0.880006 respectively. The results indicate that increasing the training dataset size leads to an increase in the accuracy of the testing results. Finally, considering factors other than applied load, temperature, and relative humidity while forecasting the strain's future value may lead to more accurate results.

December 2024, 175 pages.

Keywords: Digital Twin, Construction, Machine Learning, Neural Networks, Regression

1. GİRİŞ

Son yıllarda, çevrimlerin ve ekipmanların mevcut ve gelecekteki durumunun fiziksel ve dijital özelliklerini ele almak için bilgisayarlı harmanlama fikirleri endüstri tarafından benimsenmiştir (Modoni ve diğ., 2016). Dijital ikiz (DT), Endüstri 4.0 kılavuzunun kritik bir bileşeni, bir fiziksel kaynağı izlemeyi ve gerçek zamanlı veri çeşitliliği yoluyla operasyonel etkinliğini artırmayı amaçlayan, tahmini bakımı güçlendiren ve çok eğitimli bir dinamikle sonuçlanan bir dijitalleştirme teknolojisidir. Bina bilgi modelleme (BIM) ve DT benzerliklere sahip olsalar da çeşitli şekillerde farklılık göstermektedir. Söz konusu farklılıklara geliştirme sebepleri, uygulanan yenilikler, son kullanıcılar hedefi örnek olarak verilebilmektedir (Khajavi ve diğ., 2019).

DT'in inşaatta en çok kullanımı, proje ister konut ister endüstriyel olsun, tesisin işletme ve bakım dönemindedir (El Jazzar ve diğ., 2020). Dahası, inşaat bakış açısından, DT paradigması, Dijital Modellerin (DM'lerin) olduğu bir siber-fiziksel eşzamanlılık ortamında destekleyici anlambilimleriyle (örneğin, IFC, COBie) mevcut inşaat döngülerini ve modellerini (nD BIM'ler) iyileştirmek anlamına gelmektedir. DT fiziksel kaynakların hiçbir yerde bulunmayan bir izlenimidir. Buna göre, mevcut BIM'in denetimi (nD aralığında) ve bunların temel anlambilim, DT konseptinin talep ettiği daha güncel ilerlemelerde önceden koordine edilmesi gereken inşaat veri modellerinin unsurlarını kavramak için hayati öneme sahiptir (Boje ve diğ., 2020). Bununla birlikte, yapım aşamasında DT ile ilgili mevcut literatürde kolaylıkla bulunamamaktadır çünkü DT ifadesi birçok makalede kesin bir şekilde belirtilmemektedir ve sıklıkla BIM veya BIM-FM (tesis işletmesi) olarak anılmaktadır. Yayınların çoğu, inşaat sektörü ile ilgili olarak, veriler toplanırken ve BIM modeline bağlanırken, bilgisayarlı modellerde yapılan değişikliklerin gerçek alanda değişikliklere yol açmadığını gösteren Dijital Gölge (DS) alt kategorisine girmektedir (El Jazzar ve diğ., 2020).

DT, müşterilerin girişimi monte edilmeden önce üretmelerine izin verir ve hatta tek model metodolojisi, inşaat ve yönetim ekiplerinden tüm bireylerin BIM'i benzer şekilde kullanmasını sağlamaktadır. Gruba, sorunların ele alınabileceği işbirlikçi ve gözetimli bir sanal iklim sunmaktadır. Tek Model metodolojisi, seçimlere karar vermek için gereken süreyi azaltarak ve yapının yaşam döngüsü boyunca oluşturulabilmektedir. İnşaat projelerinde dijital

ikiz uygulamasının belirli bir çerçevesi bulunmamakla birlikte, bu çalışmanın önemi, projelerin süresini kısaltmaya, maliyet aşımını önlemeye ve inşaat aşamasında meydana gelebilecek arızaları tahmin etmeye ve bunlar için gerçekleşmeden önce öngörücü çözümler sağlamaya yardımcı olabilecek dijital ikiz modelinin inşaat projelerinde uygulanmasında gelecekte kullanılacak açık ve kullanışlı bir çerçeve veya model oluşturmaktan kaynaklanmaktadır. Ayrıca DT modeli, projenin ilk aşamasından sonuna kadar inşaat, işletme ve bakım yoluyla iyi ve faydalı bir iletişim kanalı kurarak proje üyeleri, tasarımcılar, paydaşlar ve son kullanıcılar arasındaki iş birliği seviyesini artırmaktadır. Bununla birlikte, birlikte çalışabilirlik, verimsiz entegrasyon, yetersiz bilgi yönetimi, operasyonel sorunlar, tesis yönetiminde veri eksikliği ve bilgi kullanımı ve yönetimindeki engeller, bir bina projesinin yaşam döngüsü boyunca DT'lerin dağıtımını etkilemektedir (Yıldırım ve Giran, 2023). İnşaat sektörü DM'in ötesine geçerek muazzam bir ilerleme kaydetmiş olsa da DT'in uygulanması sektörde hâlâ tam olarak gerçekleştirilememiştir.

DT'den maksimum kapasitede faydalanabilmek için, bir tesisin başlangıç aşamasında ve tüm yaşam döngüsü boyunca kullanması gerekmektedir. Veri çeşitliliği, bir BIM modeli kullanılarak tasarım aşamasında başlamalıdır. Veriler daha sonra inşaat projesinin tüm yaşam döngüsü boyunca sürekli olarak yenilenmeli ve biriktirilmeli, böylece karar aşaması için tamamen faydacı bir birleştirilmiş model hazırlanmalıdır.

Literatürdeki boşluğu doldurmak için tez çalışmasında, inşaat projelerinde DT'lerin kullanımına yönelik net bir çerçeve oluşturulması amaçlanmıştır. Ayrıca, bu amaca ulaşmak için aşağıdaki hedefler belirlenmiştir.

DT'in inşaat projelerindeki potansiyelini anlamak.

İnşaat projelerinde bir DT yaklaşımı oluşturmak için gereken gereksinimleri ve parametreleri belirlemek.

DT modelinin inşaat projelerinde uygulanmasından faydalı bir sonuç almak için yapılması gereken süreçleri belirlemek.

DT modelinin inşaat projelerinde doğru bir şekilde uygulanmasının önündeki zorlukları ve sınırları belirleyebilmek.

2. KAVRAMSAL ÇERÇEVE

Bilgi ve iletişim teknolojilerindeki ilerlemeler sayesinde, endüstrideki yeni bilgi çağı analog, mekanik ve elektrik teknolojisinin yerini dijital teknolojiye bırakmıştır (Ozturk ve Yitmen, 2019). Dijital teknolojiler, Endüstri 4.0 ve üçüncü nesil bilgi ve iletişim sistemlerinin kullanılmaya başlanmasıyla birlikte verimliliğin artırılması için etkin bir değer önerisine dönüşmüştür (Herterich ve diğ., 2016). Fiziksel varlıkların yönetimi, faaliyetlerin ve süreçlerin bilgisayarlaştırılması ve dijitalleştirilmesinden büyük ölçüde etkilenmektedir (Ozturk ve Yitmen, 2019). Yapay zekâ (AI), nesnelerin interneti (IoT), BIM, DT'ler, blok zinciri, makine öğrenimi, veri analitiği, derin öğrenme ve benzerleri gibi birçok farklı teknoloji, birçok sektörde verimliliği artırmak için kullanılmaktadır. Sonuç olarak, birçok ekonomi büyüme ve kalkınmalarını hızlandırmak için bu teknolojileri kullanma becerilerine güvenmektedir.

DT'ler, gerçek nesnelerin ve süreçlerin sanal reprodüksiyonlarını üretmek için en son dijital teknolojileri kullanarak endüstrileri dönüştüren Endüstri 4.0 çağında devrim niteliğinde bir teknoloji haline gelmiştir (Arrichiello ve Gualeni, 2020). İmalat, sağlık, ulaşım ve inşaat sektörlerinde çeşitli kullanım alanları vardır. DT'ler inşaat sektöründe planlama, tasarım, simülasyon, gerçek zamanlı izleme, kestirimci bakım ve paydaş katılımını önemli ölçüde geliştirme potansiyeline sahiptir (Ammar ve diğ., 2022).

Bir fiziksel nesne (şey, sistem veya süreç), onun dijital temsili ve sanal ve fiziksel muadilleri birbirine bağlayan kusursuz veri bağlantıları, DT'ler üç ana bileşenidir (VanDerHorn ve Mahadevan, 2021). DT'lerin amacı, fiziksel varlığın performansını simüle etmeyi, analiz etmeyi ve optimize etmeyi kolaylaştırmaktır. Bu, karar verme sürecini, önleyici bakımı ve genel proje verimliliğini iyileştirecektir. DT'ler, fiziksel nesneleri veya sistemleri doğru bir şekilde tasvir etmek için DM'leri kullanan Endüstri 4.0 sistemlerinin önemli bir bileşenidir (Broo ve Schooling, 2023).

DT, bir malın, prosedürün veya hizmetin her yönünü sanal olarak eşleştirerek piyasayı dönüştüren en son teknolojidir. Gerçek dünyadaki her şey dijital alanda kopyalanabilir ve mühendisler sanal dünyadan girdi alabilmektedir (Fu ve diğ., 2022). Sonuç olarak teknoloji, işletmelerin fiziksel sorunları daha hızlı tespit edip çözmelerine, daha iyi ürünler yaratıp

üretmelerine ve daha önce mümkün olandan daha hızlı bir şekilde değer ve avantaj elde etmelerine yardımcı olmaktadır. İşletmeler ayrıca DT teknolojisi sayesinde performanslarını ve iş operasyonlarını geliştirebilmektedir (Qi ve diğ., 2021).

Kentler için DT'ler, akıllı kentlerin (SCs) dijital teknolojileri uygulamaya, çeşitli paydaşları (hükümetler, işletmeler ve insanlar) dâhil etmeye ve çeşitli simülasyonlar ve kentsel analizler yoluyla gelişmiş karar verme için kavramlar üretmeye hazır olma çabalarının bir sonucudur. Ayrıca, teknolojik gelişmeler, mekânsal ve mekânsal olmayan verilerin mevcudiyeti ve sanal simülasyon teknolojilerinin küresel evrimi sonucunda, şehirler de dâhil olmak üzere giderek daha karmaşık fiziksel ve dinamik sistemler DT teknolojileri kullanılarak ele alınabilmektedir (Ketzler ve diğ., 2020; Grieves, 2022). Ancak, kentsel çevrenin karmaşıklığı, coğrafi ve zamansal ölçeği nedeniyle, diğer işletmelerin bu nosyonu yeniden üretme süreci basit değildir.

2.1. DİJİTAL İKİZ KAVRAMI VE KÖKENİ

Diğer ekonomik sektörlerdeki operasyonlar, dijital imalat endüstrisinin son on yıldaki değişimlerinin bir sonucu olarak değişmektedir (Opoku ve diğ., 2021). Dijital imalat sektörü, fabrikaların sanal bir tasviri aracılığıyla modeller oluşturmakta ve ürün geliştirme prosedürlerini taklit etmektedir (Chryssolouris ve diğ., 2009). Ulusal havacılık ve uzay dairesi'nin (NASA) entegre teknoloji yol haritası, DT terimini ilk olarak Teknoloji Alanı Modelleme, Simülasyon, Bilgi Teknolojisi ve İşleme altında kamu alanında kullanmıştır (Shafto ve diğ., 2012). "İkiz" fikri ilk olarak NASA'nın Apollo programı tarafından ortaya atılmış ve yolculuk sırasında uzay aracının koşullarının yansıtılmasını sağlamak için iki özdeş uzay aracı inşa edilmiştir (Boschert ve Rosen, 2016). Dünya'da kalan araç, görev sırasında yörüngede olan araçla aynıydı (Boschert ve Rosen, 2016).

Michigan Üniversitesi'nden Dr. Michael Grieves 2002 yılında ürün yaşam döngüsü yönetimi (PLM) için Kavramsal İdeali ortaya atarak DT kavramını doğurmuştur (Grieves ve Vickers, 2016). DT'in tüm yönlerini kapsayan PLM konsepti, her sistemin iki sistemden oluştuğunu varsayar. Her zaman var olan fiziksel bir sistem ve fiziksel sistemle ilgili tüm bilgileri içeren sanal bir sistemdir. Bu iki sistem birbirine bağlı olduğundan, veriler hem gerçek hem de sanal alemler arasında akabilmektedir (Grieves ve Vickers, 2016). İlk kez DT terimini kullanmışlardır (Bradley ve Hehenberger, 2016).

DT'nin tanımı, sektöre özgü olmayan ve sektörlerde uygulanabilirliğine dayanmaktadır. Ancak DT, fiziksel varlığın davranış kuralını yansıtır ve varlığı süresince sürekli güncellenmektedir. DT'yi, sistemlerin ve ekipmanların çevrelerinde nasıl çalıştıklarının ve yaşamları boyunca nasıl hayatta kaldıklarının hem bileşenlerini hem de dinamiklerini yakalayan fiziksel varlıkların ağa bağlı ve senkronize dijital bir kopyası olarak tanımlamıştır (Borth ve diğ., 2019). DT'yi, nesnelerin ve hizmetlerin internetinde akıllı düğümler olarak işlev gören akıllı nesneleri içeren sanal temsiller ve iletişim yeteneklerinden oluşan gerçek dünya nesnelerinin sanal ikameleri olarak tanımlamıştır (Schluse ve Rossmann, 2016). DT'yi, nesnenin kendisine vurgu yaparak gerçek dünyadaki bir şeyin dijital olarak yeniden üretilmesi olarak tanımlamıştır (Canedo, 2016). Ayrıca, DT'yi gelecekteki sistem durumlarını tahmin etmek için fiziksel öğenin kendisinin simülasyonu olarak tanımlamıştır (Gabor ve diğ., 2016). DT'lerin önemli parçaları, fiziksel ve dijital dünyaları birbirine bağlayan verilerin yanı sıra gerçek nesnelerin ve sanal modellerin çift yönlü dinamik etkileşimidir (Tao ve diğ., 2019a). NASA, DT'in ilk resmi tanımını yapmıştır: "İlgili uçan ikizin ömrünü yansıtmak için mevcut en iyi fiziksel modeli, sensör güncellemelerini, filo geçmişini vb. kullanan, inşa edilmiş bir aracın veya sistemin entegre çok fizikli, çok ölçekli, olasılıksal simülasyonu" (Schleich ve diğ., 2017).

DT'ler, gerçek zamanlı gözlem, analiz ve simülasyona olanak tanıyan gerçek şeylerin dijital temsilleridir. Diğer önemli unsurların yanı sıra veri entegrasyonu, modelleme ve simülasyon, analitik ve görselleştirmeyi içerirler (Kineber ve diğ., 2023). Modelleme ve simülasyon gerçek sistemin sanal bir resmini üretirken, veri entegrasyonu çok sayıda kaynaktan gelen verilerin birleştirilmesini içerir (Yoon, 2023). DT'nin birçok akademisyen tarafından uluslararası işletmelerdeki belirli disiplinlere atıfta bulunulmadan tanımlanmış olması nedeniyle, artık nispeten belirsiz ve geneldir (Opoku ve diğ., 2021). Bu fikir ilk ortaya atıldığında sadece tanımlayıcı nitelikteydi ve herhangi bir destekleyici teknolojiden yoksundu. Ancak DT'lerin ortaya çıkışı, sofistike bilgi teknolojilerinin geliştirilmesiyle hazırlanmaktadır (Liu ve diğ., 2021a).

2.2. ENTEGRASYON DÜZEYİ VE DİJİTAL İKİZ PARADİGMA

Yukarıda belirtilen DT tanımlarına dayanarak, her durumda fiziksel nesnelerin dijital kopyaları olarak ortak bir DT kavramı oluşturulabilmektedir. Bu tanımlarda DM, DS ve DT terimleri genellikle eşanlamlı olarak kullanılmaktadır (Kritzinger ve diğ., 2018). Ancak söz

konusu tanımlar, fiziksel ve dijital eşdeğerleri arasında ne kadar veri entegre edildiğine göre değişiklik göstermektedir. Bazı dijital temsiller manuel olarak oluşturulurken ve gerçek dünyayla fiziksel bir bağlantıları yokken, diğerleri gerçek zamanlı veri değişimleriyle tamamen bağlantılıdır (Kritzinger ve diğ., 2018). Yazarlar, DT'lerin ne kadar veriyi entegre ettiklerine bağlı olarak üç bölümde sınıflandırılmasını önermektedir.

Fiziksel ve dijital nesneler arasında otomatik bir veri aktarımı gerçekleşmiyorsa, mevcut veya gelecekteki fiziksel bir şeyin dijital temsili DM olarak adlandırılmaktadır. Dijital temsil, gerçek şeyin az ya da çok derinlemesine bir tanımını içerebilir (Kritzinger ve diğ., 2018). DM fikrine göre, mevcut bir fiziksel nesnenin durumu ile dijital bir öğenin durumu arasında otomatik tek yönlü bir veri akışı da varsa, bu kombinasyon DS olarak bilinmektedir. Fiziksel öğe değiştiğinde dijital nesne de değişir, ancak tam tersi olmamaktadır (Kritzinger ve diğ., 2018). Mevcut bir fiziksel nesne ile dijital bir varlık arasındaki veri akışı her iki yönde de tam olarak entegre edilmişse, bu DT olarak adlandırılır. Bu durumda dijital nesne, fiziksel nesnenin kontrol eden bir örneği olarak da hizmet edebilmektedir. Dijital nesnenin durumu hem gerçek hem de sanal diğer unsurların bir sonucu olarak da değişebilir. Fiziksel öğenin durumundaki bir değişiklik, dijital nesnenin durumunda buna karşılık gelen bir değişikliğe yol açar ve bunun tersi de geçerlidir (Kritzinger ve diğ., 2018). Yukarıda belirtilen üç ana kategori için veri akışı Şekil 2.1'de gösterilmektedir.



Şekil 2.1: DM, DS ve DT'de Veri Akışı.

Şehirler için bir DT oluşturmak için, özellikle veriler farklı ve heterojen kaynaklardan elde edildiğinden ve farklı zaman ve mekânsal ölçeklere yayıldığından, veri entegrasyon yöntemleri çok önemlidir (Shahat ve diğ., 2021; Lei ve diğ., 2023). Bu durum, veri toplama yöntemleri, mevcut coğrafi veri tabanları, gerçek zamanlı sensör verileri, aktüatörler, kitle kaynak kullanımı vb. gibi farklı kaynaklardan gelen verileri entegre eden ve pratikte uygulanan DT'lerde örneklendirilmektedir. Birçok yazar veri entegrasyonunun geometrik yönlerine odaklanmaktadır. İster 3D şehir modelleri (Deng ve diğ., 2021) ister kentsel DT'lerin girdi katmanı olarak şehirler için DT'ler (Döllner, 2020; Lehner ve Dorffner, 2020; Bacher, 2022) ile

ilgili olsun, çeşitli kaynaklardan elde edilen geometrik bilgileri birleştirmek için çeşitli yöntemler önermektedirler. Heterojen verilerin DT'lere etkili bir şekilde entegre edilmesi sadece geometrik kısımla sınırlı olmayıp aynı zamanda semantik, yapı ve depolama yöntemlerini de dikkate almaktadır (Noardo, 2022). DT'lerin çok kaynaklı verileri ortak bir sisteme entegre etmesi ve her bir kullanım durumu için (hareketlilik, sel, hava kirliliği vb.) DT'lerden gelen verilerin özel gereksinimlere uyması gerekmektedir (Jeddoub ve diğ., 2023).

DT paradigması, basit üretilmiş varlıklar, binalar, şehir bölgeleri ve nihayetinde eyalet çapında DT'lerden başlayarak daha yüksek derecede ayrıntı ve hassasiyet gerektirmektedir (Bolton ve diğ., 2018). Bir DT'nin sembolize ettiği karmaşık yapı hakkında kapsamlı bir bakış açısı sunan bir DT yaklaşımı ortaya koymuştur (Grieves, 2014). Şekil 2.2'de gösterildiği gibi, dikkate alınan üç ana DT bileşeni şunlardır: Fiziksel bileşenler, Sanal modeller ve bunları birbirine bağlayan Verilerdir.

Sistemin "Sanal-Fiziksel" ikiliği, birçok biçimiyle "Veri" aracılığıyla birbirine bağlanmaktadır. Buna karşılık, sanaldan fiziksele veri, DM'ler aracılığıyla işlenebilen bilgi ve depolanabilen bilgi - daha yüksek anlam dereceleri ile - çeşitli dönüşümlere tabidir. Örneğin fizikselden sanala gelen verileri ham ve işlenmeye muhtaç olarak görmektedir (Grieves, 2014). Ancak, bilgi nihayetinde aktüatörler aracılığıyla fiziksele geri yansıtılmaktadır. Bu nedenle, fiziksel kısım analiz edilmek üzere göndermeden önce gerçek dünyadan veri toplamaktadır. Buna karşılık, sanal bileşen, gömülü mühendislik modelleri ve AI kullanarak fiziksel kısmın düzenli olarak ihtiyaç duyduğu bilgileri aramaktadır (Boje ve diğ., 2020).

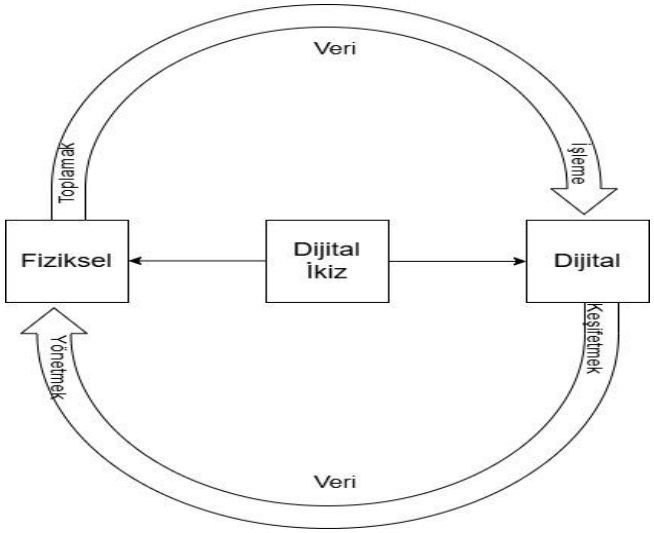

Şekil 2.2: DT paradigması.

2.3. DİJİTAL İKİZ UYGULAMA TEKNOLOJİLERİ

DT uygulamaları tarafından bir dizi veriyle ilgili, yüksek doğrulukta modelleme ve model tabanlı simülasyon teknolojileri kullanılmaktadır. Veriler, sensörler, radyo frekanslı tanımlama (RFID) etiketleri, göstergeler, okuyucular, tarayıcılar, kameralar ve daha fazlası dâhil olmak üzere veriyle ilgili çeşitli teknolojiler kullanılarak oluşturulur ve DT'in temelini oluşturmaktadır. Bu cihazlar düzenli olarak çok büyük hacimlerde yapılandırılmamış, yarı yapılandırılmış ve yapılandırılmış veri üretmektedir. Toplanan verileri önceden işlemek için uç bilişim kullanılır çünkü bu verileri bulut sunucusundaki DT'e taşımak karmaşık ve maliyetlidir. Gerçek zamanlı veri aktarımı ve veri sızıntısının önlenmesi 5G teknolojisi ile mümkün olmaktadır (Liu ve diğ., 2021a). Toplanan verilere anlam kazandırmak için veri füzyonu ve veri haritalamadan da yararlanılmaktadır. Çeşitli kaynaklardan gerçek zamanlı veri toplamak için DT'lerde IoT ve sinyal işleme tekniklerinin ve algoritmalarının uygulanmasını araştırmıştır (He ve diğ., 2018). Fabrikanın varlığı boyunca, onu gerçek zamanlı olarak gözlemleyebilir ve taklit edebilmektedir.

DT modellerinin geliştirilmesi, yüksek doğruluklu modelleme yöntemlerinin kullanılmasını gerektirmektedir. DT modelleri fiziksel veya anlamsal veri modelleri kullanılarak üretilebilmektedir (Liu ve diğ., 2021a). Fiziksel modeller, fiziksel özelliklerinin ve mevcut bağlantılarının ayrıntılı bir şekilde kavranmasını gerektirirken, anlamsal veri modelleri, iyi bilinen girdi ve çıktıları kullanan AI metodolojileri kullanılarak öğretilir. DT'lerin yüksek doğrulukta modellenmesi için çok fizikli bir yöntem gereklidir (Liu ve diğ., 2021a). Belirli

endüstriyel makine parçalarının davranışını taklit eden simülasyon modülleri geliştirmiştir (Negri ve diğ., 2019). Birincil simülasyon modeli, standart arayüzler kullanarak modüllerle bağlantı kurarak üretim sisteminin ömrü boyunca simülasyon yapılmasını sağlamıştır (Opoku ve diğ., 2021). Bu nedenle DT, çeşitli modelleme seviyeleri kullanılarak oluşturulabilmektedir.

Model tabanlı simülasyon teknolojisi kullanılırken DT'lerin simülasyon içermesi gerekmektedir. Fiziksel şey ve sanal model, DT simülasyonu sayesinde gerçek zamanlı olarak ileri geri iletişim kurabilmektedir. Fiziksel ikiz ile çift yönlü bağlantıyı modellemek için otomasyon İşaretleme Dili (automationML) kullanarak DT'e ilişkili modelleme önerilmektedir (Schroeder ve diğ., 2016). DT'nin çeşitli sistemleri, model sayesinde verileri etkili bir şekilde paylaşabilmiştir (Opoku ve diğ., 2021). DT'nin inşaat sektörü gibi diğer alanlardaki bağlam sallaştırılması, imalat sektörünün bu fikri giderek daha fazla benimsemesine rağmen henüz başlangıç aşamasındadır (Negri ve diğ., 2017). Sonuç olarak, sektörün karmaşık sorunlarının üstesinden gelmek için DT'nin inşaat sektöründe yoğun bir şekilde kullanılması gerekmektedir.

Gelişmekte olan teknolojiler şu anda inşaat sektörünün en karmaşık zorluklarından bazılarını çözmek için kullanılmaktadır. Güven ve iş birliği için Blockchain ve BIM (Winfield, 2018; Hijazi ve diğ., 2019); karmaşık insan girdileri ve kontrolü gerektiren geleneksel sözleşmelerin akıllı sözleşmeler olarak otomatikleştirilmesi (Clack ve diğ., 2016); inşaat sağlığı ve güvenliği için Ultra Geniş Bant teknolojisi gibi BIM ve sensörler (Li ve diğ., 2015); kısıtlamalar ve verimlilik için iş ilerlemesi, IoT ve BIM (Dave ve diğ., 2016); enerji tüketimi için enerji yönetimi çözümleriyle entegre coğrafi bilgi sistemi (GIS) (Kim ve diğ., 2012); bina işletimi ve bakımı için BIM ve bina yönetim sistemi (BMS) verileri (Oti ve diğ., 2016); yerinde çevresel izleme için sensörler, BIM ve sanal gerçeklik (VR) (Oppermann ve diğ., 2016); köprü sağlığı izleme için robotik süreç otomasyonu (RPA'lar) (Rashidi ve Samali, 2021) ve modern köprü izleme için yersel lazer tarama (TLS) (Rashidi ve diğ., 2020) yer almaktadır.

Endüstri teknolojilerinin çoğu DT'den etkilenebilmektedir. Örneğin, binaların işletmeye alındıklarındaki durumları hakkında bilgi vermeyi amaçlayan tesis yönetimi as-built BIM modelleri (Teicholz, 2013), binanın mevcut durumunun güncel bir temsilini sağlayamamaktadır. DT bunu destekleyebilmektedir. İnşaatı izlemek için küresel konumlandırma sistemi (GPS), Bilgisayar görüşü, Etiket tanımlama sistemleri, Akıllı sensör ağları, İletişim ağları ve diğerleri dahil olmak üzere çeşitli veri toplama teknolojileri kullanılmaktadır (Opoku ve diğ., 2021). Yalnızca birkaç durum birden fazla teknolojinin

kullanılmasını gerektirmektedir. Çok sayıda izleme sisteminin birden fazla yönetim görevini desteklemek için bir proje veri tabanına veri girebileceği uyumlu ve entegre bir yaklaşımın sürdürülmesi zordur. DT tarafından önerildiği gibi, bu teknolojilerin kapsamlı ve entegre bir şekilde kullanılması, inşaat izleme ve kontrolü için etkili bir yöntem sağlayabilmektedir.

Gerçek zamanlı verileri toplamak ve depolamak, paha biçilmez kavramlar sunmak için bilgi toplamak ve fiziksel bir şeyin dijital bir kopyasını üretmek için DT teknolojilerden yararlanmaktadır (Attaran ve Celik, 2023). IoT, AI, genişletilmiş gerçeklik (XR) ve Bulut bu teknolojilerden bazılarıdır. IoT, birbirine bağlı "şeylerden" oluşan dev bir ağı ifade etmektedir. Bağlantı, nesneler-nesneler, insanlar-nesneler veya insanlar-insanlar arasındadır (Attaran, 2017). DT'nin her uygulaması IoT'yi ana teknoloji olarak kullanmaktadır. Hizmetlerin çevrimiçi olarak barındırılması bulut bilişim olarak adlandırılmaktadır. Bu teknoloji sayesinde veriler etkin bir şekilde depolanır ve internet üzerinden erişilmektedir (Attaran, 2017). Veri hesaplama ve bulut veri depolama, bulut bilişim aracılığıyla DT'lerin kullanımına sunulmaktadır. Bulut bilişim yardımıyla, çok fazla veriye sahip olan DT, bu verileri hayali bir bulutta depolayabilir ve ihtiyaç duyulan verileri herhangi bir yerden rahatça alabilmektedir (Attaran ve Celik, 2023). DT'ler, bulut bilişim sayesinde karmaşık sistemlerin hesaplama süresini verimli bir şekilde kısaltabilir ve çok fazla veri depolamanın zorluklarını aşabilmektedir (Shu ve diğ., 2016). Buna ek olarak, bilgisayar biliminin bir dalı olan AI, insanlarla akıllı bir şekilde iletişim kurabilen yeni bir akıllı makine sınıfı oluşturmak için zekânın temellerini çoğaltmayı amaçlamaktadır. Robotik, görüntü tanıma ve dil tanıma AI araştırmalarının konularıdır. Sinir Ağları, Makine Öğrenimi, Derin Öğrenme ve uzman sistemleri (Hou ve diğ., 2020) içeren AI, elde edilen verileri otomatik olarak analiz edebilen ve değerli kavramlar sağlayabilen, sonuçlar hakkında tahminlerde bulunabilen ve potansiyel sorunlardan nasıl kaçınılacağına dair öneriler sunabilen sofistike bir analitik araç sunarak DT'e yardımcı olabilmektedir (Lv ve Xie, 2022). Son olarak, XR, VR, artırılmış gerçeklik (AR) ve karma gerçeklik (MR) dâhil olmak üzere sürükleyici teknolojiler için kullanılan genel bir addır. Bu teknolojiler, gerçek ve sanal dünyaları kaynaştırarak gerçeklik algısını genişletme gücüne sahiptir (Marr, 2019). Dijital ve fiziksel öğeler, XR'nin dijital alemde nesne temsilleri yaratması yoluyla gerçek zamanlı olarak bir arada var olur ve etkileşime girmektedir. Kullanıcılar, gerçek dünyadaki şeyleri dijital olarak taklit etmek için XR yeteneklerini kullanan DT'ler sayesinde dijital materyallerle etkileşime girebilmektedir (Attaran ve Celik, 2023).

2.4. DİĞER SEKTÖRLERDE DİJİTAL İKİZ

Günümüzde DT'ler, öğelerin hassas sanal modellerini oluşturmak ve operasyonel süreçleri simüle etmek için mühendislik ve imalatta yaygın olarak kullanılmaktadır (Attaran, 2023). Bunula birlikte DT teknolojisi, dijital dönüşüm geçiren çeşitli sektörlerde de kullanılmıştır. Enders ve Hoßbach (2019) çalışmalarında DT'yi uygulayan önde gelen on sanayi sektörünü belirlenmiştir. Bu sektörler havacılık ve uzay, imalat, sağlık, enerji, otomotiv, petrol, kamu sektörü, madencilik, denizcilik ve tarımdır. Ayrıca, simülasyon, izleme ve kontrol olmak üzere söz konusu sektörlerde DT'nin üç temel amaç için kullanıldığını vurgulamışlardır. Ancak, DT'nin uygulamaları sadece bu üç hedefle sınırlı değildir. DT hali hazırda tasarım, doğrulama, özelleştirme, optimizasyon, tahmin ve bakım amaçları için kullanılmaktadır.

2.4.1. Havacılık ve Uzay

Havacılık sektörü, dijital dönüşüm uygulamalarının tüm alanlarında öncü bir güçtür. Havacılık ve uzay sektörü, DT'nin geliştirilmesinde ve yaygın olarak kullanılmasında çok önemli bir rol oynamaktadır. Her şey Apollo programında ortaya çıkan fiziksel ikiz kavramıyla başlamıştır. NASA daha sonra DT'nin ayrıntılı bir tanımını ve açıklamasını yapmıştır. Amerika Birleşik Devletleri Hava Kuvvetleri Araştırma Laboratuvarı (AFRL), DT'yi kestirimci bakım ve uçakların hizmet ömrünün uzatılmasında başarıyla uygulamıştır. Bu durum Boeing, Airbus ve general elektrik gibi büyük şirketlerin DT'ye dâhil olmasına yol açmıştır. Genel olarak, havacılık ve uzay sektörü DT'nin oluşturulmasında, ilerlemesinde ve yaygın olarak kabul görmesinde çok önemli bir rol oynamıştır (Liu ve diğ., 2024). DT'lerin bu sektördeki başlıca kullanım alanları, uzay aracının/uçağının performansını ve güvenilirliğini artırmayı, bakım sorunlarını öngörmeyi ve çözmeyi ve mürettebat için görev güvenliğini artırmayı kapsamaktadır (Singh ve diğ., 2022).

Uçak oldukça karmaşık bir çerçeveye sahiptir ve yapısal tasarım ilkesi statik güç, güvenli ömür ve hasar toleransından bağımsız izlemeye doğru ilerlemiştir (Xiong ve Wang, 2022). Tasarım değişkenler arasında önemli düzeyde karşılıklı bağımlılık, yetersiz veri ve göstergelerin elde edilmesindeki zorluklar gibi sorunlar sergilemektedir (Tao ve diğ., 2019b). Havacılık ve uzay bileşenlerinin işlenmesi için biyomimikri kavramından etkilenen bir DT modelleme yaklaşımı önerilmiştir (Liu ve diğ., 2021b). Bu metodoloji, geometrik, davranışsal ve prosedürel modeller olmak üzere DT modelleme sürecini üç kategoriye ayırmaktadır. Bu yaklaşımın etkinliği, havacılık dümenlerinin analizi ile doğrulanmıştır. Uçaklar karmaşık bir yapıya ve çok sayıda bileşene sahiptir (Pogarskaia ve diğ., 2019). Montaj süreci, uçağın nihai

kalitesini, üretim döngüsünü ve inşaat maliyetlerini belirlemede çok önemli bir rol oynamaktadır. Uçaklarda hızlı ve tekrarlanabilir modüler montaj ihtiyaçlarını karşılamak için özel olarak tasarlanmış yeniden kullanılabilir bir DT sistemi oluşturmuştur (Jin ve diğ., 2023). Sun ve diğ. (2020), DT teknolojisini kullanan ve yüksek basınçlı işleme (HPP) teorisi tarafından yönlendirilen uçak montajı ve hata ayıklama için bir yöntem tanıtmıştır. Montaj ve hata ayıklama için teorik bir çerçeve ile montaj ve hata ayıklama için kapsamlı bir bilgi modeli oluşturmaya yönelik bir metodoloji geliştirmişlerdir.

Montaj teknolojisi, uçak üretim sektöründe çok önemli bir teknolojidir. Rekabet gücünün ve üretim standartlarının geliştirilmesinde önemli bir rol oynamaktadır (Xiong ve Wang, 2022). Montaj süreci üç farklı aşamadan oluşur: atölye planlaması, yerinde montaj ve sorun geri bildirimidir (Zhuang ve diğ., 2021). DT ve dijital iş parçacığının entegrasyonu, kapalı döngü üretim olarak bilinen işbirlikçi ve birbirine bağlı bir bilgi döngüsünü kolaylaştırmaktadır. Bu, kuruluşların tasarım, üretim programı, üretim, otomasyon ve kullanım dâhil olmak üzere çeşitli aşamalarda üretimi senkronize etmelerine ve optimize etmelerine yardımcı olabilmektedir (Demartini ve diğ., 2019). DT, uçak montaj kalitesi verilerinin entegrasyonunu sağlar ve montaj süreci boyunca sanal-fiziksel dünyanın senkronizasyonunu gerçekleştirmek için uçak 3D modelini kullanır (Cai ve diğ., 2021), böylece fiziksel dünyada montaj kalitesinin verimliliğini ve doğruluğunu artırmaktadır. Matris tamamlama teorisi ile çevrimiçi çok noktalı yer değiştirme izleme kullanılarak, uçak montajı yer değiştirmesinin gerçek zamanlı olarak algılanması mümkündür (Liang ve diğ., 2020). DT, uçak montaj hattının akıllı gelişimi için verimliliği, performansı ve görünürlüğü artırmayı amaçlayan bilgi tabanlı bir yaklaşım sunmaktadır (Chang ve diğ., 2021). Uçak montaj DT'si kapsamlı kalite verileri toplama kapasitesine sahiptir (Cai ve diğ., 2019). Bu, ürün montaj sürecinin eşzamanlı olarak modellenmesini ve montaj veri paketlerinin oluşturulmasını sağlayarak karmaşık ürünün üretim sürecinin izlenmesini mümkün kılmaktadır (Zhuang ve diğ., 2021). Sonuç olarak, uçak nihai montaj süreci gelişmiş kalite yönetiminden, iyileştirilmiş montaj kalitesinden ve artan verimlilikten faydalanmaktadır (Zhang ve diğ., 2022b).

Performans ve güvenilirliğine ek olarak, DT kullanmanın bir avantajı da hataları tahmin etme yeteneğidir, dolayısıyla uzay aracı veya uçakların geleneksel planlı bakıma kıyasla daha verimli ve uygun maliyetli bakımını kolaylaştırmaktadır. 2020 yılında ABD AFRL, kestirimci bakım amacıyla B-1B süpersonik bombardıman uçağının DT'sini geliştirme planlarını açıklamıştır. Bu, somun ve cıvata gibi en küçük parçalar da dâhil olmak üzere uçağın her

bileşeni hakkında ayrıntılı bilgi yakalamak için 3D tarama teknolojisinin kullanılmasını içerecektir. Görevler arasındaki aralıklarda yeniden kullanılabilir uzay araçlarının yapısal sağlığının değerlendirilmesine ilişkin önemli bir sorunu ele almıştır (Ye ve diğ., 2020). Uzay aracının sağlığını yönetmeye odaklanan bir DT tanıtılmıştır. Temel amaç, yorulma çatlaklarını tanımlamak ve teşhis etmektedir. Bu çerçevede sürekli güncellenen çatlak verilerini kullanarak, çatlakların gelecekteki yayılımını doğru bir şekilde tahmin etmek ve böylece bakım aralıklarının sıklığını en aza indirmek mümkün hale gelmektedir. DT tarafından desteklenen örtük dijital ikiz modeli adı verilen uçak motoru bakımı için bir çerçeve oluşturmuştur (Xiong ve diğ., 2021). Örtük dijital ikizin motor kestirimci bakımındaki etkinliğini, veriye dayalı bir uzun-kısa süreli bellek (LSTM) modeli ekleyerek doğrulamışlardır.

2.4.2. Üretim

DT'nin kökenleri havacılık ve uzay endüstrisine kadar uzansa da bu teknolojiyi keşfetme ve uygulama konusunda ön planda olan üretim endüstrisidir. DT'ler, Endüstri 4.0 ve akıllı üretimin birincil kolaylaştırıcıları olarak tanımlanmıştır (Qi ve Tao, 2018; Shao ve Helu, 2020). DT teknolojisinin üretim endüstrisinde kullanımı önemli bir umut vaat etmekte ve üretim sürecinde önemli değişiklikler oluşturma kabiliyetine sahiptir (Bilberg ve Malik, 2019; Tekinerdogan ve Verdouw, 2020). Üretilen her ürün, tasarım, üretim, işletme ve bertaraf olmak üzere yaşam döngüsü boyunca dört temel aşamadan geçmektedir.

Tasarım aşamasında DT, tasarımcıların ürün tasarımlarını etkili bir şekilde doğrulamasına, farklı ürün konseptlerinin yineleme sürecini kolaylaştırmasına ve işçilik ve masrafları önemli ölçüde azaltmasına olanak tanımaktadır (Qi ve Tao, 2018). Mühendisler, fiziksel bir prototipe kaynak ayırmadan önce çeşitli tasarımları denemek için tasarım aşamasında DT'ler tarafından üretilen sanal prototipi kullanabilmektedir (Schleich ve diğ., 2017). Bu sayede prototip sayısı azalır, zaman tasarrufu sağlanır ve üretim masrafları düşürülmüş olmaktadır. Ayrıca mühendisler ve tasarımcılar, ürün kalitesi, kişiselleştirme ve kullanım kolaylığı açısından tüketici beklentilerini geliştirmek için birikmiş verileri kullanma becerisine sahiptir (Tekinerdogan ve Verdouw, 2020). Tasarımcının bilgi ve deneyimini temel alarak bisiklet tasarım sürecinde fiziksel alandan geri bildirim verileri toplamıştır (Tao ve diğ., 2019b). DT ile güçlendirilmiş bir ürün tasarım çerçevesi sunmuşlar ve bu çerçevenin üreticilere DT kullanarak gelecekteki ürünleri tasarlama veya yeniden tasarlama konusunda yardımcı olduğunu belirtilmiştir. Ayrıca, DT tasarımcılara tasarımları için uygun malzemeyi seçmelerinde yardımcı olabilmektedir. Çevre dostu malzemeleri verimli bir şekilde seçmek için

DT tabanlı bir yaklaşım sunmuşlardır (Xiang ve diğ., 2019). Bu yöntemi özellikle dizüstü bilgisayar kasalarının seçimine uygulamışlardır. Tasarım ve atık yönetimi de dâhil olmak üzere çeşitli üretim adımlarının simülasyonu farklı malzemeler için gerçekleştirilmiştir. Malzemeler fiziksel özelliklerine, maliyetlerine ve çevresel etkilerine göre değerlendirilmiş ve malzeme seçim sürecini optimize etmek için puanlar atanmıştır.

DT, varlık yönetimi, üretim planlama ve üretim süreci kontrolü gibi birçok yönü iyileştirebilmektedir. Motor bloklarının üretim sürecine odaklanmış ve fiziksel, sanal ve bilgi işleme katmanlarından oluşan bir DT oluşturmuştur (Bambura ve diğ., 2020). Bu metodoloji, somut ve sanal üretim hatları arasında anlık senkronizasyon sağlamıştır. Üretim hatlarının sanal olarak devreye alınmasını simüle etmek için faaliyet tabanlı yönetim (ABM) kullanan veri odaklı bir DT emülatörü geliştirmiştir (Mykoniatis ve Harris, 2021). Ayrıca, DT'yi bir üretim tesisine uygulamak için bir teknik sunmuşlardır (Vijayakumar ve diğ., 2019). Bu yaklaşım, makine durumlarını, forklift yerleşimini, varlık konumunu ve kısıt yönetimini izlemek için gereken sürede önemli bir azalmaya yol açmıştır. DT teknolojisi, paketleme performansını optimize etme, filo yönetimini iyileştirme ve rota verimliliğini artırma gibi çeşitli tedarik zinciri sorunlarını ele alma potansiyeline sahiptir (Blomkvist ve Ullemar Loenbom, 2020).

Ürün müşterilere teslim edildikten ve işletme ve bakım süreçleri başladıktan sonra, DT'nin çeşitli işletme ve bakım hizmetleri sağlayabileceğini savunmaktadır (Tao ve diğ., 2019b). Xu ve diğ. (2019) transfer öğrenmeye dayalı bir arıza yardım teşhis yöntemi önermiştir. Yöntem, DT tabanlı teknikler kullanarak üretim sürecinde farklı cihazlardaki olası arızaları tahmin etmeyi amaçlamaktadır. Bertaraf aşamasında, DT teknolojisini kullanarak atık elektronik ve elektrikli ekipmanlar için yeni bir geri dönüşüm yöntemi oluşturmuştur (Wang ve Wang, 2019). Bu sistem, kullanım ömrünün farklı aşamalarında eksik bilgileri doldurmaya hizmet eder ve fiziksel benzerlerinin durumunu ve eylemlerini çoğaltmak, gözlemlemek, analiz etmek ve yönetmek için kullanılabilmektedir.

2.4.3. Sağlık

Sağlık sektörü küresel olarak en önemli sektörlerden biridir ve günlük yaşamda birçok kişi kullanmaktadır. Sağlık sistemindeki DT teknolojisi, yapılan işinin verimliliğini, maliyet etkinliğini ve performansını artırmak için hastaneleri, operasyonel stratejileri, yetenekleri, personeli ve bakım modellerini analiz etmektedir. Ayrıca bilinçli ve stratejik kararlar

alınmasına da yardımcı olmaktadır (Miskinis, 2018). Covid-19 salgını, sağlık ve yaşam bilimleri sektörünü dijital dönüşüm çabalarını hızlandırmaya zorlamıştır.

Diğer sektörlerde DT teknolojisinde kaydedilen ilerlemeden ilham alarak insan dijital ikizi için kapsamlı bir sistem çerçevesi geliştirmiştir (Lin ve diğ., 2022). İnsan algısının incelenmesi, organların modellenmesi, gövdenin modellenmesi, faaliyetlerin modellenmesi ve sosyal etkileşimlerin modellenmesini içeren yapım sürecinin inceliklerini araştırmışlardır. DT, ilaç geliştirme bağlamında, yeni ilaçların test edilmesi sürecini kolaylaştırabilir, bu da güvenlik ve etkinliklerini sağlarken maliyet tasarrufu ile sonuçlanabilmektedir (Ye ve diğ., 2020). İlaç geliştirme sürecinin her aşamasında önemli miktarda veri üretilmektedir. DT, ilaç araştırmalarında klinik deneme aşamasını hızlandırabilecek ve ilaç dağıtımı için gereken hasta sayısını azaltabilecek modeller oluşturmak için bu verileri kullanmaktadır (Subramanian, 2020). Ayrıca DT'ler, üretkenliği artırmak ve maliyetleri optimize etmek amacıyla bireyselleştirilmiş ve akıllı tıbbi cihazları ve diğer ekipmanları simüle etmek için kullanılabilmektedir (Ross, 2016).

2.5. İNŞAAT PROJELERİNİN YAŞAM DÖNGÜSÜ AŞAMASINDA DİJİTAL İKİZ UYGULAMASI

Endüstri 4.0 kapsamında teknolojinin ortaya çıkması ve ilerlemesi sayesinde üretim, sağlık ve diğer sektörlerin tümü iyileştirilebilmektedir (Akanmu ve diğ., 2021). Bununla birlikte, inşaat sektöründe modernizasyon, dijitalleşme ve bilişim düzeyi ile ilgili sorunlar devam etmektedir (Greif ve diğ., 2020). Söz konusu problemler, üretimin düşmesine (Yin ve diğ., 2019), maliyetlerin artmasına (García de Soto ve diğ., 2018), güvenlik sorunlarının (Baker ve diğ., 2020) ve israfın artmasına (Benachio ve diğ., 2020) neden olabilmektedir. DT, bütünleşmiş otomatik sistemlere sahip yapıların ötesinde, inşaat sektöründe gerçek binalar ile sanal ortamlar (siber-fiziksel sistemler) arasında yakın koordinasyon sağlayacak şekilde sistemleri senkronize etme yeteneğine sahiptir (Madubuike ve diğ., 2022).

Bina operasyonları ve bakımında, DT'ler statik ve dinamik BIM modellerinin birleştirilmesine olarak tanımaktadır (Jiang ve diğ., 2022). Anlamsal web teknolojileri, sensörler, IoT, gelişmiş algoritmalar ve AI, proje geliştirme ve inşaatı izlemek ve kontrol etmek için DT kullanan inşaat yönetimi iş akışlarında bir araya getirilmiştir (Lee ve diğ., 2021). DT kullanan şantiyeler daha üretken, daha iyi iş kalitesine sahip ve güvenlik açısından daha iyi performans göstermektedir (Qazi ve diğ., 2022). Ayrıca araştırmacılar, DT'lerin varlıkların

önleyici bakım ihtiyaçlarını izlemek, teşhis etmek ve tahmin etmek için sensör verileri, geçmiş veriler ve simülasyonlar gibi çeşitli veri kaynaklarından nasıl yararlandığını açıklamıştır (Rafsanjani ve Nabizadeh, 2023). Üstelik, BIM bilgileri, BIM'den dijital gösterimler ve IoT, veri tabanları ve diğer destekleyici teknolojiler aracılığıyla mevcut şantiye ile iletişim, DT'leri kullanarak inşaat projelerini denetlemek ve yönetmek için önerilen çerçeve tarafından mümkün olmaktadır (Li ve diğ., 2021). Wi-Fi, düşük güçlü kablosuz LAN'lar, 5G ve kablosuz sensör ağları (WSN'lar) dâhil olmak üzere IoT özellikli teknolojiler, inşaat sektöründe DT kullanımının artmasını kolaylaştıracaktır (Greif ve diğ., 2020).

2.5.1. Planlama ve Tasarlama Aşaması

İnşaat projeleri söz konusu olduğunda, planlama ve tasarlama ilk sırada yer alır (Ghafourian ve diğ., 2018) ve bu aşama genellikle çok önemli ve finansal olarak yönlendirici olarak kabul edilmektedir (Son ve diğ., 2010; Bao ve diğ., 2022). Bu aşamada bir fizibilite çalışması gerekmektedir. Nihai çizim ve gerekli şartnameler, inşaatın boyutunun ve malzeme gereksinimlerinin belirlenmesi ile sağlanmalıdır (Jiang ve diğ., 2021). Tüm inşaat projesinin temelini oluşturan tasarımın kalitesi, güvenlik (Hossain ve diğ., 2018), verimlilik (Bakhshi ve diğ., 2022), maliyet (Akanbi ve Zhang, 2021) gibi inşaatla ilgili sonraki faaliyetler üzerinde gerçekten de önemli bir etkiye sahip olacaktır (Islam ve diğ., 2021). Sonuç olarak, DT'nin bu aşamada kullanılmasının, tasarlama sürecini hızlandırmak, yeniden çalışma ihtiyacını azaltmak ve tasarımcıların topladıkları verileri daha sonraki projeler için kullanmalarına olanak sağlamak gibi bir dizi avantajı olabilmektedir (Singh ve diğ., 2022). DT'ler, ürünün fiziksel modelini bilgi modeliyle birleştirerek her iki modelin de yinelemeli olarak optimize edilmesini sağlamaktadır (Opoku ve diğ., 2021). Modellerin yinelemeli olarak optimize edilmesi, yeniden çalışma sırasında ek çaba ihtiyacını azaltır ve genel tasarım sürecini kısaltır (Li ve diğ., 2019). Fakat akademisyenler ve profesyoneller DT'nin inşaat projesi planlama ve tasarlama süreçlerini nasıl iyileştirebileceği konusunda aynı fikirde değildir (Jiang, 2021; Pan ve Zhang, 2021; Zhang ve diğ., 2021). Bununla birlikte, DT bazı tasarlama ve planlama bağlamlarında etkili bir şekilde kullanılmıştır.

Bir projenin tasarım ve mühendislik aşamasında DT'nin benimsenmesi, belirli bir varlıkla ilgili dijital bilgileri içeren bir modelin üretilmesi ve sürdürülmesine yönelik bir teknik olan BIM ile kolaylaştırılmıştır (Opoku ve diğ., 2021). Dijital bir BIM modeli, önemli proje dönüm noktaları sırasında iş birliği içinde toplanan ve güncellenen verilere dayanmaktadır. Projenin genel sonucunu geliştirmek amacıyla BIM, tasarım aşamaları sırasında paydaşlardan

girdi toplar ve yaygınlaştırmaktadır (Kaewunruen ve Lian, 2019). İnşaat sektöründe DT'lerin bir uygulaması olarak işlev gören gerçek zamanlı aktif bir model, BIM'in WSN ile birleştirilmesiyle oluşturulmuş (Lin ve Cheung, 2020) ve bu, proje tasarımcılarına projeyi geliştirirken birlikte çalışabilecekleri yararlı bilgiler sağlayacaktır.

Sonuç olarak, DT'ler tasarımcılara projenin tüm dijital ayak izini sunarak iyi bilgilendirilmiş kararlar vermelerini sağlamaktadır (Tao ve diğ., 2019a). Tasarımcılar, DT kullanılarak toplanan verileri bir veri tabanında saklayarak daha sonraki projelerde kullanabilir (Qi ve Tao, 2018) ve enerji yönetimi, tedarikçi seçimi, satın alma ve malzeme seçimi alanlarında karar vermeyi destekleyebilmektedir. Ayrıca BIM, projenin uygulanabilirliği, enerji analizi, sürdürülebilirlik kaygıları ve diğer konular hakkında erken tasarım seçimlerini eğitebilir ve inşaat öncesi kılavuzlar olarak hareket edebilir (Ilhan ve Yaman, 2016).

Ning ve diğ. (2019) çalışmalarında hibrit bir genetik algoritma ve karınca kolonisi modeli kullanarak bir inşaat alanının tasarımının gürültü kirliliğini nasıl etkilediğini sunmuştur. Yönetimin şantiye alanlarının düzenlenmesini planlamasına ve gürültü kirliliğini önemli ölçüde azaltmasına yardımcı olabilecek sonucuna ulaşmışlardır. Tao ve diğ. (2020) ise çalışma alanı girişiminin zamanlama sorununa odaklanmıştır. Girişim problemi, çalışma alanı girişimini iki gruba ayırarak ve iki aşamalı bir meta sezgisel model oluşturarak iyileştirilebilmektedir. Fotoğraflara ve CAD tasarımlarına dayalı olarak mevcut yapılar için yarı otomatik geometrik dijital büküm kullanımı ele alınmıştır (Lu ve diğ., 2020a). Bir ofis binasının bir bölümünü vaka çalışması olarak kullanarak, DT destekli operasyon ve bakımın yapının işletme aşamasında başarılı bir strateji olduğunu keşfetmişlerdir. Ayrıca geometrik dijital bükülmenin mevcut yapılardan ne kadar farklı olduğu da araştırılmıştır. Zhang ve diğ., (2022a) DT tabanlı bir destekli karar verme sistemi oluşturulmuştur. Örneğin, spor tesislerinin seçiminde, görsel veri analizi kullanılarak insanlara kabul edilebilir bir yer seçim stratejisi verilebilmektedir. Önerilen tekniğin doğruluğunu ve hesaplama verimliliğini teyit etmek için deneyler yapılmıştır.

Shao ve Wang (2022) çalışmalarında DT'nin yardımıyla, yeraltı alanının farklı yönlerini dikkate alan metodik bir planlama tekniği oluşturmuştur. Çalışma sonucunda planlama sürecinin net bir şekilde bölünmüş ve metodik bir mimari olmuştur. Ayrıca Bocullo ve diğ. (2023) DT, tasarlama aşamasında enerji tüketimini tahmin etmek için de kullanmıştır. Örneğin, binaya entegre güneş bacaları, yinelemeli fiziksel modellere göre önemli ölçüde hesaplama maliyeti tasarrufu sağlayan bir DT modeli kullanılarak başarılı bir şekilde optimize edilmiştir

(Tariq ve diğ., 2022b). Ayrıca DT, çift katmanlı bir güneş cephesi sisteminin enerji depolamayı nasıl etkileyeceğini tahmin etmek için kullanılmıştır (Tariq ve diğ., 2022a).

2.5.2. Yapım Aşaması

Bir inşaat projesinin en emek yoğun, kaynak yoğun ve karmaşık aşaması yapımdır. Bu aşama, en çok işin yapıldığı aşama olmasının yanı sıra, önemli yapıların inşasını (Zheng ve diğ., 2020), temel inşaatını (Van Tam ve diğ., 2021) ve arazi etüdünü (Li ve diğ., 2018) de içermektedir. Buna ek olarak, yapıların çoğu ısıtma, havalandırma, su ve elektrik için altyapı geliştirilmesini gerektirmektedir. İnşaat sürecindeki otomasyon seviyesini artırmak için DT, bina inşaat projelerinin tüm aşamalarında metodik olarak uygulanmalıdır. Bu program, inşaat faaliyetlerinin gözetimini artırmaya, inşaat verimliliğini artırmaya, inşaatla ilgili tehlikeleri azaltmaya ve bina projelerinin genel kalibresini sağlamaya yardımcı olmaktadır (Wang ve diğ., 2022). DT, yapım aşaması boyunca programlama, kalite yönetimi, malzeme yönetimi, kaynak yönetimi ve sıra yönetimi dâhil olmak üzere çeşitli yönetim görevlerine yardımcı olabilmektedir. Malzemelerin ve işçilerin konumlarını izlemek için etiket tanımlama sistemleri, inşaat kalitesini izlemek için akıllı sensörler ve sensör ağları, üretim ilerlemesini izlemenin yanı sıra yapılan işi bulmak ve ölçmek için GPS gibi birçok teknoloji kullanılmaktadır (Opoku ve diğ., 2021). Birkaç istisna dışında, bu teknolojiler farklı yönetim işlevlerine hizmet edecek şekilde entegre edilmemiştir (Sacks ve diğ., 2020).

DT'ler, bilgi paylaşımı (Jiang ve diğ., 2023), insan-robot etkileşimi (Wang ve diğ., 2021), kalite değerlendirmesi (Tran ve diğ., 2021), inşaat güvenliği (Kamari ve Ham, 2022) ve saha izleme (Alizadehsalehi ve Yitmen, 2023) gibi inşaatla ilgili çok çeşitli sorunları çözmek için kullanılmaktadır. Bununla birlikte, bir projenin yapım aşaması boyunca DT teknolojisini kullanan araştırmaların büyük bir kısmı, nesnenin yapısal sistem bütünlüğünü değerlendirmeye odaklanmıştır. Angjeliu ve diğ. (2020) tarihi tuğla binaların yapısal sistem bütünlüğü incelenirken, DT kavramı uygulamıştır. Yazarlar, tarihi bir tuğla yapı için DT uygulamalarına yönelik bir simülasyon modeli oluşturmuşlardır. Çalışma, DT teknolojisinin farklı gelişim aşamalarındaki yapısal davranışları doğru bir şekilde anlamak için kullanılabileceğini göstermiştir.

Chen ve diğ. (2021) BIM'e dayalı olarak şantiyede kamera yerleştirme optimizasyon tekniği incelemiştir. Strateji, deneyime dayalı kamera yerleşim yöntemiyle karşılaştırıldığında önemli avantajlar ortaya çıkmaktadır. DT'nin dâhil edilmesi halinde bu yaklaşımın doğruluğu

ve verimliliği gelecekte bir miktar artırılabilir ve bu, geçmiş veriler, ampirik veriler, sahada toplanan veriler ve teorik temel birleştirilerek elde edilebilecektir. Ayrıca, DT'nin oluşturduğu ve depoladığı büyük hacimli veriler, inşaat projelerinin planlanması ve programlanması gibi daha sonraki görevlere yardımcı olabilecektir. Uyarlanabilir DT tabanlı çerçeveler geliştirerek ve IoT ile BIM'i birleştirerek, inşaat ilerlemesinin otomatik olarak izlenmesi sağlanacaktır (Jiang ve Jiang, 2022; Ospina-Bohórquez ve diğ., 2022). Yapı bileşeninin sanal konumu, ilerleme takibi için değerli bilgiler sağlamaktadır (Lee ve diğ., 2021; Lee ve Lee, 2021).

Bir projenin ilerleyişini etkileyen en önemli unsurlardan biri de inşaat malzemelerinin teslimatıdır. Greif ve diğ. (2020) şantiye lojistiği, tanınmış bir yapı malzemeleri tedarikçisi ile ortak bir araştırmada dökme silolar için DT kullanmanın fizibilitesini incelemiştir. Karar verme, kaynak sevkiyatı, talep analizi ve kaynak sıkıntısı tespiti gibi bir dizi sorunu başarıyla ele alan akıllı sevkiyat sistemlerini yönetmek için geliştirilmiş bir platform sağlanmıştır (Sun ve Liu, 2022). Hem saha içinde hem de saha dışında modüler entegre inşaat donatım süreçlerinin yönetimini otomatikleştirmek için DT ve blok zinciri teknolojisi ile desteklenen iş birliğine dayalı bir platform sunmuştur (Jiang ve diğ., 2023). Modüler inşaatta tedarik zinciri koordinasyonunu çözmek için modüler bileşen teslimat programlarının tahmin edilmesine olanak tanıyan bir DT çerçevesi tanıtılmıştır (Lee ve diğ., 2021; Lee ve Lee, 2021). Ayrıca, Zhao ve diğ. (2022) gerçek zamanlı veri toplama, kaldırma rotalarını dikkatlice planlama ve prefabrik bileşenlerin yerini tam olarak belirleme gibi çeşitli görevleri yerine getirmek için DT kullanan devrim niteliğinde bir kaldırma yönetim sistemi tanıtılmıştır.

Risk yönetimi, inşaat projesi yönetiminde DT'nin bir başka yararlı kullanımıdır. Bu acil gereksinime yanıt olarak, Sun ve diğ. (2023) riskleri verimli bir şekilde tahmin etmek ve yönetmek, inşaat işçilerinin güvenliğini korumak ve temel çukuru kazısının başarısını garanti etmek için DT teknolojisinden yararlanan akıllı bir yöntem geliştirmiştir. Ayrıca, öngerilmeli çelik binaların güvenlik değerlendirmesi de önemli bir araştırma alanıdır. Sanal etkileşimi kullanarak DT, zaman ve mekânın çok boyutlu birleşimini kolaylaştırarak yapısal güvenlik performans analizinin gerçekleştirilmesine yardımcı olabilmektedir (Liu ve diğ., 2021c). Liu ve diğ. (2022) DT'leri ve destek vektör makinelerini kullanarak kaldırma işlemlerinde güvenlik risklerini tahmin eden bir sistem sunmuştur. Kaldırma prosedürlerindeki potansiyel tehlikeler, gerçek zamanlı kaldırma verilerinin toplanmasıyla tahmin edilebilmektedir. Gelecekteki çalışmalar bu alanı, hizmet katmanının fiziksel katmanı otonom olarak kontrol etmesini de içerecek şekilde genişletebilecektir.

2.5.3. İşletme ve Bakım Aşaması

İnşaat yüklenicileri genellikle işletme ve bakım aşamasında binaların yönetimini diğer paydaşlara bırakır, bu da nesnenin verilerini yönetmeyi ve bunlara erişim sağlamayı daha zor hale getirmektedir. Diğer sektörlerle ve hatta inşaat sektörünün tasarlama veya inşa etme aşamasıyla karşılaştırıldığında, inşaat sektörünün işletme ve bakım aşaması nispeten düşük bir dijitalleşme derecesine sahiptir (Gao ve Pishdad-Bozorgi, 2019). Verilerin aşamalar arasında ve çok sayıda paydaş arasında sorunsuz bir şekilde entegre edilmesinin önündeki zorluklardan biri, inşaat projelerinde yer alan çeşitli operasyonlarda çeşitli tarafların yer almasıdır (Long ve diğ., 2024). Sanal model, ürünün birebir kopyası olsa bile, gerçek projeyle ilgisi yoktur (Anderl ve diğ., 2018).

DT, çeşitli taraflar arasındaki bilgi alışverişini geliştirebilmektedir. DT teknolojisi, projenin işletme ve bakım aşamasında tesis yönetimi, bakım yönetimi, izleme, lojistik ve enerji simülasyonu için kullanılmaktadır. Bina performans yönetimi, enerji tüketimi optimizasyonu ve bina işletme ve bakımı, DT'nin tesis yöneticilerinin almasına yardımcı olabileceği önemli kararlardan sadece birkaçıdır. Gerçek zamanlı verilerin toplanması, projenin operasyonel verimliliğini artırır ve öngörücü bakım ve bilinçli karar vermeyi kolaylaştırmaktadır (Khajavi ve diğ., 2019). Tesis yöneticilerinin ve ilgili alanlardaki araştırmacıların, tesis yönetimi operasyonlarını desteklemek için veri ve bilgilerin en iyi şekilde kullanımını düşünmeleri tavsiye edilmektedir (Su ve diğ., 2023).

Antonino ve diğ. (2019) bina doluluğuna ilişkin geçmiş ve gerçek zamanlı verilerin bina yönetimine önemli faydalar sağladığı göstermiştir. Potansiyel olarak bina hizmetlerini ve bakımını da iyileştirebilmektedirler. Bir vaka çalışmasında yazarlar, kullanıcıların bir ofis binası içindeki hareketlerini izlemek ve gerçek zamanlı doluluk istatistikleri sağlamak için görüntü tanımayı kullanmışlardır. Akıllı sözleşmelerin tanımının, insanların izlenen bir bölge içindeki hareketlerine ilişkin gerçek zamanlı verilerden yararlanabileceğini bulmuşlardır. Bununla birlikte, yazarlar BIM modelini görüntü sensörleri kullanılarak toplanan gerçek verilerle entegre etmede herhangi bir sorun bulamamışlardır. Ayrıca yazarlar, tesis yönetiminde uygulanabilirliğini artırmak için önerdikleri metodolojiyi birçok vaka çalışmasında test etmemişlerdir. Qiuchen ve diğ. (2020) bina seviyesinde çalışmak üzere tasarlanmış benzersiz bir DT sistem mimarisi sunulmuştur. Çeşitli çalışmalar, DT için geleneksel veri toplamanın sıklıkla zaman alıcı sensör okuma örneklerini gerektirdiğini göstermiştir (Khajavi ve diğ., 2019; Elfarri ve diğ., 2023). Öte yandan, Lu ve diğ. (2020a) düzenli, doğru ve kullanıcı dostu bir DT

sistemi oluşturmak için CAD çizimlerini ve resimlerini kullanan yeni bir yarı otomatik yöntem sunulmuştur.

DT uygulamalarını kullanan binalar kullanıcı konforunu artırır, kaynak kullanımını optimize eder, potansiyel senaryoları inceler ve bina işletim sürecindeki tasarım döngülerini ortadan kaldırmaktadır (Perno ve diğ., 2022). Lu ve diğ. (2020b) DT destekli bir anomali tespit sistemi, varlıkların operasyonel durumu hakkında teşhis bilgileri içeren bir izleme verileri koleksiyonu kullanılarak oluşturmuştur. Çalışmaya göre, bir DT tarafından etkinleştirilen bir anormallik tespit sistemi, bina varlıklarının durumunu sürekli olarak izleyebilmektedir. Sonuç olarak, çeşitli proje yaşam döngüsü aşamalarında DT uygulamaları ile farklı karar verme süreçleri desteklenmektedir (Macchi ve diğ., 2018). Buna ek olarak, DT, bina enerji kullanımını optimize etmek için iyi bilgilendirilmiş karar verme sürecine yardımcı olmak için gereklidir (Bortolini ve diğ. 2022).

Elektrikli ekipmanların etkili gerçek zamanlı yönetimi, özellikle kontrollü yükler ve enerji depolama üniteleri için düşük karbonlu operasyonların başarılı bir şekilde gerçekleştirilmesi için gereklidir (Mohseni ve diğ., 2022). Bu kapsamda, Agostinelli ve diğ. (2021) bir konut binasında enerji yönetimini otomatikleştirmek ve optimize etmek için gelişmiş bir sistem oluşturmaya yönelik DT tabanlı bir strateji araştırmıştır. Sağlığın geliştirilmesi ve genel refah gibi insan varlığının çeşitli yönleri üzerindeki derin etkisi nedeniyle, ideal iç mekân ortamlarının oluşturulması çok önemlidir. Clausen ve diğ. (2021) ısıtma, havalandırma ve iklimlendirme (HVAC) sistemini verimli bir şekilde yönetmek için DT'yi içeren bir model öngörülü kontrol tekniği geliştirmiştir. Bu strateji, enerji verimliliğinde ve bireysel termal konforda gözle görülür artışlar sağlamıştır. Bu yaklaşım, bireysel termal konfor tercihlerini tahmin etme hassasiyetini geliştirmiştir. Bina denetimlerinin geleneksel yöntemi öznellik, zaman alan prosedürler ve zahmetli kayıt tutma gibi sorunlardan etkilenmektedir. Denetim sürecini otomatikleştirmek için DT kullanılarak bu sorunlar başarılı bir şekilde çözülebilmektedir (Pantoja-Rosero ve diğ., 2023).

Bina bakımında DT kullanımı için iki ana vurgu alanı bina yapısı bakımı ve bina tesisleri bakımıdır. Loverdos ve Sarhosis (2023) bina yapılarının bakımı alanında, yığma yapılardaki yığma birimleri ve yapısal kusurları otomatik olarak tanımlamayı kolaylaştıran geometrik bir dijital tomografi tekniği sunmuştur. Angjeliu ve diğ. (2020) eski yığma yapıların yapısal davranışını incelemek, güçlendirme önlemlerinin ve önleyici bakımın önemini vurgulamak için

bir DT sistemi oluşturmuştur. Lu ve diğ. (2020b) bina tesislerinin bakımı için anomali tespitini kolaylaştırmak amacıyla, tesislerin sağlık teşhis bilgileri de dâhil olmak üzere çeşitli tespit verilerini çıkaran yeni bir endüstriyel temel sınıfları tabanlı veri yapısı tanıtmıştır. HVAC sistemleri bağlamında, DT tarafından sağlanan anomali tespit yöntemleri, verimli bina varlık izlemesini sağlamak için incelenmiştir (Hosamo ve diğ., 2022; Xie ve diğ., 2023).

2.5.4. Yıkım ve İyileştirme Aşaması

Araştırmacılar genellikle kullanımdan kaldırmayı meşru bir aşama olarak görmezden gelmektedir (Liu ve diğ., 2021a). İnşaat sektöründe DT teknolojisi kullanılırken göz ardı edilen bir diğer aşama da emeklilik dönemiyle kıyaslanabilecek yıkım ve geri kazanım aşamasıdır. Yıkım sektöründe hem miktar hem de tür (Kabirifar ve diğ., 2021) olarak bol miktarda atık bulunmaktadır (Luciano ve diğ., 2021). Ayrıca, yıkım endüstrisi kamu sağlığı (Cheng ve diğ., 2021), ekonomi (Lederer ve diğ., 2020) ve kâr (Su ve diğ., 2020) gibi diğer değişkenleri de etkileyebilmektedir.

Akhtar ve Sarmah (2018) yıkım işinin büyüklüğü ve önemi nedeniyle, hükümet, yükleniciler ve yıkım atığı işleme tesisleri de dâhil olmak üzere çeşitli paydaşlar daha uygun fiyatlı, çevre dostu ve verimli bir bertaraf stratejisi araştırmıştır. Bir nesnenin davranışının anlaşılması genellikle yıkım ve iyileştirme aşamalarında kaybolmaktadır. Nesneler benzer niteliklere sahip olabileceğinden, Grieves ve Vickers (2017) nesnenin bir sonraki neslinin öncülü hakkındaki bilgilerin, benzer şekilde karşılaşılacak zorlukların üstesinden gelmek için kullanılabileceğini öne sürmüştür. Liu ve diğ. (2021a) yıkım ve iyileştirme aşamasının tüm yaşam evreleri hakkında bilgi sağladığından, sanal uzayda düşük bir maliyetin korunabileceğini belirtmiştir.

Züst ve diğ. (2021) tarafından yayınlanan bir araştırma çalışmasında, DT'nin kazı ve yıkım için malzeme akışlarını verimli bir şekilde kontrol etme potansiyelini gösteren grafik tabanlı bir Monte Carlo simülasyonu sunulmuştur. Çökme kazalarının araştırılması söz konusu olduğunda DT, bina çökme olaylarının hem öncesinde hem de sonrasında gerçekçi çok aşamalı modeller oluşturabilmektedir. Bu, gelecekteki yapısal çöküşlerin olası nedenleri ve çözümleri hakkında kapsamlı bir kavrayışa sahip olmayı kolaylaştırmaktadır (Zheng ve diğ., 2022). Bir sonraki nesil binalarda benzer sorunları çözmek için, bir binanın selefinden gelen bilgileri kullanmak zorunlu hale gelmektedir (Opoku ve diğ., 2021).

3. YÖNTEM

3.1. MALZEME

Tez çalışmasında kullanılan veriler, İÜ BAP FLO-2016-23071 numaralı ARDUINO geliştirme kartı ve sensörleriyle yapı elemanlarında meydana gelen deformasyonların kısa ve uzun süreli ölçülmesi projesinden elde edilmiştir (Damcı ve diğ., 2017). Laboratuvarda 185 cm uzunluğunda ve 100x150mm2 kesitinde, özel olarak tasarlanmış ve inşa edilmiş betonarme bir kiriş üzerinde yapılan bir deneyden elde edilmiştir. Kullanılan beton tipi C30 olup, boyuna çubuklar 2ø8 çapında B500B çeliğinden ve enine çubuklar ø6/75 çapındadır. Şekil 3.1, bu çalışmada kullanılan betonarme kirişi göstermektedir.



Şekil 3.1: Çalışmada kullanılan betonarme kirişi (Damcı ve diğ., 2017).

Betonarme kirişe uygulanan yük, nihai yüke ulaşana kadar haftalık olarak kademeli olarak artırılmıştır. Betonarme kirişin başlangıç ağırlığı ilk hafta 162,5 kg olmuştur. Daha sonra, yük toplam altı hafta boyunca her hafta kademeli olarak artırılmış ve 750 kg'lık nihai yük ile sonuçlanmıştır.

Betonarme kiriş üzerinde yük, sıcaklık ve bağıl nemden kaynaklanan gerilmeleri toplamak için bir gerinim ölçüm cihazı kullanılmıştır. Cihaz, sekiz ay boyunca her dakika gerinim değerini kaydederken sıcaklık ve bağıl nemi de kaydetmiştir. Şekil 3.2, gerinim ölçüm cihazını göstermektedir.

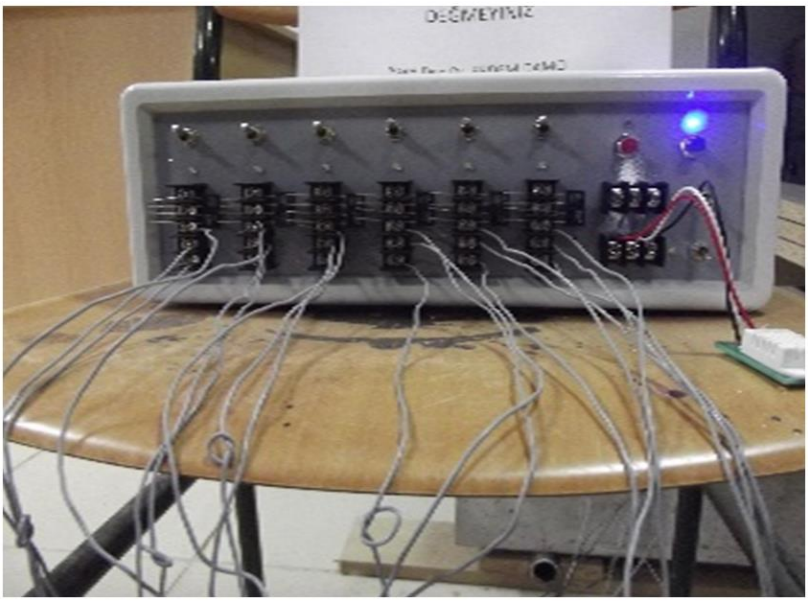

Şekil 3.2: Gerinim ölçüm cihazı (Damcı ve diğ., 2017).

Çalışmada, çeşitli mikroişlemciler ve kontrolörler kullanan Arduino kartları kullanılmıştır. Kartlar, farklı genişleme kartlarına veya breadboard'lara ve diğer devrelere bağlanabilen dijital ve analog giriş/çıkış (I/O) pimleri dizileriyle donatılmıştır. Kartlar, yazılım yükleme amacına hizmet eden, belirli modellerde Evrensel Seri Veri Yolu gibi seri iletişim arayüzleri ile donatılmıştır. Mikrodenetleyiciler C ve C++ programlama dilleri, özellikle de Gömülü C kullanılarak programlanabilmektedir. Bu, bazen Arduino Programlama Dili olarak adlandırılan standart bir API kullanılarak yapılmaktadır. Bu dil Prosessin dilinden esinlenmiştir ve Prosessin entegre bir geliştirme ortamının değiştirilmiş bir versiyonu ile kullanılmaktadır. Arduino projesi, geleneksel derleyici araç zincirleri ile entegre bir geliştirme ortamı sunmaktadır.

3.2. VERİ İŞLEMDE KULLANILAN ARAÇ VE YAZILIMLAR

Tez çalışmasında analiz bölümünü gerçekleştirmek için farklı modeller ile MATLAB programı kullanılmıştır. Ayrıca, bu çalışmada kullanılacak modeller sinir ağı, dışsal girdili

doğrusal olmayan otoregresif ağı (NARX), doğrusal olmayan otoregresif sinir ağı (NARNN) ve regresyon modelleridir.

Analiz kısmı iki aşamada yapılacaktır. İlk aşamanın amacı, ikinci üç ayın verilerini tahmin ederek ve daha sonra bunları daha önce deneyden toplanan verilerle karşılaştırarak dijital varlığı oluşturmak olacaktır. Ayrıca, ikinci aşama, son iki ayın verilerini tahmin ederek ve bunları deneyden elde edilen verilerle karşılaştırarak ilk aşamada oluşturulan dijital modeli incelemeye odaklanacaktır.

3.2.1. Sinir Ağı

Daha az hesaplama yükü ile duyarlılık analizi yapabilmek için modelin bir simülasyon veri tabanı kullanılarak uydurulması önemlidir. Bu çalışmada kullanılan çok girişli, tek çıkışlı doğrusal olmayan model için uygun bulgular, parametreler arasındaki etkileşimi yakalayabilmelidir. Olumsuzlama normal formu için, geri yayılım (BP) sinir ağı ölçeklenebilirliği, esnekliği, öğrenme kapasitesi ve doğrusal olmaması nedeniyle yaygın olarak kullanılmaktadır (Rumelhart ve McClelland, 1987). Levenberg-Marquardt, Bayesian regularization ve scaled conjugate gradient backpropagation iyi bilinen sinir ağı bulanık algoritmalarına örnektir. Levenberg-Marquardt algoritması, Gauss-Newton ve gradyan iniş yöntemlerini birleştirerek parametreleri değiştiren iteratif bir tekniktir. Biraz yavaş olmasına rağmen, Bayesian düzenlemesi küçük veya gürültülü veri setlerinde iyi çalışmaktadır. Ölçeklendirilmiş eşlenik gradyan yaklaşımı, bellek açısından verimli gradyan hesaplamaları kullandığından, büyük ölçekli sorunlar için tavsiye edilmektedir. Mevcut model, makul boyutu ve düşük gürültüsü nedeniyle Bayesian regularization yöntemini kullanmak üzere seçilmiştir.

Bir girdi katmanı, gizli katmanlar ve bir çıktı katmanı bir sinir ağının matematiksel modelini oluşturmaktadır. Ağın nihai çıktı sonucu, çıktı katmanı, her katmandaki nöronları tanımlamak için geriye yayılma tekniğini kullanan gizli katmanlar ve girdi matrisleri anlamına gelen girdi katmanı ile temsil edilmektedir. Ayrıca, eğitim için kullanılan performans fonksiyonu ortalama kare hatasıdır (MSE). Maksimum çağ sayısı 1000 olarak ayarlanmıştır. Minimum gradyan 1e-7 ve maksimum doğrulama kontrolü 10'dur.

Model çıktı sonucu ($\tilde{y}$) ile gerçek sonuç (y) arasındaki mesafe, Denklem (3.1)'de gösterildiği gibi regresyon kaybını ölçen MSE ile ölçülmektedir.

$$\boldsymbol{MSE(y,\bar{y}) = \frac{\sum_{i=1}^{n}(\bar{y}_i - y_i)^2}{n}} \qquad \textbf{(3.1)}$$

Şekil 3.3, sinir ağının mimari çerçevesini göstermektedir.

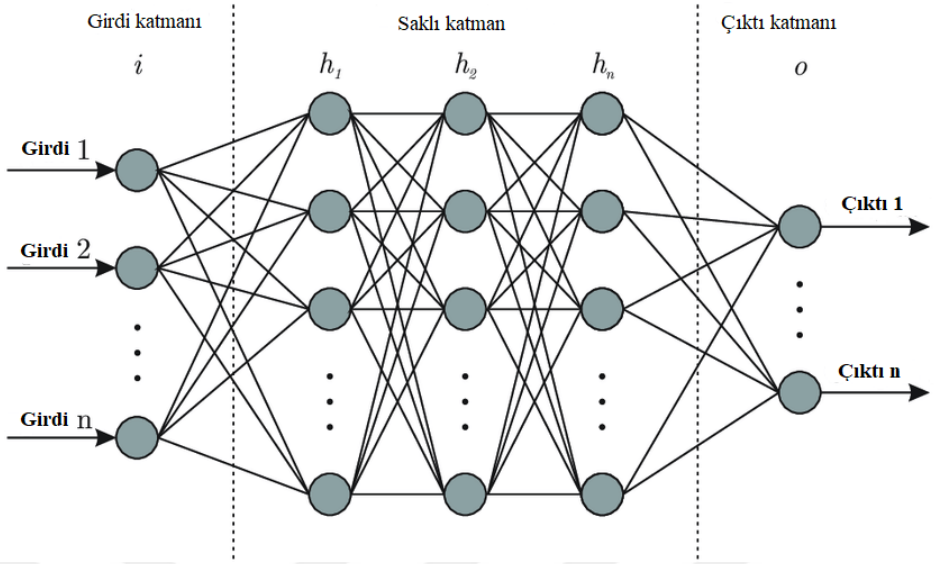

Şekil 3.3: Sinir ağı uyumunun mimari çerçevesi.

3.2.2. NARX

NARX ağlarının, doğrusal olmayan sistemleri, özellikle de zaman serilerini incelerken bu tür problemler için çok uygun güçlü bir model sınıfı olduğu gösterilmiştir (Carbonera ve diğ., 2021). Ayrıca, diğer sinir ağı türleriyle karşılaştırıldığında, NARX ağlarının gradyan inişi öğrenme yöntemleriyle kullanılması daha etkili öğrenme sağlamıştır çünkü gradyan inişi NARX ağlarında daha iyi performans göstermektedir. Üstelik bu ağlar diğer sinir ağı türlerine göre daha hızlı yakınsamakta ve daha iyi genelleme yapmaktadır (Diaconescu, 2008). Bir NARX modelini tanımlayan Denklem (3.2)'deki gibidir,

$$\hat{\boldsymbol{y}}(\boldsymbol{t}) = \boldsymbol{f}\left[\boldsymbol{u}(\boldsymbol{t}), \boldsymbol{u}(\boldsymbol{t-1}), \boldsymbol{u}(\boldsymbol{t-2}), \ldots, \boldsymbol{u}(\boldsymbol{t-n_u}), \boldsymbol{y}(\boldsymbol{t-1}), \boldsymbol{y}(\boldsymbol{t-2}), \ldots, \boldsymbol{y}(\boldsymbol{t-n_y})\right] + \boldsymbol{e}(\boldsymbol{t}) \quad \textbf{(3.2)}$$

Burada gerçek ve tahmin edilen çıktı değişkenleri sırasıyla $y(t)$ ve $\hat{y}(t)$ ile gösterilmektedir; ağın girdi değişkeni $u(t)$ ile gösterilmektedir; girdi ve çıktı değişkenlerinin zaman gecikmeleri n_u ve n_y ile gösterilmektedir ve gerçek ile tahmin arasındaki model hatası $e(t)$ ile gösterilir.

(t) zamanındaki gizli katman çıktısı, aşağıdaki Denklem (3.3)'te gösterildiği gibi u(t) girdi değişkenine dayalı olarak hesaplanmaktadır

$$\boldsymbol{H_i(t)} = \boldsymbol{f_1}\left[\sum_{\boldsymbol{r=0}}^{\boldsymbol{n_u}} \boldsymbol{\omega_{ir}} \boldsymbol{u(t-r)} + \sum_{\boldsymbol{l=1}}^{\boldsymbol{n_y}} \boldsymbol{\omega_{il}} \boldsymbol{y(t-l)} + \boldsymbol{a_i}\right] \quad \textbf{(3.3)}$$

Burada ω_{ir} giriş nöronu ile gizli nöron arasındaki bağlantı ağırlığıdır. ω_{il} gizli nöron ile çıkış geri besleme nöronu arasındaki bağlantı ağırlığıdır; a_i gizli nöronun önyargısıdır ve f_1 gizli katman aktivasyon fonksiyonudur.

Nihai tahmin, aşağıdaki Denklem (3.4)'te gösterildiği gibi gizli katmanın çıktısı birleştirilerek elde edilebilmektedir.

$$\widehat{\boldsymbol{y}}_{\boldsymbol{j}}(\boldsymbol{t}) = \boldsymbol{f}_{\boldsymbol{2}}\left[\sum_{\boldsymbol{i=1}}^{\boldsymbol{n_h}} \boldsymbol{\omega}_{\boldsymbol{ji}}\, \boldsymbol{H}_{\boldsymbol{i}}(\boldsymbol{t}) + \boldsymbol{b}_{\boldsymbol{j}}\right] \quad \textbf{(3.4)}$$

Burada ω_{ji} gizli nöron ile tahmin edilen çıktı arasındaki bağlantı ağırlığıdır; b_j tahmin edilen çıktının yanlılığıdır; n_h gizli nöron sayısıdır ve f_2 çıktı katmanı aktivasyon fonksiyonudur.

Son olarak, model tahmin performansını değerlendirmek için öngörülen ve gözlemlenen sönümleme kuvveti arasındaki kök ortalama kare hatası (RMSE) kullanılmaktadır. Denklem (3.5)'te verilmiştir.

$$\boldsymbol{RMSE} = \sqrt{\frac{\boldsymbol{1}}{\boldsymbol{N}}\sum_{\boldsymbol{i=1}}^{\boldsymbol{N}}\left[\widehat{\boldsymbol{F}}(\boldsymbol{i}) - \boldsymbol{F}(\boldsymbol{i})\right]^{\boldsymbol{2}}} \quad \textbf{(3.5)}$$

Burada $F(i)$ ve $\hat{F}(i)$ ölçülen ve tahmin edilen sönümleme kuvvetidir; N toplam veri miktarıdır.

Şekil 3.4, NARX'ın mimari çerçevesini göstermektedir.

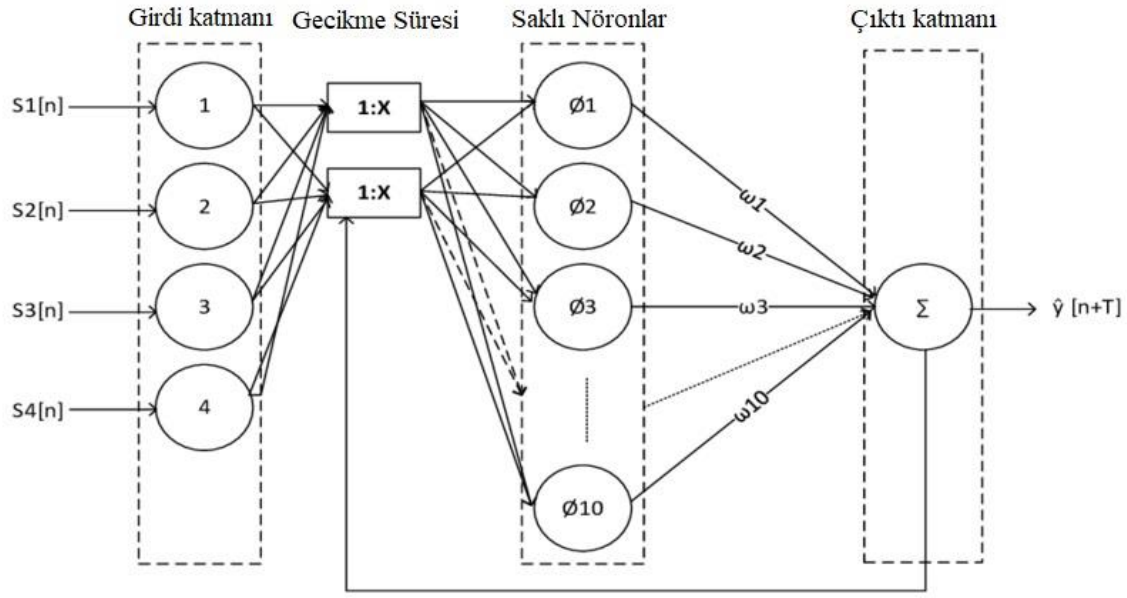

Şekil 3.4: NARX'ın mimari çerçevesini.

3.2.3. NARNN

NARNN, zaman serisi modellerini ve doğrusal olmayan nitelikleri tanımlamada usta olan sağlam bir model kategorisidir. NARNN, katmanları arasında geri besleme bağlantıları içeren tekrarlayan dinamik bir ağdır, yani mevcut çıktısı önceki çıktılarının değerlerine bağlıdır (da Costa Lopes vd. 2015). NARNN, Denklem (3.6)'da tanımlanmıştır (Nyanteh vd. 2013).

$$y(t) = f(y(t-1), y(t-2), y(t-3), ...y(t-n)) + \varepsilon(t) \qquad \textbf{(3.6)}$$

Burada y N-1 girişimcinin birleşik girişim değerleri için veri serisi, f(·) sinir ağının yaklaştırabileceği bir transfer fonksiyonu, n girişim zaman serisinin giriş gecikmesi ve ε yaklaştırma hatasıdır.

NARNN modeli, geri bildirim gecikmeleri, gizli katmandaki nöron sayısı, eğitim prosedürleri ve aktivasyon fonksiyonları dahil olmak üzere ağ kurulum parametreleri için değerler tanımlanarak oluşturulmuştur. Bu parametreler yalnızca sorun alanına bağlıdır ve en iyi değerlerini belirlemek zorlu bir görevdir. Daha sonra, gerçek hedef değerleri geri bildirim olarak kullanılarak açık döngü bir ağ içinde yürütülür ve büyük bir hassasiyetle eğitim gerçekleştirilebilmektedir. Eğitimden sonra, açık döngü modeli kapalı döngü sistemine dönüştürülür ve yeni öngörülen bir değer geri bildirim ağına girdi olarak yeniden verilmektedir.

Bir NARNN, bir sinir ağı çerçevesi kullanarak zaman serisi verilerindeki zamansal karşılıklı bağımlılığı modelleyerek çalışmaktadır. Zaman serisi verileri bir dizi değer olarak

gösterilmektedir. Kavram, gelecekteki değerleri (çıktılar) tahmin etmek için serinin geçmiş değerlerini (girdiler) kullanmayı içerir. “Otoregresif” özelliği, modelin gelecekteki değerleri tahmin etmek için aynı serinin önceki zaman adımlarını kullandığını göstermektedir. Belirli bir t zamanında, önceki zaman adımlarından (t-1, t-2, ..., t-n) elde edilen değerler sinir ağına girdi olarak hizmet etmektedir. Kullanılan geçmiş veri miktarı (n olarak gösterilir), otoregresif modelin sırası olarak adlandırılan bir hiper parametredir.

İleri bildirim sinir ağı genellikle bir veya daha fazla gizli katmanla kullanılmaktadır. Giriş düğümleri önceki gözlemleri belirtirken, çıkış düğümü serideki sonraki değer için tahmin sunmaktadır. Gizli katmanlarda kullanılan aktivasyon fonksiyonları doğrusal olmayan bir yapı oluşturarak modelin veriler içindeki karmaşık örüntüleri ayırt etmesini sağlamaktadır. Eğitim boyunca model, ağırlıklarını ve önyargılarını geri yayılım yoluyla değiştirerek bir kayıp fonksiyonunu, genellikle MSE en aza indirmeye çalışmaktadır. Eğitim veri seti, önceki gözlemlerin dizilerini girdi olarak seçerek ve sonraki değerleri çıktı olarak eşleştirerek oluşturulan girdi-çıktı çiftlerinden oluşmaktadır. Eğitimin tamamlanmasının ardından model, zaman serisindeki en son (n) gözlemleri ağa girerek bir tahmin oluşturmak için kullanmaktadır. Çıktı, beklenen sonraki değeri ifade etmektedir. Bu yöntem, yeni öngörülen değerleri girdiye dahil ederek geleceğe yönelik daha fazla tahmin yapmak için tekrar tekrar tekrarlanabilmektedir.

Şekil 3.5, NARNN'ın mimari çerçevesini göstermektedir.

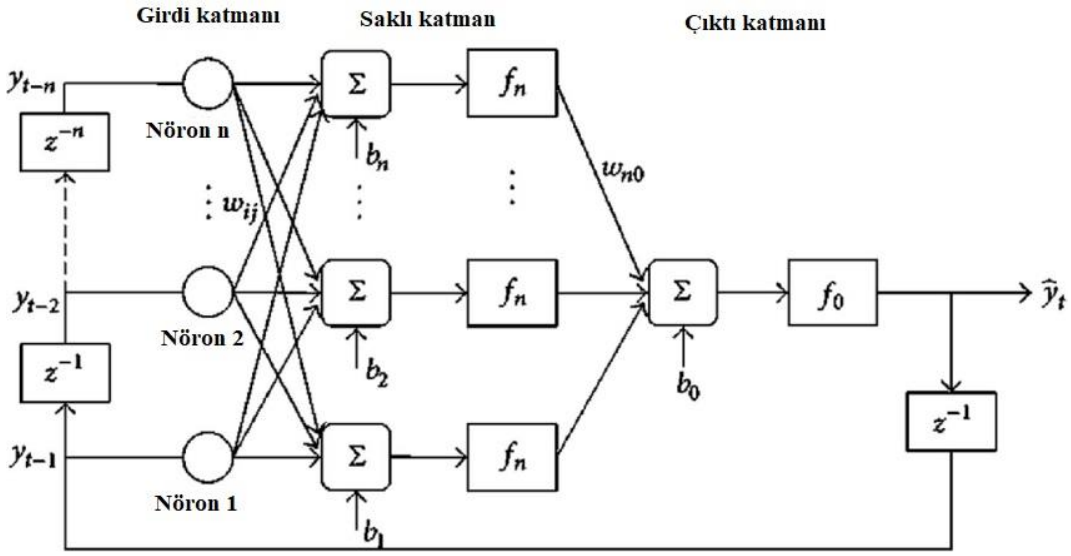

Şekil 3.5: NARNN'ın mimari çerçevesi.

3.2.4. İstatistiksel Modeller

İstatistiksel modeller, geçmiş verilere ve diğer ilgili değişkenlere dayalı olarak gelecekteki sonuçları tahmin etmeye veya öngörmeye yönelik yöntemlerdir. Doğrusal regresyon modelleri, karar ağaçları, topluluk modelleri, üstel düzleştirme, zaman serisi ayrıştırma modelleri ve Bayesian teknikleri tahmin için kullanılan birkaç popüler istatistiksel modeldir. Verilerin özellikleri ve tahmin gereksinimleri model seçimini etkilemektedir. Belirli bir tahmin görevine en iyi uyan modeli seçmek için çeşitli modelleri değerlendirmek olağan bir uygulamadır. Tablo 3.1, tez çalışmasında kullanılan regresyon algoritmalarını göstermektedir.

Doğrusal regresyon modeli, bir bağımlı değişken olan y ile bir veya daha fazla bağımsız değişken olan X arasındaki bağlantıyı açıklayan matematiksel bir gösterimdir. Bağımsız değişkenler alternatif olarak açıklayıcı veya tahmin edici değişkenler olarak adlandırılmaktadır. Sürekli yor dayıcı değişkenler alternatif olarak ortak değişkenler olarak adlandırılırken, kategorik yor dayıcı değişkenler alternatif olarak faktörler olarak anılmaktadır. Yor dayıcı değişkenlere ilişkin gözlemleri içeren X matrisi bazen tasarım matrisi olarak da adlandırılmaktadır.

Tipik olarak, doğrusal bir regresyon modeli Denklem (3.7) ile temsil edilebilmektedir:

$$\boldsymbol{y_i = \beta_0 + \sum_{K=1}^{K} \beta_K f_K(X_{i1}, X_{i2}, \ldots\ldots, X_{ip}) + \varepsilon_i}, \quad \boldsymbol{i = 1, \ldots, n}, \tag{3.7}$$

N: toplam gözlem sayısını temsil etmektedir.

y_i: i_{th} pozisyonuna karşılık gelen yanıtı temsil etmektedir.

β_K: katsayısı modeldeki K_{th} terimi temsil eder ve β_0 özellikle sabit terimi göstermektedir. Bazen, tasarım matrisleri sabit terime ilişkin veriler içerebilmektedir.

X_{ij}: i_{th} tahmin edici değişkenin birinci ölçümünü temsil etmektedir, burada j 1 ile p arasında değişmektedir.

ε_i: rastgele bir hatayı ifade eden i_{th} gürültü terimini temsil etmektedir.

Regresyon ağaçları, hedef değişkenlerin yapraklardaki sınıf etiketleriyle sınırlı olmak yerine sürekli değerlere sahip olabildiği bir karar ağacı türüdür. Regresyon ağaçları, ayarlanmış bölme seçim kriterleri ve durdurma kriterleri kullanmaktadır. Regresyon ağaçları verileri alt kümelere, özellikle dallara, düğümlere ve yapraklara bölmektedir. Karar ağaçlarına benzer şekilde, regresyon ağaçları da hedef öznitelik değerlerinin değişkenliğini azaltan bölünmeleri seçmektedir. Bu nedenle, hedef öznitelik değerleri yaprak düğümlerindeki ortalama değerlerden çıkarılabilmektedir.

Destek vektör makinesi (SVM) analizi, ilk olarak 1992 yılında Vladimir Vapnik ve meslektaşları tarafından keşfedilen, sınıflandırma ve regresyon için yaygın olarak kullanılan bir makine öğrenme tekniğidir (Vapnik, 2000). SVM regresyonu, Kernel fonksiyonlarına bağımlılığı nedeniyle parametrik olmayan bir yöntem olarak sınıflandırılmaktadır. SVM doğrusal ve doğrusal olmayan olmak üzere iki tür regresyon içerir.

Verimli bir şekilde eğitilen doğrusal regresyon modelleri, eğitim hesaplamaları için gereken süreyi azaltan, ancak belirli bir doğruluk derecesi pahasına yöntemler kullanmaktadır. Şu anda verimli eğitim için mevcut olan modeller doğrusal en küçük kareler modelleri ve doğrusal destek vektör makineleridir. Çok sayıda tahminci veya gözlem içeren veri kümeleriyle çalışırken, önceden var olan doğrusal veya doğrusal SVM modellerine güvenmek yerine, etkili bir şekilde eğitilmiş doğrusal regresyon modellerinin kullanılması tavsiye edilmektedir.

Gauss süreci regresyonu (GPR), makine öğrenimi ve istatistik alanlarında kullanılan çok yönlü ve sağlam bir parametrik olmayan regresyon yöntemidir. Özellikle girdi değişkenleri ile çıktı arasındaki bağlantının açıkça anlaşılmadığı veya karmaşık olabileceği sürekli verilerle ilgili sorunları ele almak için faydalıdır. GPR, tahminlerdeki belirsizliğin modellenmesine olanak tanıyan olasılıksal bir yöntemdir. Bu, onu optimizasyon ve zaman serisi tahmini gibi

çok çeşitli uygulamalarda oldukça kullanışlı bir araç haline getirmektedir. GPR, herhangi bir sonlu sayıda alındığında ortak bir Gauss dağılımını izleyen bir dizi rastgele değişken olan Gauss süreci ilkesi üzerine kurulmuştur. Bir Gauss süreci, fonksiyonlar arasında bir olasılık dağılımı olarak kavramlaştırılabilmektedir. Önceki ortalama ve önceki kovaryansın sağlanması gereklidir. Kovaryans bir Kernel nesnesi olarak tanımlanır. Çekirdeğin hiper-parametreleri, verilen optimize edici kullanılarak log-marjinal-olabilirlik maksimize edilerek uydurma işlemi sırasında optimize edilmektedir. Maksimize etme süreci konveks olmayan optimizasyonu içerir, bu da birkaç yerel optimal olduğu anlamına gelmektedir. Bunu ele almak için optimize edici birden çok kez yeniden başlatılmaktadır. İlk iterasyon başlangıç hiper parametrelerinin kullanımıyla başlarken, sonraki iterasyonlar izin verilen aralıkta rastgele seçilen hiper parametreleri kullanmaktadır.

Çekirdek yaklaşım modelleri, çok sayıda gözlemle doğrusal olmayan regresyon yapmak için yaygın olarak kullanılmaktadır. Çekirdek yaklaşım modelleri, büyük bellek içi verilerle uğraşırken Gauss çekirdekli SVM modellerinden daha hızlı eğitme ve tahmin etme eğilimindedir. Ayrıca, bir ağaç topluluğu, çok sayıda zayıf öğreniciyi sağlam bir öğrenicide birleştirmek için kullanılabilecek yetkin bir stratejidir. Ağaç topluluğunun arkasındaki temel kavram, bazıları tatmin edici performans elde edememiş olsa bile çok sayıda ağacın sonuçlarını birleştirmektir. Bu kolektif varlık, bireysel ağaçların eksikliklerini hafifletir ve böylece genel performansı artmaktadır.

Bir regresyon analizi Sinir Ağı nesnesi, regresyon görevleri için özel olarak tasarlanmış eğitimli, ileri beslemeli ve tam bağlantılı bir sinir ağıdır. Sinir ağının ilk katmanı tamamen bağlantılıdır, yani tahmin edici veri X'ten girdi almaktadır. Ağdaki sonraki her katman da bir önceki katmana bağlıdır. Her tam bağlantılı katmanın girdisi bir ağırlık matrisi (Katman Ağırlıkları) ile çarpılır ve ardından bir yanlılık vektörü (Katman Yanlılıkları) eklenmektedir. Son katman hariç (hem aktivasyonları hem de çıkış katmanı aktivasyonunu içerir), tamamen bağlantılı her katmana bir aktivasyon fonksiyonu uygulanmaktadır. Nihai tam bağlantılı katman, ağın çıktısını, özellikle de yanıt için öngörülen değerleri üretmektedir.

Tablo 3.1: Tez çalışmasında kullanılan regresyon algoritmaları.

Grup	Algoritmalar
Doğrusal Regresyon Modelleri	1. Doğrusal 2. Doğrusal Etkileşimler 3. Sağlam Doğrusal 4. Kademeli Doğrusal
Regresyon Ağaçları	1. İnce Ağaç 2. Orta Ağaç 3. Kaba Ağaç 4. Optimize Ağaç
Destek Vektör Makineleri (SVM)	1. Doğrusal SVM 2. Karesel SVM 3. Kübik SVM 4. İnce Gauss SVM 5. Orta Gauss SVM 6. Kaba Gauss SVM 7. Optimize SVM
Verimli Şekilde Eğitilmiş Doğrusal Regresyon Modelleri	1. Verimli Doğrusal En Küçük Kareler 2. Verimli Doğrusal SVM 3. Optimize Verimli Doğrusal
Gauss Süreci Regresyon Modelleri (GPR)	1. Rasyonel Karesel GPR 2. Kare Üstel GPR 3. Matern 5/2 GPR 4. Üstel GPR
Kernel Yaklaşım Regresyon Modelleri	1. SVM Çekirdeği 2. En Küçük Kareler Çekirdeği 3. Optimize Çekirdek
Ağaç Toplulukları	1. Güçlendirilmiş Ağaçlar 2. Torbalı Ağaçlar 3. Optimize Topluluk
Sinir Ağları	1. Dar Sinir Ağı 2. Orta Sinir Ağı 3. Geniş Sinir Ağı 4. Çift Katmanlı Sinir Ağı 5. Üç Katmanlı Sinir Ağı 6. Optimize Sinir Ağı

Şekil 3.6, gerekli verilerin elde edilmesi ve deneyden veri toplamak için sensörlerin kullanılmasıyla başlayan, daha sonra gelecekteki sonuçları tahmin etmek ve sanal varlığı oluşturmak için makine öğrenimi algoritmalarını kullanan ve son olarak fiziksel varlığı geliştirmek için oluşturulan sanal varlığı kullanan bu çalışmanın analiz sürecini göstermektedir.

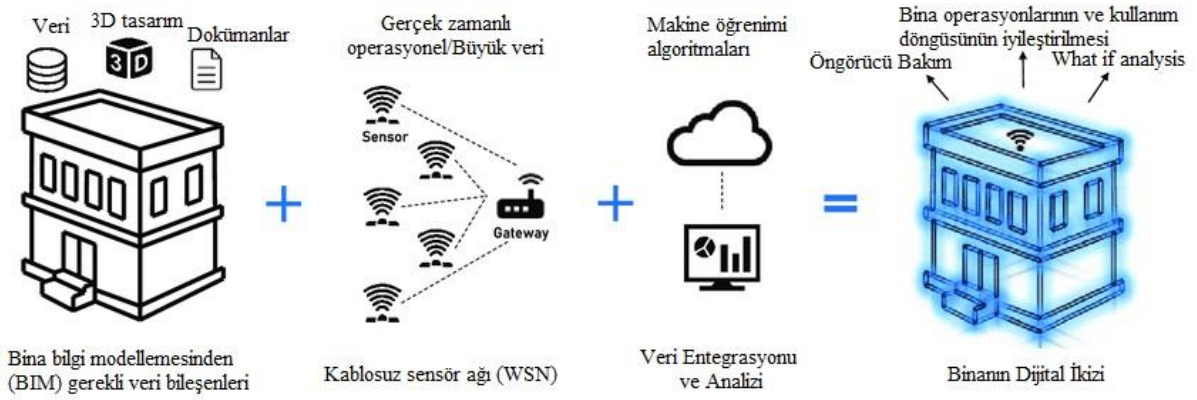

Şekil 3.6: DT oluşturma süreci.

4. BULGULAR

4.1. İNŞAATTA DİJİTAL İKİZ MODELİNİN OLUŞTURMASI

4.1.1. Model Oluşturması

DT'nin temel bileşenleri arasında maddi varlıklar, maddi olmayan varlıklar ve birbirine bağlı gerçek zamanlı veriler yer almaktadır. Dolayısıyla, DT modeli yukarıda bahsedilen bileşenleri içermelidir. Çok sayıda çalışma BIM'i DT'nin bir bileşeni olarak sınıflandırmakta ve inşaat mühendislik endüstrisinde değerli bir veri kaynağı olarak hizmet vermektedir. Bu nedenle, inşaat sektöründe BIM, DT modelini geliştirmek için kullanılan birincil teknoloji olmaktır. Herhangi bir inşaat projesinin ilk aşamalarında BIM, tüm grafik bilgileri ve malzeme özellikleri gibi grafik olmayan verileri içeren binaların veya altyapı projelerinin sanal 3D modellerini üretmek için kullanılacaktır. Ardından, simülasyon araçlarının BIM ile birleştirilmesi, gelişmiş enerji simülasyonları, diğer önemli değerlendirmeler ve daha iyi bilgilendirilmiş karar verme kapasitesini artıracak ve bunların tümü çeşitli proje yaşam döngüsü süreçlerini iyileştirecektir. Buna ek olarak, taramadan BIM teknolojisine, lazer taramalı nokta bulutlarından oluşturulan dijital modelleri BIM platformlarına dönüştüren, daha sonra bilgileri analiz eden ve geliştirme, tasarım ve inşaatta yer alan ekipler için bir 3D şantiye veya bina modeline dâhil eden bir prosedür veya iş akışından oluşmaktadır. Söz konusu oluşum, kapsamlı ve dinamik proje kavramları sağlayabilir, projeleri etkinliklerini, satın alınabilirliklerini ve sürdürülebilirliklerini artırarak güçlendirebilir ve genel proje yönetimini ve yürütmeyi iyileştirebilmektedir.

Sensörler ve dronlar gibi IoT teknolojileri, sahadaki makine ve araçların performansının izlenmesine yardımcı olmak ve hatta işletme aşamasında binada kullanılan ekipman ve sistemlerin performansını izlemek için sürekli veri sunmaktadır. Bu sürekli toplanan veriler, DT'nin temel bileşenlerinden birini yansıtan gerçek zamanlı bilgiyi yakalamak için gereklidir. Bu gerçek zamanlı bilgi, önleyici bakımı kolaylaştırmakta, üretkenliği artırmakta ve bina sakinlerinin konforunu yükseltmektedir. Ayrıca, MR, VR ve AR gibi XR teknolojilerinin gelişmesiyle, inşaat sektöründeki uzmanlar binayı daha iyi anlayabilmekte ve birlikte çalışabilmektedir. Nihayetinde, inşaat sektöründe DT çerçevesini oluşturmak için kullanılabilecek teknolojiler, AI algoritmalarının önceki teknolojilerle entegrasyonu ile

tamamlanacaktır. AI, işçi güvenliğinin büyük ölçüde artırılmasına, masrafların ve gecikmelerin azaltılmasına ve kaynakların en uygun şekilde tahsis edilmesine destek sağlamaktadır. Örneğin, AI önceki projelerden elde edilen verileri kapsamlı bir şekilde değerlendirerek olası riskleri ve sorunları tahmin edebilecektir. Bu, proje ekiplerinin gecikmeleri ve maliyet aşımlarını azaltmak için proaktif adımlar atmasını sağlayacaktır. Ayrıca AI, sürdürülebilir inşaat yöntemlerinin geliştirilmesi, müşteri memnuniyeti seviyelerinin yükseltilmesi ve inşaat kalite kontrolünün güçlendirilmesi için büyük bir potansiyel taşımaktadır.

Şekil 4.1'de DT çerçeve modelini, bina inşaatı alanı içinde göstermektedir. DT sistemi, inşaat sektörünün birbiriyle bağlantılı olarak kullanabileceği üç temel teknolojiyi içermektedir. Sürecin ilk adımı, sistemin DT için ana verileri oluşturmak amacıyla BIM araçlarından proje verilerini ve dokümantasyonunu elde edilmesini içermektedir. Buna ek olarak, IoT cihazları inşaat projelerinin çeşitli aşamalarında gerçek zamanlı verilerin toplanmasında önemli bir rol oynayacaktır. Bu veriler, projenin ömrü boyunca performansın izlenmesine ve takip edilmesine yardımcı olmak açısından hayati önem taşıyacaktır. BIM araçları daha sonra çeşitli IoT cihazlarından gelen gerçek zamanlı verileri, ürettikleri veri ve belgelere dahil edecektir. Bu, çeşitli paydaşların daha etkin bir şekilde iş birliği yapmasını sağlayacak ve inşaat projesinin başarıyla tamamlanmasına yol açacaktır. Daha sonra makine öğrenimi gibi AI yazılımı ve algoritmalar tahmine dayalı analiz için kullanılacaktır. Bu süreç, fiziksel varlığın dijital bir temsilinin geliştirilmesine yardımcı olacak ve böylece proje süresi boyunca verimliliği ve karar verme süreçlerini artıracaktır. Sonuç olarak, üretilen veriler ve modeller, gelecekteki benzer projelerde avantajlarından yararlanmak için bulut platformunda saklanacaktır.

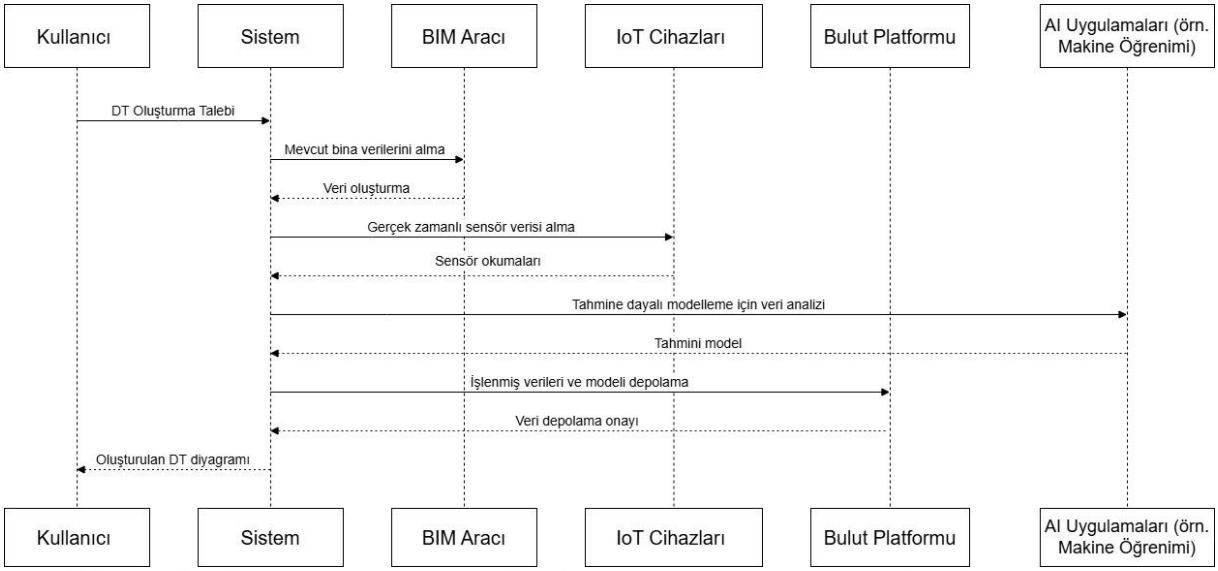

Şekil 4.1: İnşaat sektöründe DT çerçevesi.

Literatürde yapılan analizde, inşaat projelerinin dört farklı bölüme ayrılabileceğini ortaya koymaktadır. Projenin ilk aşaması planlama ve tasarımı içermekte ve tüm çabanın çerçevesini oluşturmaktadır. Bu aşamada, inşaat sürecini yönlendirmek için kapsamlı planlar ve ozalitler üretilmektedir. Mimarlar, mühendisler ve müşteriler de dahil olmak üzere başlıca paydaşlar, projenin tüm şartnamelere ve kurallara uymasını sağlamak için iş birliği yapmaktadır. Bir sonraki adım inşaat aşamasıdır. Temel görevler arasında saha hazırlığı, temel inşaatı, yapısal çerçeveleme ve sıhhi tesisat, elektrik ve HVAC gibi hizmetlerin kurulumu yer almaktadır. Bu aşamada, proje yönetimi ve inşaat ekipleri, projenin zaman çizelgesine uymasını ve bütçe kısıtlamaları dahilinde kalmasını sağlamak için yakın iş birliği içinde çalışmaktadır. Üçüncü aşama ise inşaatın tamamlanmasının ardından başlayan işletme ve bakım aşamasıdır. Bu aşama, binanın varlığı boyunca etkin bir şekilde işletilmesini ve durumunun korunmasını vurgulamaktadır. Bu aşamanın başlıca faaliyetleri arasında düzenli denetimler, önleyici bakım ve bina içindeki yapısal parçaların ve sistemlerin onarımı yer almaktadır. Dördüncü aşama, bir binanın veya yapının metodik olarak sökülmesi veya yıkılması olan yıkım aşamasıdır. Bu aşamada, atıkların ve çevresel etkilerin azaltılması amacıyla geri dönüşüm ve malzemelerin kurtarılması çağdaş yıkım yöntemlerinin önemli bileşenleridir. Şekil 4.2, bu çalışmada ana hatlarıyla belirtildiği üzere inşaat projelerinin aşamalarını göstermektedir.

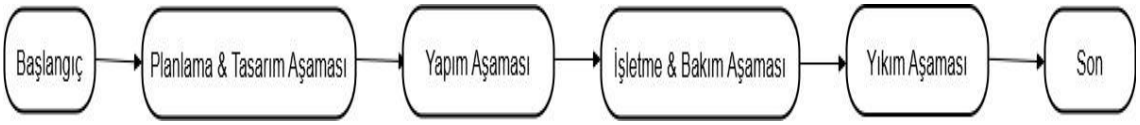

Şekil 4.2: İnşaat projenin aşamaları.

Planlama ve tasarım aşamasında, BIM'in simülasyon araçlarıyla entegrasyonu, projenin 3D modellerinin geliştirilmesi için çok önemlidir. Bu süreç, binanın yapısal unsurlarını, malzemelerini ve ekipmanlarını, saha simülasyonlarını, inşaat sahasının geoteknik değerlendirmelerini, öngörülen maliyetleri ve zaman çizelgelerini ve daha önce tamamlanmış benzer projelerden elde edilen geçmiş verileri içermektedir. Gerçek zamanlı verilerin ve sofistike modelleme yaklaşımlarının entegrasyonu sayesinde DT, doğru planlama, olası zorlukların erken tespiti ve tasarım kararlarının optimizasyonunu sağlamaktadır. Sonuç olarak DT, mimarlara, mühendislere ve paydaşlara verimli proje planlaması, tasarım süreçlerini kolaylaştırma, parametrik yapısal analiz yapma, maliyet tahminini iyileştirme, zamanlamayı optimize etme, enerji tüketimini tahmin etme, malzeme seçimini geliştirme, tedarik süreçlerini iyileştirme ve karar verme sürecini güçlendirme konularında yardımcı olacaktır.

Şekil 4.3, planlama ve tasarım aşaması boyunca DT'nin yürütülmesi için sistematik bir yaklaşımı tanımlamaktadır. Süreç, projeyi başlatan ve genel hedefleri ve kriterleri belirleyen mal sahibi ile başlamaktadır. Mal sahibinin vizyonunu pratik planlara dönüştürmekten sorumlu olan planlama ve tasarım ekibi, birkaç önemli aşamada çalışmaya başlayacaktır. Planlamayı içeren ön aşama, proje hedeflerinin, kapsamının ve kısıtlamalarının tanımlanmasını gerektirmektedir. Sonraki tasarım çalışmaları için zemin hazırlanmış olmaktadır. Planlamanın ardından tasarım aşaması, kapsamlı şartnamelerin ve planların formüle edilmesini içermektedir. Bu, projenin üç boyutlu modellerini oluşturmak, görselleştirme ve tasarım hassasiyetini artırmak için sofistike yazılımların yanı sıra projenin fiziksel ve işlevsel özelliklerinin dijital bir temsili olarak hizmet veren ve böylece paydaşlar arasında gelişmiş iş birliği ve bilgi alışverişini teşvik eden BIM'in kullanılmasını içermektedir.

DT sistemi, karar verme süreçlerini iyileştirmek için çeşitli veri akışlarını birleştirmektedir. Veri entegrasyonu, proje performansı ve koşulları hakkında gerçek zamanlı veri toplayan BIM ve IoT sensörleri de dahil olmak üzere çeşitli kaynaklardan gelen bilgilerin birleştirilmesini gerektirmektedir. Performans analizi, projenin verimliliğini ve etkinliğini değerlendirmek için yapılacaktır. Buna karşılık, AR ve VR dahil olmak üzere çeşitli XR teknolojilerini kullanan görselleştirme, paydaşlar arasında anlama ve iletişimi geliştirmek için

verilerin görsel temsillerini sağlayacaktır. Ayrıca, çeşitli durumları modellemek ve sonuçları tahmin etmek için sofistike AI algoritmalarının kullanılması, proje performans optimizasyonunu geliştirecektir. Optimizasyon aşamasında, üstün sonuçlar elde etmek için prosedürlerin ve tasarımların geliştirilmesine odaklanılacaktır. Önceki değerlendirmeler ve optimizasyonların rehberliğinde, paydaşlar projenin gidişatı hakkında önemli seçimler yapmaktadır. Karar verildikten sonra, planlar ve tasarımlar uygulanacak ve projenin fiilen inşa edilmesine yol açacaktır. Geri bildirim döngüsü, inşaat aşamasından gelen kavram ve verileri planlama ve tasarım süreçlerine yeniden entegre ederek sürekli iyileştirmeyi garanti eden kritik bir unsur içermektedir.

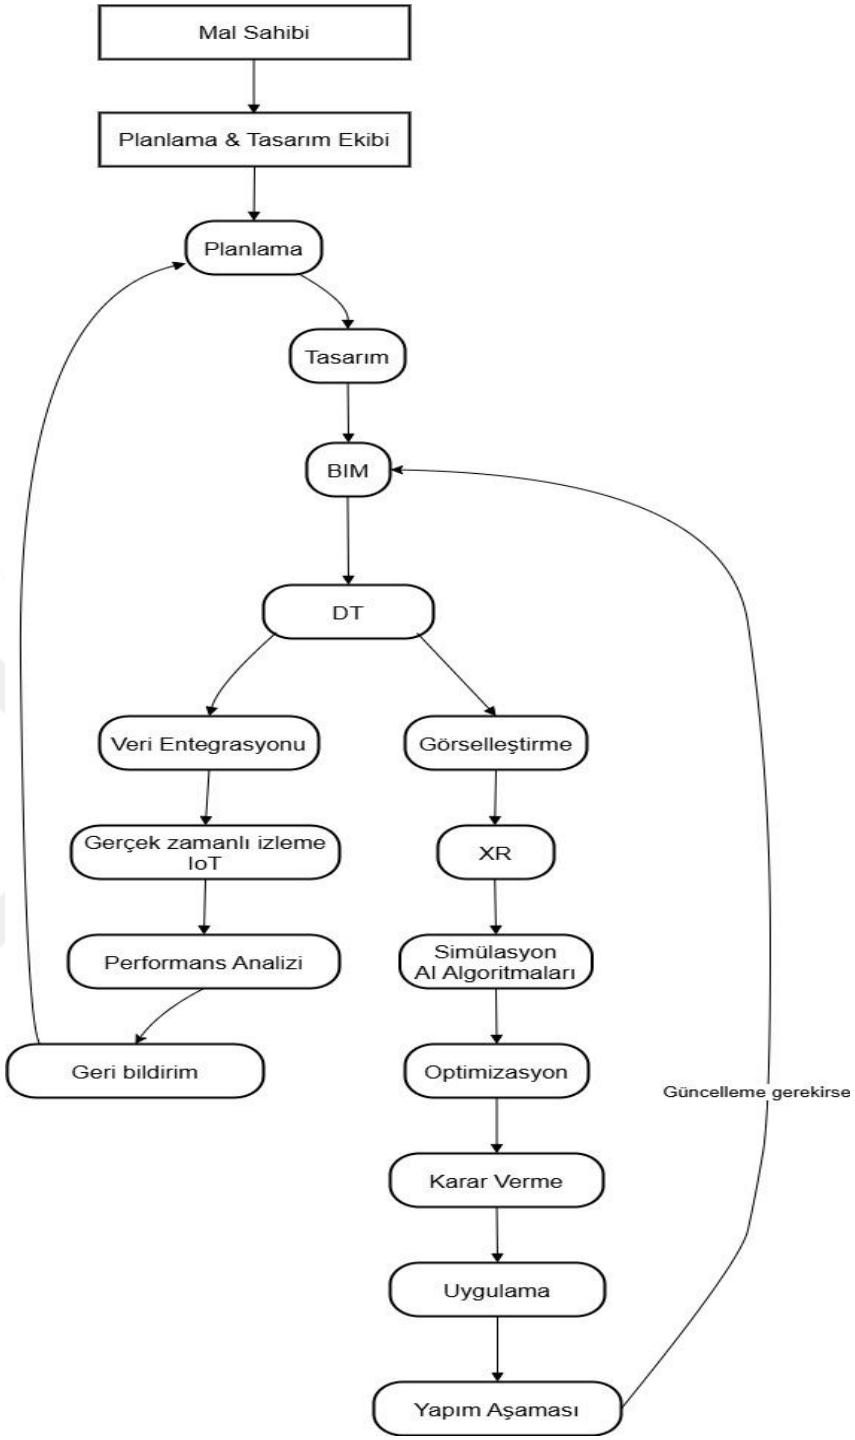

Şekil 4.3: Planlama ve tasarım aşamasında DT çerçevesi.

İnşaat projelerinin en kritik ve karmaşık aşaması olarak kabul edilen yapım aşamasında, sahadan gerçek zamanlı veri toplamak için DT teknolojisinin bileşenleri olarak IoT ve XR cihazları kullanılacaktır. Bu veriler, belirsizlikleri azaltmak için önceki bilgileri geliştirecek ve inşaat süreçlerini optimize edecek, inşaat işçilerinin kontrollü bir ortamda çeşitli senaryoları uygulamasına ve bunlara tepki vermesine olanak tanıyacak ve şantiyedeki kaza veya yaralanma

risklerini azaltacaktır. Ayrıca, sinir ağları, makine öğrenimi ve uzman sistemler dahil olmak üzere AI uygulamaları, gelecekteki senaryoları tahmin etmek için toplanan veriler üzerinde kullanılabilir, inşaat ekibine faaliyetleri ve üretkenliği iyileştirmede, kaliteyi, kaynakları, malzemeleri, programları, riskleri ve tedariki yönetmede, yapısal sistem bütünlüğünü değerlendirmede ve genel güvenliği sağlamak için işçi hareketleri ve faaliyetleri dahil olmak üzere sahayı izlemede yardımcı olabilecektir. İnşaat aşamasında DT kullanımı, proaktif karar vermeyi kolaylaştırarak ve riskleri azaltarak proje sonuçlarını önemli ölçüde iyileştirmektedir.

Şekil 4.4'te inşaat projelerinin yapım aşaması boyunca DT platformu için eksiksiz bir yapı tanımlanmaktadır. Hiyerarşik yapı, bu dönemde etkin proje yönetimi ve yürütme için hayati önem taşıyan çok sayıda unsur arasındaki ilişkileri göstermektedir. Sistem, çizimler, şartnameler ve diğer materyaller gibi planlama ve tasarım aşamasından gelen tüm belgeleri içeren bir önceki aşamanın çıktılarıyla başlamaktadır. Bu platform, BIM ve IoT cihazlarıyla sorunsuz entegrasyon için tasarlanmış olup gerçek zamanlı yükseltmelere ve veri senkronizasyonuna olanak sağlamaktadır. Platform, gerçek zamanlı veri toplama sağlayan IoT cihazlarını entegre edebilecektir. Bu veriler, saha koşulları ve malzeme lojistiği de dahil olmak üzere projenin çeşitli yönlerini denetlemek için gereklidir ve mevcut koşullara uygun olarak planlama ve tasarım belgelerinde gerekli revizyonları uygulamak için BIM araçlarıyla bağlantılıdır. Ayrıca, gerçek zamanlı veriler anlık izleme sağlayacaktır. Şekil 4.4'te saha izleme ve kalite izleme olmak üzere iki temel izleme işlevi gösterilmektedir. Bu işlevler, projenin belirlenen standartlara ve son teslim tarihlerine uymasını garanti edecektir. Ayrıca, elde edilen gerçek zamanlı veriler, proje süresi boyunca ve gelecekteki benzer girişimlerde kullanımı kolaylaştırmak için bulut depolama alanında arşivlenecektir.

IoT cihazlarından toplanan gerçek zamanlı verilerin BIM araçlarıyla birleştirilmesinin ardından, veriler tahmine dayalı analitikte kullanılmak üzere analiz edilecektir. Çerçevenin önemli bir unsuru AI ve makine öğrenimi metodolojilerinin entegrasyonudur. Bu teknolojiler simülasyon ve tahmine dayalı analiz sağlayarak proje sonuçlarını öngörme ve kaynak dağılımını optimize etme kapasitesini artırmaktadır. AI destekli simülasyon, inşaat ekibine performansı izleme, yapısal bütünlüğü değerlendirme ve riskleri yönetme konularında yardımcı olacaktır. Bu faktörler, projenin fizibilitesini ve finansal sınırlamalara uygunluğunu garanti etmek için gereklidir. Çerçeve ayrıca kaynak optimizasyonu ve maliyet yönetimini AI kullanımının faydaları olarak ele almakta ve projenin finansal ve zamansal kısıtlamalar dahilinde tamamlanmasını sağlamak için verimli zaman çizelgesi kontrolünün önemini

vurgulamaktadır. XR cihazlarının kullanımı, başarılı ve verimli proje yürütme ve paydaş katılımını kolaylaştıran sürükleyici deneyimler sunan görselleştirme ve sanal incelemelerdeki işlevleri nedeniyle vurgulanmaktadır. Çerçeve, RFID teknolojisinin, proje akışını ve ekip iş birliğini sürdürmek için kritik olan ekipman izleme ve malzeme lojistiği için gerekli olduğunu göstermektedir. Ayrıca, DT platformu etkin iletişim kanalları aracılığıyla paydaşlar arasında iş birliğini kolaylaştırmaktadır. Özetle bu şekil, inşaat aşaması boyunca verimliliği ve etkinliği artırmak için sofistike teknoloji, gerçek zamanlı veri izleme ve iş birliğine dayalı yöntemleri entegre ederek proje yönetimine kapsamlı bir yaklaşımı göstermektedir.

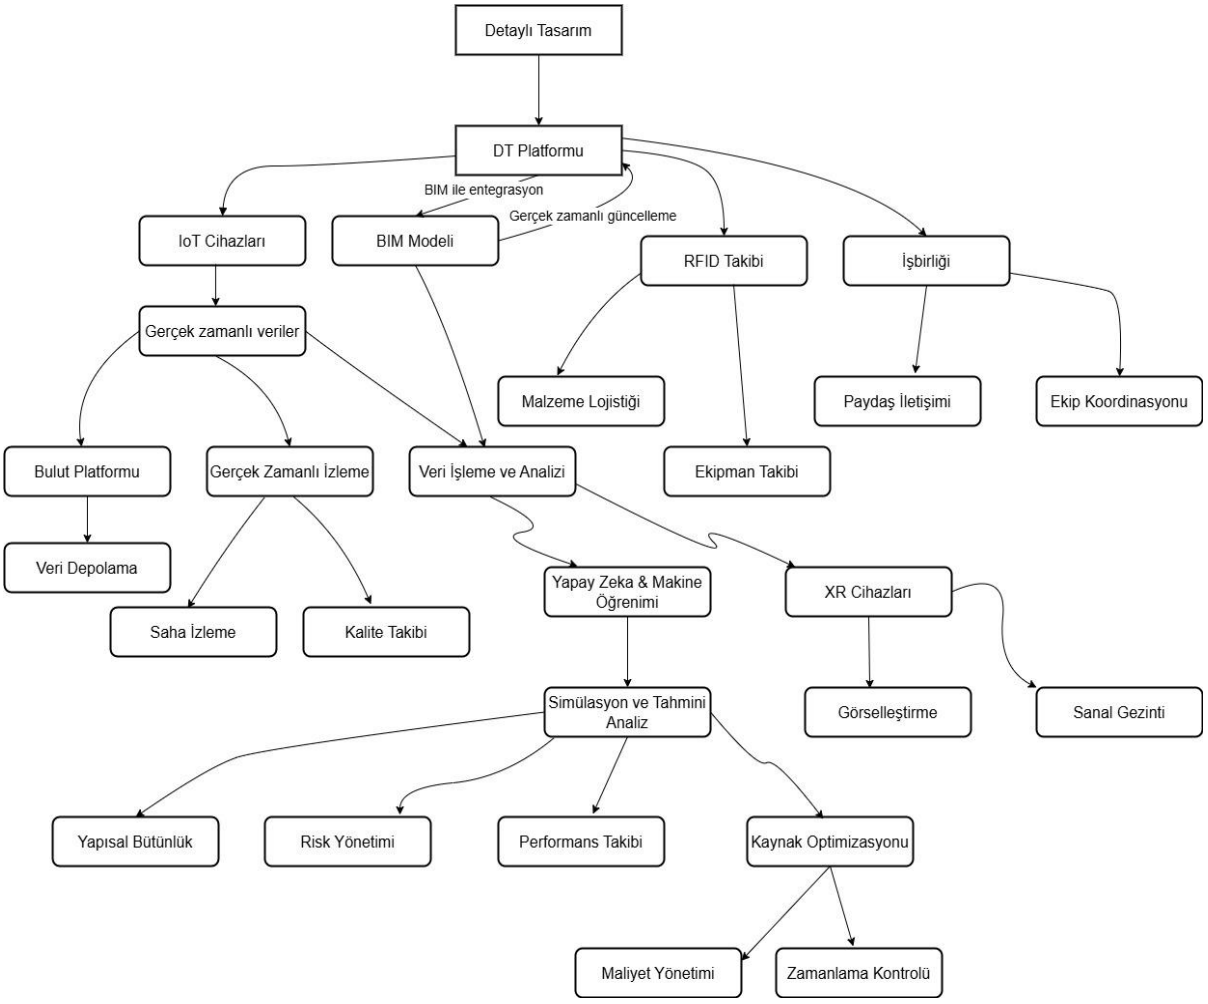

Şekil 4.4: Yapım aşamasında DT çerçevesi.

İşletme ve bakım aşaması genellikle inşaat ekibinin yetki alanı dışında görülmektedir, çünkü proje bu aşamada genellikle mal sahibine devredilmektedir. DT'nin kullanılması çok sayıda paydaş arasında daha iyi bir iletişim sağlayacaktır. Sensörler ve diğer IoT cihazları bina ve iç sistemlerinden sürekli olarak gerçek zamanlı veri toplayacaktır. Ayrıca, AI uygulamaları

bina varlıklarının yönetimini optimize etmek, enerji yönetimini ve verimliliğini artırmak, karar verme ve öngörücü bakım programlarını iyileştirmek ve bireylerin ve ekipmanların hareketlerini izleyerek emniyet ve güvenliği desteklemek için gelecek senaryoları tahmin edecek ve modelleyecektir.

Şekil 4.5, çeşitli veri kaynaklarının ve analitik tekniklerin bir araya getirilmesine odaklanarak, işletme ve bakım aşamasında DT için yapılandırılmış bir iş akışını göstermektedir. Süreç, diyagramın üst kısmında, BIM araçları tarafından kullanılan planlama ve tasarım aşaması ile yapım aşamasından elde edilen bir raporla başlamaktadır. Bu rapor, işletme ve bakım ekibinin üstleneceği müteakip faaliyetler için temel bir girdi görevi görecektir. Verilerin kapsamlı bir şekilde elde edilmesini ve özümsenmesini kolaylaştırmak için söz konusu ekip IoT cihazları, BIM ve XR cihazları gibi çeşitli kaynaklardan gelen verileri kullanacaktır.

İlk önemli aşama, IoT kaynaklarından ilgili verilerin toplanmasını gerektiren veri edinimidir. Veri entegrasyonu daha sonra bu verileri işler ve daha fazla analiz için farklı veri setlerini uyumlu hale getirmektedir. Entegrasyonun ardından veriler, bilgilerin analizini ve eyleme dönüştürülebilir kavramlara dönüştürülmesini içeren işleme sürecine tâbi tutulacaktır. Bu iş akışının kritik bir unsuru, bakım planlamasını iyileştirmek için AI kullanan tahmine dayalı analitiktir. Bu öngörü yeteneği, proaktif karar verme sürecini mümkün kılarak kaynak tahsisini ve bakım programlarını optimize edecektir.

Bakım uygulaması, performans izleme ve risk değerlendirmesini içeren varlık yönetim sistemi, işlenen verilerin nihai ürünüdür. Gerçek zamanlı veri analizi ve iş akışı otomasyonu bu işlevleri kolaylaştırarak operasyonları hızlandırır ve karar verme için zamanında kavramı sağlayacaktır. Genel olarak bu diyagram, varlık yönetiminin verimliliğini ve etkinliğini artırmak için sofistike teknolojileri ve analitiği bir araya getirmenin önemini vurgulayarak işletme ve bakıma yönelik veri odaklı bir yaklaşımı özetlemektedir.

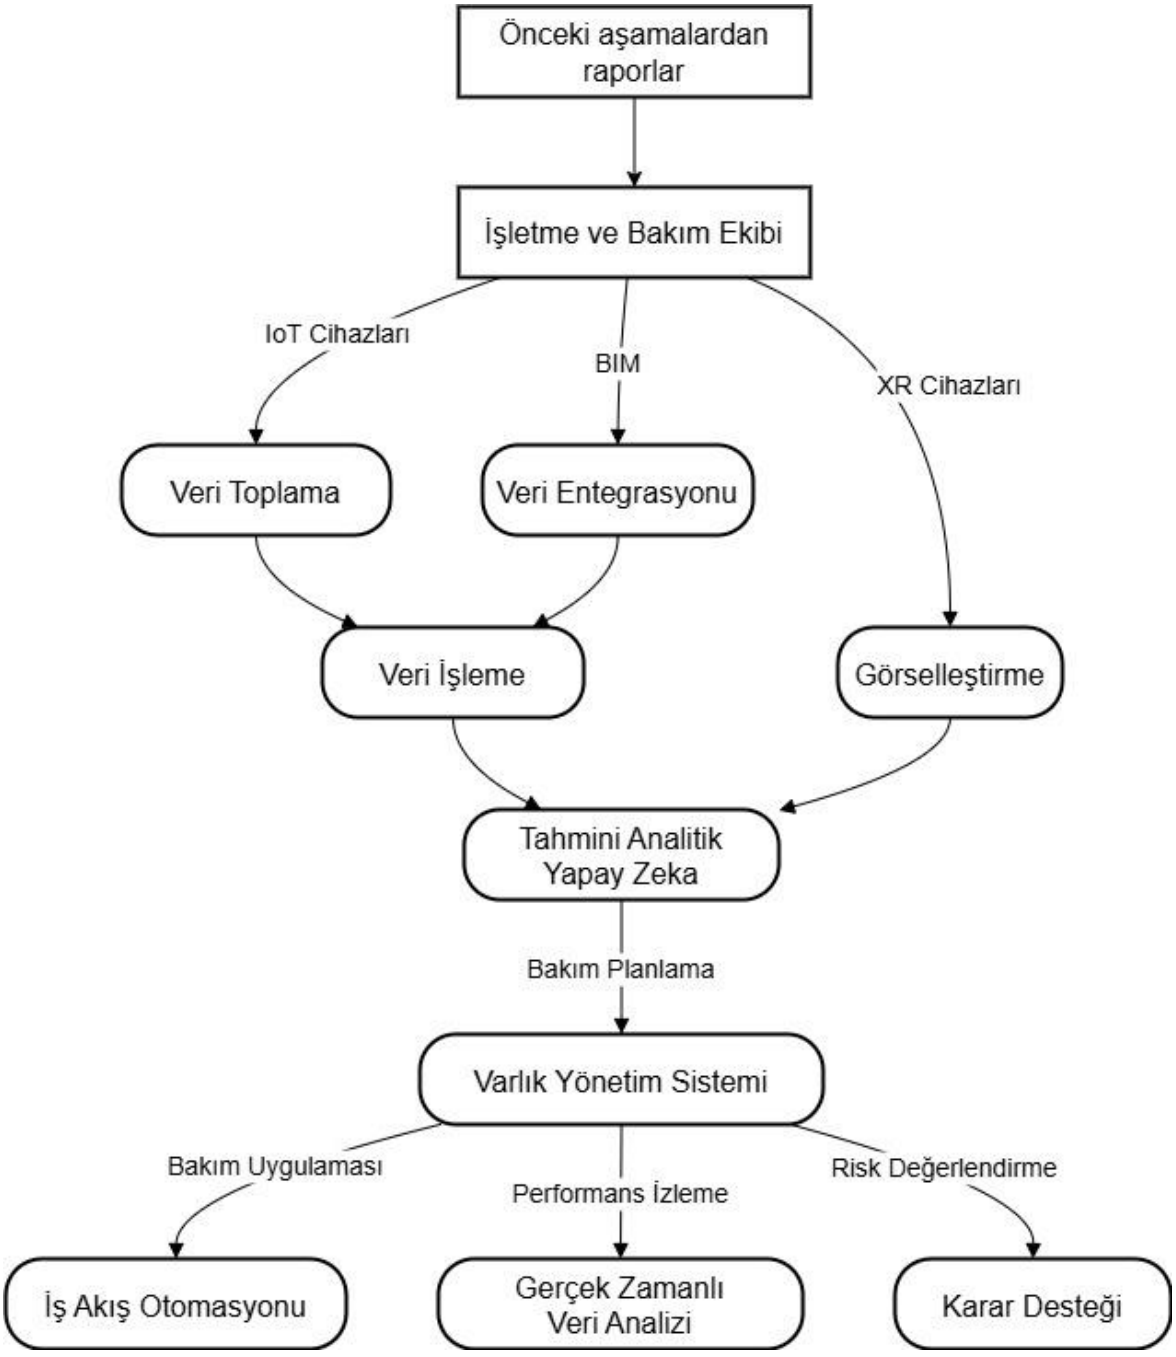

Şekil 4.5: İşletme ve bakım aşamasında DT çerçevesi.

Yıkım ve iyileştirme aşaması, herhangi bir binanın, yapının veya bileşenlerinin sökülmesini, yerle bir edilmesini, yıkılmasını veya enkaz haline getirilmesini içermektedir. Yıkım faaliyetleri bina ile ilgili çeşitli tehlikeler içermektedir. Yıkım, öngörülemeyen değişkenler nedeniyle daha fazla risk içerir ve bu da onu daha tehlikeli hale getirebilmektedir. Bu nedenle, bu aşamada DT'nin uygulanması, AI uygulamaları kullanılarak süreç tahmini yoluyla potansiyel tehlikelerin belirlenmesinde ve daha sonra bu tahminlere dayalı olarak uygun eylemlerin uygulanmasında önemli olacaktır. Ayrıca, DT teknolojisi ve AI uygulamaları

kullanılarak yıkım işlemlerinin modellenmesi, maliyetlerin ve malzeme miktarlarının tahmin edilmesini sağlayacaktır. Nihayetinde, DT teknolojisinin kullanımı, atıkların yıkım prosedürlerinin önemli bir sonucu olduğu düşünüldüğünde, atık bertaraf verimliliğini artıracaktır.

Şekil 4.6'da bina projelerinin yıkım aşamasında bir DT modelinde yer alan farklı unsurlar arasındaki bağlantıları tanımlayan bir akış şeması gösterilmektedir. DT modeli, çeşitli veri kaynaklarını ve faaliyetleri birleştiren ana çerçeve olarak işlev görmektedir. As-built bilgileri, doğru modelleme için çok önemli olan kesin inşaat verilerini sağlayacaktır. Bu veriler BIM araçlarından toplanacaktır. Bu bilgilerin elde edilmesinin ardından, çevresel etki değerlendirme prosedürü, analiz ve simülasyon aşamasına katkıda bulunarak bina operasyonlarının olası ekolojik yansımalarını inceleyecektir. Ayrıca, DT modeli GIS verilerini kullanarak mekânsal analiz ve coğrafi bağlamı entegre etmektedir. Kaynak yönetimi bileşeni, yıkım aşaması boyunca kaynakların etkin tahsisini ve kullanımını vurgulayacaktır. Çarpışma tespit mekanizması, yıkım planındaki herhangi bir çatışmayı tespit ederek güvenliği ve verimliliği sağlayacaktır.

Analiz ve simülasyon bileşeni, hem As-Built bilgileri hem de GIS verilerinden gelen enformasyonu entegre ederek, sonraki operasyonlara rehberlik etmek için çeşitli çalışmalar yapılmasını sağlayacaktır. Bu prosedür, yıkımı modellemek için AI algoritmalarını ve makine öğrenimi teknolojilerini kullanacak ve sonuçta etkili risk yönetimi, güvenlik analizi ve atık yönetimini kolaylaştıran verimli bir yıkım planı ortaya çıkacaktır. Yıkım planlaması, analiz ve simülasyon, kaynak yönetimi ve çarpışma tespit prosedürlerinin önemli bir sonucudur. Binaların güvenli ve verimli bir şekilde yıkılması için metodolojileri tanımlayacaktır. Risk değerlendirme sonucu, yıkım süreciyle bağlantılı olası tehlikeleri analiz ederek genel güvenliği ve operasyon fizibilitesini artıracaktır. Güvenlik analizi raporu, yıkım işlemleri sırasında çalışanların ve çevrenin korunması için tasarlanmış güvenlik prosedürlerini ve uygulamalarını değerlendirecektir. Atık yönetimi bileşeni, yıkım sırasında ortaya çıkan malzemelerin yönetimi ve bertarafı ile ilgilidir ve çevresel gerekliliklere uyulmasını sağlayacaktır. Akış şeması, bir DT modeli içindeki veri girdileri, analitik süreçler ve elde edilen çıktılar arasındaki karmaşık ilişkileri özlü bir şekilde göstermektedir. Yıkım aşaması boyunca karar verme sürecini iyileştirmek için çeşitli veri kaynaklarını ve analitik çerçeveleri bir araya getirme ihtiyacının altını çizmektedir.

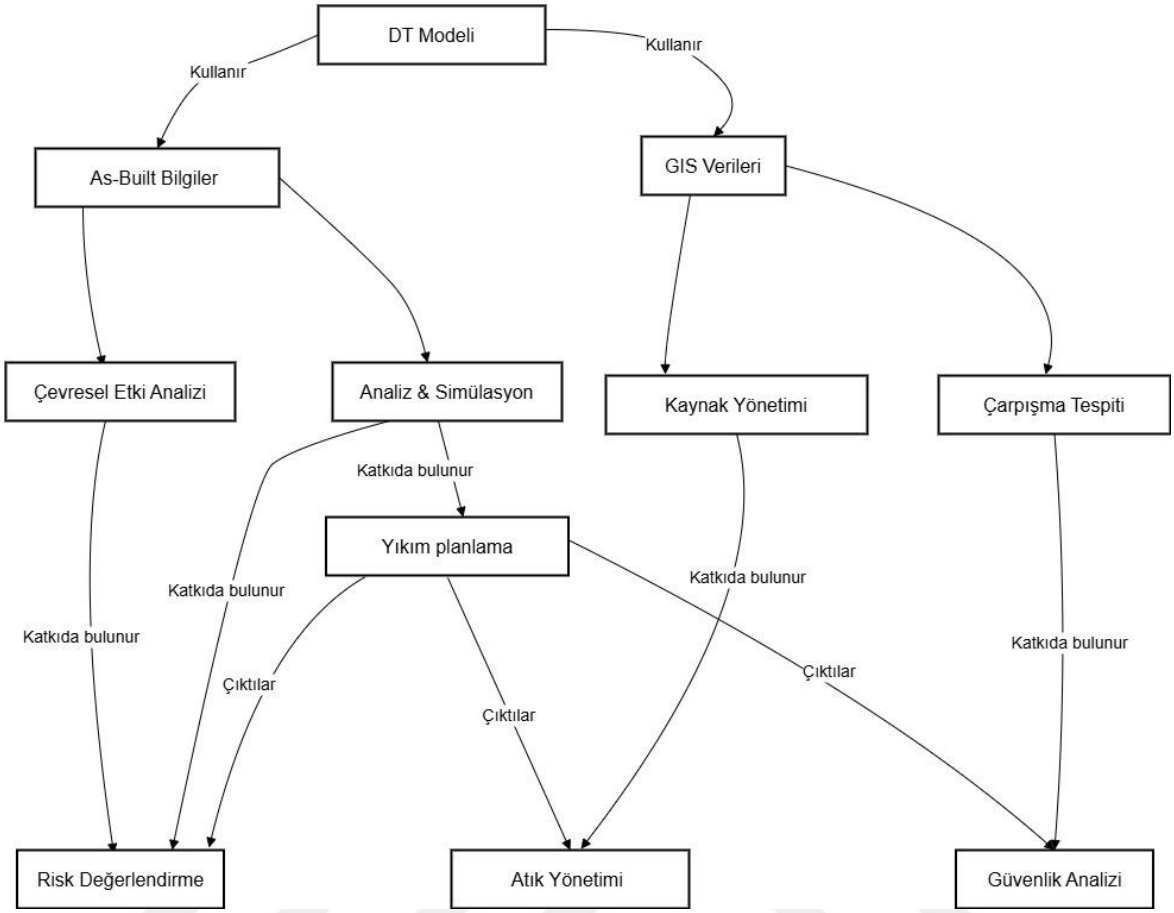

Şekil 4.6: Yıkım aşamasında DT çerçevesi.

Çağdaş inşaat projelerinin dünya çapında bir pazarda faaliyet göstermesi ve geniş proje ekiplerini içermesi, paydaş yönetimini projenin başarılı bir şekilde tamamlanması için kritik bir unsur haline getirmektedir ve bu da şirketin paydaşlarla etkin bir şekilde ilgilenmesine bağlıdır. Paydaşlar arasında iş birliği ve etkili iletişim, proje sonuçlarına ulaşmada çok önemli belirleyiciler olacaktır. Sonuç olarak, inşaat projelerinde paydaşları yönetmek için dijital araçların kullanılması iletişimi, iş birliğini ve genel proje verimliliğini önemli ölçüde arttırabilecektir. Tez çalışması, DT'nin proje ömrü boyunca çeşitli paydaşlar arasındaki iletişimi ve iş birliğini nasıl geliştirdiğini gösteren modellerde sunmaktadır.

Şekil 4.7, inşaat sektöründe bir DT platformunda yer alan çeşitli paydaşlar arasındaki bağlantıları göstermektedir. Her paydaş, projenin ömrü boyunca iletişim ve iş birliğini teşvik eden çeşitli teknolojik unsurlarla etkileşim halindedir. DT platformu, inşaat sürecinde yer alan birçok teknolojiyi ve paydaşı bir araya getiren merkezi bir işlev görmektedir. Ayrıca model, müşteriler, tasarımcılar, proje sponsorları, proje yöneticileri, müteahhitler, danışmanlar, tesis yöneticileri, işletme ve bakım ekipleri, tedarikçiler, yerel devlet kurumları, yıkım uzmanları ve

son kullanıcılar dahil olmak üzere çeşitli paydaşları tanımlamaktadır. Bileşenleri birbirine bağlayan çizgiler, taraflar arasındaki bilgi akışını ve iş birliğini göstermektedir.

Müşteri, BIM ve IoT cihazları aracılığıyla güncellemeler ve belgeler elde ederek proje hedefleri ve müşteri beklentileri arasında uyum sağlamak için esas olarak proje sponsoru, tasarımcılar ve proje yöneticisi ile etkileşim kurmaktadır. Tasarımcılar, farklı paydaşlarla iş birliğine ve teknolojinin dahil edilmesine öncelik vererek inşaat sürecinde çok önemlidir. Tasarımcılar, tasarım parametrelerinin proje hedefleri ve programlarıyla tutarlı olmasını sağlamak için proje yöneticisiyle yakın iş birliği içinde çalışacaktır. Ayrıca tasarımcılar, inşaat aşamasında proje yöneticisi ve yükleniciler tarafından kullanılan IoT cihazları tarafından sağlanan gerçek zamanlı verileri kullanarak herhangi bir çizimi veya belgeyi revize etme yeteneğine sahip olacaktır. Proje sponsoru, müşteri ve proje ekibi arasında bir aracı görevi görerek kaynakların uygun şekilde tahsis edilmesini garanti edecektir. Proje sponsoru, BIM araçlarına tam erişime sahip olacak ve bu da gelişmiş kaynak tahsisi ve proje optimizasyonu sağlayacaktır. Ayrıca, proje sponsoru IoT cihazlarından gelen gerçek zamanlı verileri kullanarak proje sağlığını izleyebilecek ve gerekli değişiklikleri uygulayabilecektir. AI simülasyonu ve XR cihazları, önleyici tedbirleri kolaylaştırmak için proje sponsoruna tahmine dayalı analiz ve görselleştirme konusunda yardımcı olacaktır.

Çeşitli teknolojilerin bir araya getirilmesi, proje yöneticisine projenin kapsamlı bir perspektifini sunarak paydaşlar arasındaki iş birliğini geliştirecektir. IoT cihazları, proje yöneticisine performans izleme için gerçek zamanlı veriler sağlarken, XR cihazları sanal incelemelere olanak tanıyarak güvenliği ve paydaşlar arasındaki iletişimi artıracaktır. Ayrıca, AI teknikleri, sorunların ortaya çıkmadan önce öngörülmesine olanak tanıyarak proaktif yönetimi mümkün kılmaktadır. Nihayetinde, proje yöneticisi malzeme ve ekipmanı izlemek için RFID etiketlerini kullanacak, bu da gelişmiş kaynak tahsisini kolaylaştıracak ve genel proje verimliliğini artıracaktır. Müteahhitler ve alt müteahhitler, proje belgelerine ve gerçek zamanlı verilere erişmek için BIM ve IoT cihazlarını kullanabilir, bu da yerinde karar vermeyi ve verimliliği artıracaktır. Ayrıca, müteahhitler ve alt müteahhitler performans izleme, kaynak tahsisi ve tahmine dayalı analiz için proje yöneticisi ile iş birliği yapmaktadır. Müteahhitler ve alt müteahhitler tarafından RFID etiketlerinin kullanılması, mal ve ekipmanların gözetimini iyileştirerek lojistiği optimize ederek ve gecikmeleri en aza indirecektir. Danışmanlar, proje sponsoru ve müşteriyle proje özellikleri, yasal belgeler ve güvenlik protokolleri hakkında

iletişim kurarak bilgi ve yönlendirme sağlamak için güncel BIM ve IoT proje belgelerini ve gereksinimlerini kullanacaktır.

Tesis yöneticisi, güvenlik takibi için gerçek zamanlı veri toplamak üzere IoT cihazlarını kullanacaktır. Ayrıca, XR görselleştirme araçları tesis yöneticisine kaynak yönetiminde yardımcı olarak geliştirme sonrasında binanın sorunsuz çalışmasını garanti etmesine yardımcı olacaktır. Tesis yöneticisi, gelişmiş varlık yönetimi ve öngörücü bakım için AI algoritmalarını kullanarak çalışacaktır. Operasyon ve bakım personeli, gerçek zamanlı veri toplama için IoT cihazları ve sanal denetimler için XR cihazları ile etkileşime girerek optimum performans ve sürdürülebilirlik sağlayacaktır. Ayrıca, AI teknolojileriyle yapılan tahmine dayalı analiz, bakım faaliyetlerinin planlanmasında, arıza süresinin en aza indirilmesinde ve varlık ömrünün uzatılmasında operasyon ve bakım ekibine yardımcı olacaktır. IoT cihazları, son kullanıcılara iç mekân çevre kalitesi (IEQ) açısından avantajlar sağlayabilir ve gelecekteki tasarımlar, proje tamamlandıktan sonra son kullanıcıların yorumlarını dahil ederek genel kaliteyi artırabilecektir.

Malzeme ve ekipman tedarikçileri, kaynak ve ekipman tedarikini izlemek için RFID etiketlerini kullanarak hızlı teslimatı kolaylaştıracak ve israfı en aza indirecektir. Gerçek zamanlı veri paylaşımı, tedarikçiler ve müteahhitlerin yanı sıra proje yöneticisi arasındaki iş birliğini geliştirerek etkili lojistik ve tedarik zinciri yönetimi sağlanmasına yardımcı olacaktır. RFID etiketleri, yıkım uzmanlarının yıkım süreci boyunca ekipman ve malzemeleri izlemelerine yardımcı olur, lojistik geliştirilecek ve masraflar en aza indirilebilecektir. Ayrıca, AI simülasyonu yıkım uzmanlarına yıkım operasyonlarının stratejisini oluşturmada yardımcı olur, güvenliği ve kurallara uyulmasını garanti edecektir. Ayrıca, yıkım uzmanları, yerel yönetim organlarıyla ortaklaşa yıkım faaliyetleri sırasında iletişim halinde olacak, normlar ve prosedürler konusundaki endişelerini dile getirecektir. Yerel yönetim organları, güvenlik standartlarına ve yerel düzenlemelere uygunluğu sağlamak amacıyla sanal denetimler için XR cihazlarını kullanmaktadır. Görselde gösterilen bağlantılar, inşaat projesindeki paydaşların karşılıklı bağımlılığını vurgulamaktadır. Teknoloji ve paydaş katılımı arasındaki etkileşim, etkili proje sonuçları için gereklidir ve mühendislik, yönetim ve bilgi teknolojisini entegre eden çok disiplinli yöntemlere olan ihtiyacı vurgulayan bir unsurdur. Dijital teknoloji, inşaat sürecindeki tüm katılımcılar arasında iş birliğini teşvik eder, verimliliği artırır ve karar vermeyi kolaylaştıracaktır. Gerçek zamanlı veriler, tahmine dayalı analitik ve sofistike görselleştirme araçları kullanılarak paydaşlar işlevlerini geliştirecek ve inşaat projelerinin genel başarısını kolaylaştırabilecektir.

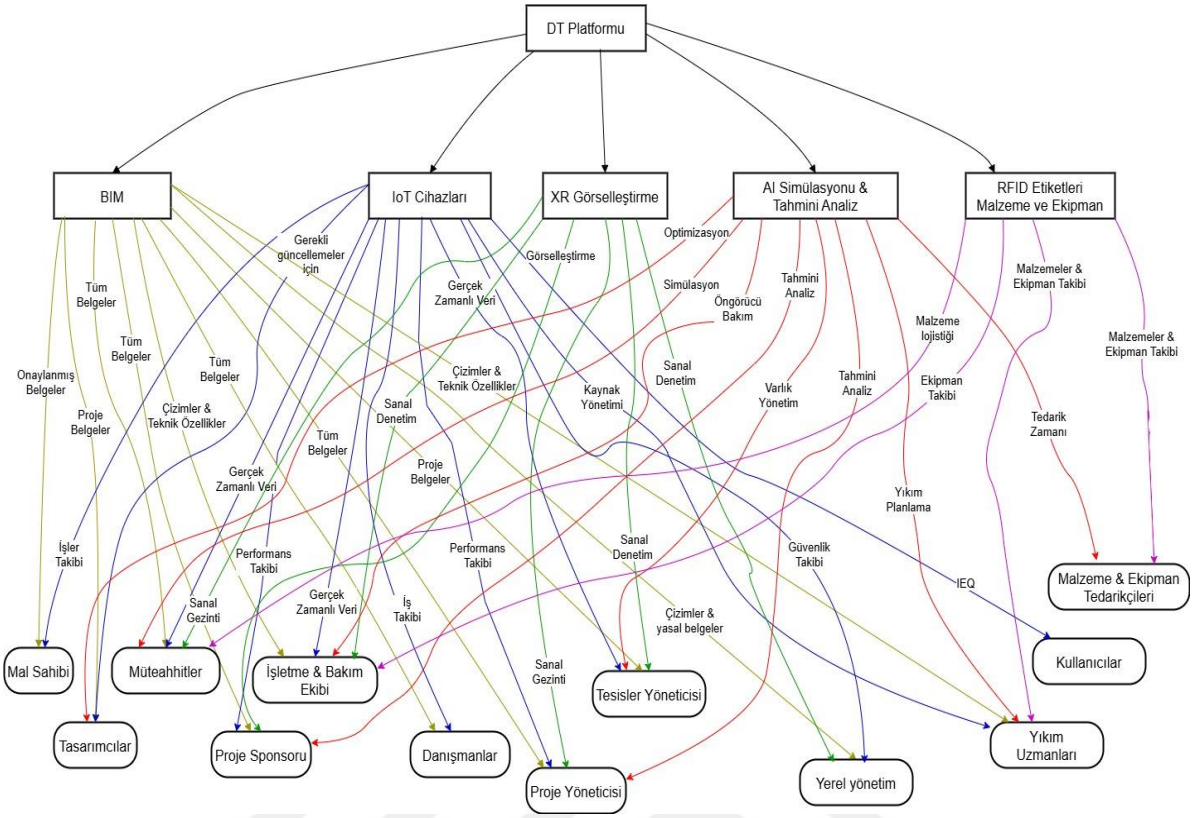

Şekil 4.7: Proje yaşam döngüsünde paydaşların DT platformu.

Şekil 4.8, bir projenin planlama ve tasarım aşaması boyunca DT modeline dahil olan birçok paydaş ve teknoloji unsuru arasındaki bağlantıları gösteren kavramsal bir çerçeveyi tasvir etmektedir. Bu aşamada BIM, izin belgeleri, çizimler, şartnameler ve performans değerlendirmeleri dahil olmak üzere proje dokümantasyonunun geliştirilmesi ve yönetilmesi için gereklidir. Projeyle ilgili tüm bilgiler için bir depo görevi görür ve paydaşların kesin ve güncel verilere erişimini garanti etmektedir. Müşteri, kriterlerin yerine getirildiğini ve proje çizimlerinin ve şartnamelerinin beklentileriyle uyumlu olduğunu teyit etmek için BIM araçlarını kullanabilecektir. Proje sponsoru, proje yöneticisi, müteahhitler, tesis yöneticisi, işletme ve bakım ekibi ve yıkım uzmanları, proje yaşam döngüsünün çeşitli aşamalarında gerekli tüm belgeleri almak için BIM teknolojilerini kullanabilecektir. Ayrıca, yerel yönetim organları BIM içindeki düzenleyici belgelere erişerek yerel yasa ve normlara uyulmasını sağlayabilecektir.

Planlama ve tasarım ekibi, planlama ve tasarım sürecinde önemli bir paydaş olarak kabul edilmektedir. BIM kapsamlı proje dokümantasyonu ve spesifikasyonları sağlamak için kullanılır ve tasarımların müşteri beklentilerine ve düzenleyici standartlara uygun olmasını sağlamaktadırlar. Ayrıca, gerçek zamanlı veri sağlayan IoT cihazlarıyla etkileşime geçerek

performans takibine yardımcı olur ve proje dokümantasyonunun hassasiyetini arttırabilecektir. Ekip, simülasyon ve optimizasyon için AI algoritmalarını kullanarak sonuçları tahmin etmelerini ve veri odaklı kavramlara dayalı tasarımları geliştirmelerini sağlayacaktır. Ayrıca, XR teknolojileri görselleştirme sağlayarak tasarımcıların proje tasarımlarıyla sürükleyici ortamlarda etkileşime girmesine olanak tanır ve böylece anlama ve geri bildirimi geliştirir.

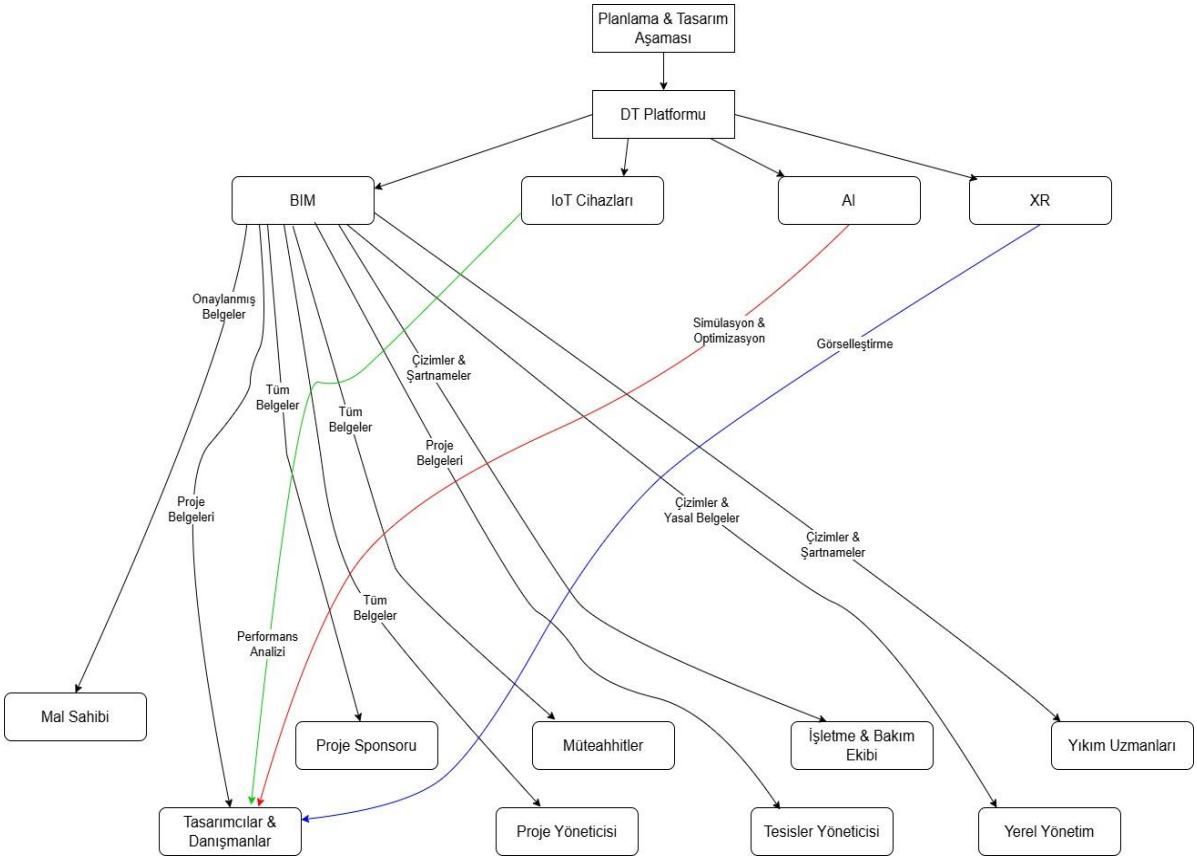

Şekil 4.8: Planlama ve tasarım aşamasında DT modeli aracılığıyla paydaşların ilişikleri.

Şekil 4.9, yapım aşaması boyunca bir DT platformu tarafından etkinleştirilen çok yönlü bir paydaş etkileşimi ağını tasvir etmektedir. BIM, IoT cihazları, AI, XR ve RFID etiketleri dahil olmak üzere çeşitli dijital teknolojiler, projedeki her temel paydaşın etkileşimini kolaylaştırmaktadır. Müşteri, iş raporları almak ve zamanında güncellemeler için iş akışlarını izlemek üzere BIM ve IoT cihazlarıyla etkileşim kuracaktır. Proje sponsoru, projenin finansal ve stratejik boyutlarını denetler. İş raporlarını incelemek için BIM platformunu kullanır ve gerçek zamanlı veri toplamak için IoT cihazlarıyla etkileşim kurabilir. Ayrıca, proje sponsoru, proje hakkında bilinçli karar vermeyi kolaylaştırmak için AI simülasyonları ve XR görselleştirmeleri ile etkileşime girebilir. Tasarımcılar, tasarımlarının doğru bir şekilde temsil edilmesini ve uygulanmasını sağlamak için BIM sistemiyle etkileşime geçerek çalışmaktadır.

Ayrıca, şantiyeden gelen gerçek zamanlı girdilere dayanarak işin ilerleyişi ve gerekli değişiklikler hakkında güncellemeler almak için proje yöneticisi ile iş birliği yapacaklardır. Ayrıca, danışmanlar DT platformunu iş raporları almak ve olası tehlikeleri fark etmek ve hafifletici çözümler sunmak için tahmine dayalı analiz yapmak için kullanacaklardır.

Proje yöneticisi ve müteahhitler, BIM ve IoT cihazlarını kullanarak performansı denetlemek ve güvenliği garanti etmek için DT platformunu kullanmaktadır. Ayrıca, olası tehlikeleri öngörmek ve süreçleri iyileştirmek için öngörücü analiz ve simülasyonlar için AI araçlarının yanı sıra adım adım görselleştirme için XR teknolojisini kullanabileceklerdir. RFID etiketleri, malzeme ve ekipman tedarikçilerini projeye bağlayarak söz konusu kaynakların izlenmesini kolaylaştırmaktadır. Müteahhitlerle olan bağlantıları, inşaat için gerekli malzemelerin hızlı teslimatını ve erişilebilirliğini garanti edecektir. Tesisler yöneticisi ile işletme ve bakım ekibi, işletme ve bakım aşaması boyunca kendilerine yardımcı olacak operasyonel verileri ve diğer belgeleri almak için BIM teknolojilerini kullanabileceklerdir. Ayrıca, yıkım uzmanları, yıkım prosedürlerinin tasarımı ve yürütülmesi sırasında bina yapısını anlamalarını kolaylaştıran operasyonel raporlar oluşturmak için BIM teknolojilerini kullanacaktır. Ayrıca, yerel yönetim yetkilileri mevzuata uygunluk ve denetime katılmaktadır. Şantiyede güvenliği garanti altına almak için IoT cihazlarından gelen gerçek zamanlı verilerle etkileşim kuruyor ve tüm inşaat operasyonlarında yerel mevzuata uygunluğu doğrulamak için çalışma raporlarını inceleyebileceklerdir.

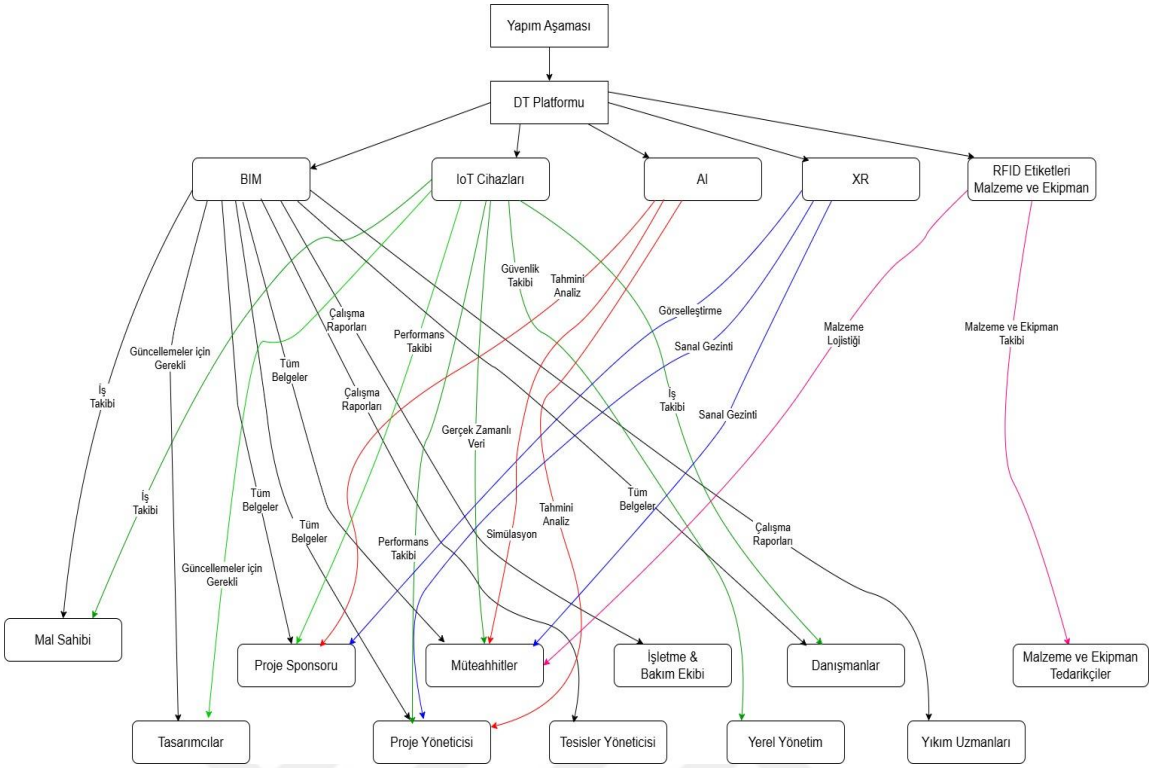

Şekil 4.9: Yapım aşamasında DT Modeli dahilinde paydaşlar etkileşimleri.

Şekil 4.10, bir DT platformunun işletme ve bakım aşaması boyunca gelişmiş bir paydaş etkileşimi sistemini göstermektedir. Müşteri, binanın performansını ve dahili sistemlerini izlemek amacıyla gerçek zamanlı veri elde etmek için IoT cihazlarını kullanabilecektir. Ayrıca müşteri, tüm operasyonların iyi ilerlediğini teyit etmek için tesis yöneticisi ile iletişime geçebilecektir. Tesisler yöneticisi, müşteri ile işletme ve bakım personeli arasında bir aracı görevi görmektedir. Tesisler yöneticisi, performans izleme için IoT cihazlarıyla etkileşim sağlayacaktır. Ayrıca, olası sorunları belirlemek ve bakım planlamasını kolaylaştırmak için sanal denetimler için XR teknolojisi ile tahmine dayalı analiz ve simülasyonlar için AI algoritmalarını kullanarak gerçekleştirecektir. Tesis operasyonlarının günlük yönetimi büyük ölçüde operasyon ve bakım ekibine dayanmaktadır. Tesisin ve sistemlerinin güvenliğini ve performansını değerlendirmek için IoT cihazlarından gelen gerçek zamanlı verileri kullanacaklardır. Ayrıca, karar verme sürecini geliştirmek ve verimliliği artırmak amacıyla tahmine dayalı analiz ve sanal denetimler için AI algoritmaları ve XR teknolojisini kullanacaklardır.

Malzeme ve ekipman tedarikçileri, RFID etiketlerinin kullanımı yoluyla malzeme ve ekipmanların hızlı teslimatını ve izlenmesini garanti etmek için işletme ve bakım ekipleriyle iş birliği yapmaktadır. Ek olarak, yerel yönetim, faaliyetlerin yasal ve güvenlik normlarına

uymasını sağlayarak düzenleyici bir işlevi yerine getirecektir. Güvenlik izleme ve operasyonel uyumluluk hakkında bilgi almak için BIM ve IoT cihazlarıyla etkileşim sağlayacaktır. Ayrıca, yıkım uzmanları, yapı içindeki sistemler ve ekipmanlar hakkında kapsamlı bilgiler içeren raporlar almak için BIM aracılığıyla platformu kullanır, böylece yıkım aşamasında bu tür ekipmanların kaldırılmasına yardımcı olacaktır. Ayrıca, son kullanıcılar IEQ'yu izlemek için bina içindeki IoT cihazlarını kullanacaklardır. Hatta sürekli iyileştirme için girdi sağlamak üzere işletme ve bakım ekibiyle etkileşim sağlayacaklardır.

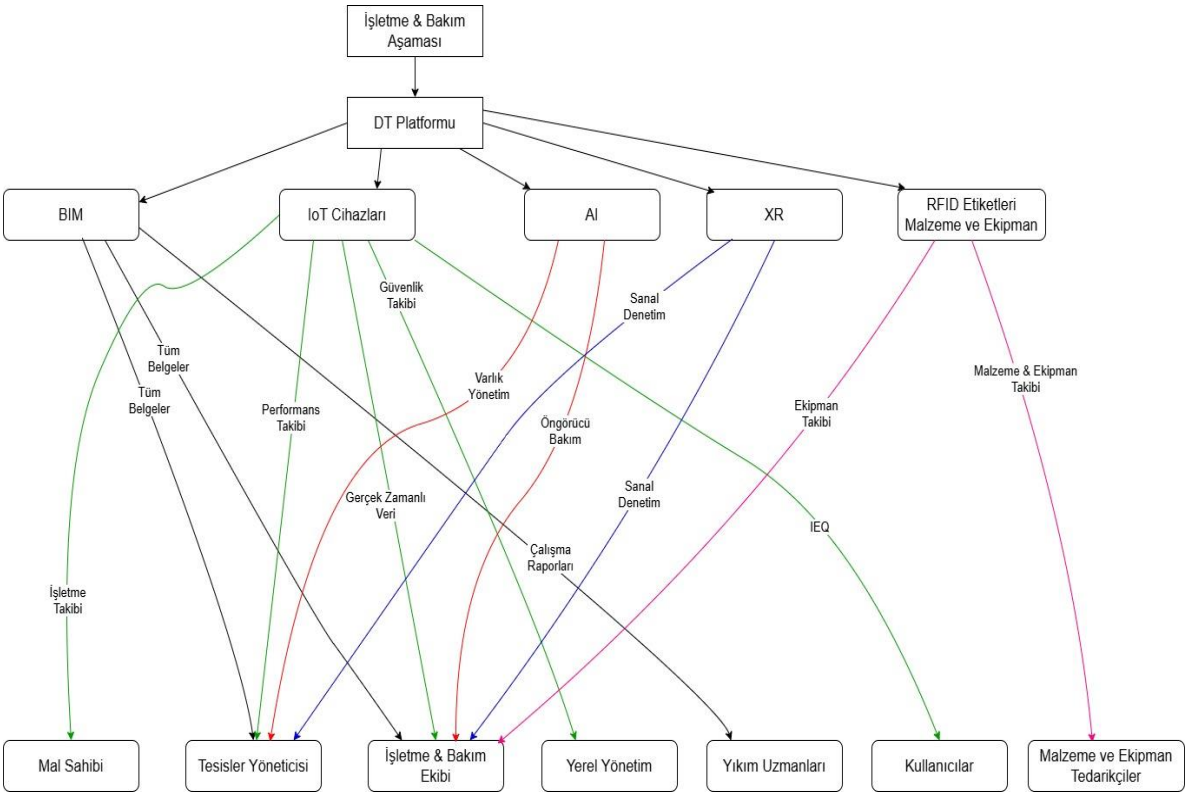

Şekil 4.10: İşletme ve bakım aşamasında DT Modeli dahilinde paydaşlar etkileşimleri.

Şekil 4.11'de bir DT platformunun yıkım aşaması boyunca paydaş etkileşimlerini göstermekte ve çeşitli teknolojilerin entegrasyonunu vurgulamaktadır. Müşteri, tüm yasal standartlara uygunluğu doğrulamak için BIM teknolojilerini kullanmaya başlayacaktır. Yıkım prosedürlerinin programlara ve bütçelere uygunluğunu garanti etmek amacıyla gerçek zamanlı izleme için IoT cihazlarıyla etkileşim kurmaktadır. Ayrıca, yıkım uzmanları, yıkım işlemleri sırasında performans izleme ve güvenlik güvencesi için gerçek zamanlı veri elde etmek üzere IoT cihazlarını kullanarak gerçekleştireceklerdir. DT ile yıkım operasyonlarının stratejik planlamasına yardımcı olmak için AI teknolojileri kullanılarak yıkım uzmanlarının sorunları öngörmesini ve verimliliği artırmasını sağlanacaktır. Bu aşama, yıkım faaliyetleri sırasında

tehlikelerin azaltılması ve güvenliğin garanti altına alınması için çok önemlidir. Ayrıca, yıkımda kullanılan ekipmanın konumunu ve durumunu izlemek için RFID etiketleri kullanılacaktır. Yıkım uzmanları ile malzeme ve ekipman tedarikçileri, ekipman kaybını önlemek ve kullanılabilirliğini sağlamak için bu bilgileri paylaşmaktadır. Ayrıca, yerel devlet kurumları, yıkımla ilgili tüm yasal belgelerin sunulmasını ve izlenmesini zorunlu kılmak için BIM ile iş birliği yapmaktadır. Kurallara ve güvenlik gerekliliklerine uyulmasını sağlamak amacıyla yürütmenin izlenmesi için IoT cihazlarını kullanmaktadırlar.

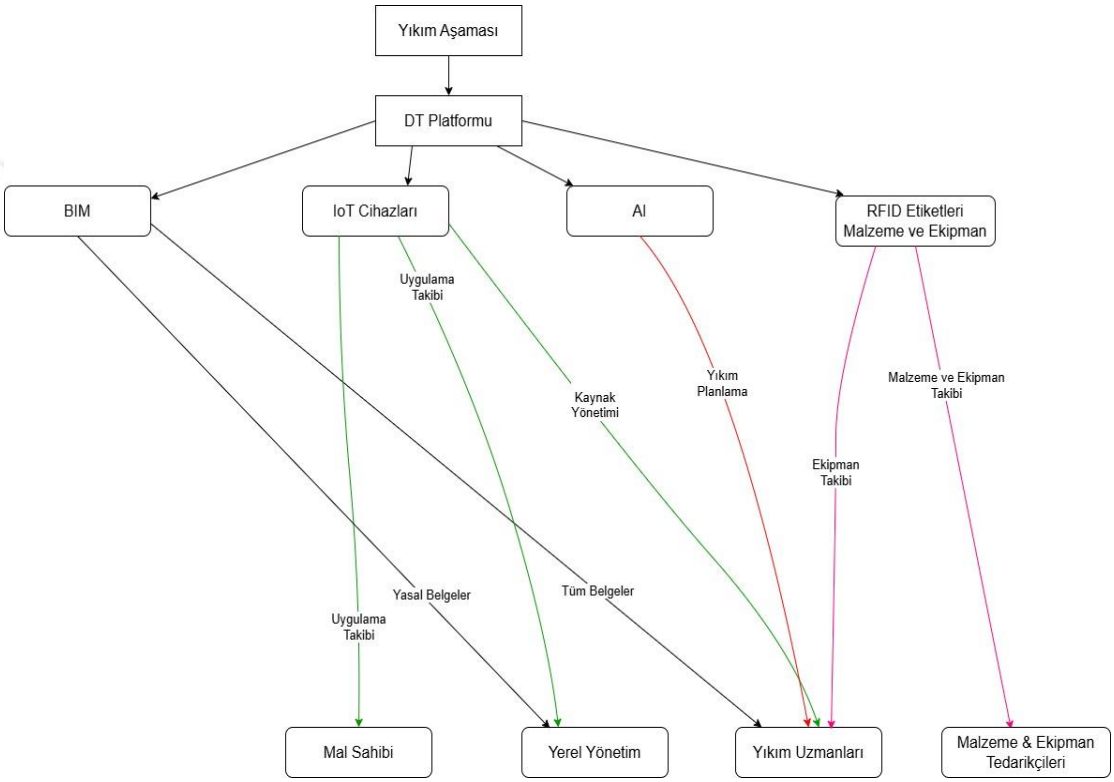

Şekil 4.11: Yıkım aşamasında DT Modeli dahilinde paydaş etkileşimleri.

4.1.2. Model Doğrulaması

Oluşturulan modelleri doğrulamak için konusunda uzman kişilere bir anket dağıtılmıştır. Anket üç ana bölüme ayrılmıştır. Ankette kullanılan ölçek ve ölçüm araçlarının tutarlılığını belirlemek için SPSS yazılımı kullanılarak güvenilirlik testi uygulanmıştır. Bu testin sonuçları, Cronbach's Alpha değerinin 0.954'e eşit olduğunu göstermiştir, bu da kullanılan ölçüm araçlarının tamamen güvenilir olduğu anlamına gelmektedir. Ankette ilk bölüm, eğer varsa, katılımcıların endüstri ve akademideki rollerine odaklanmıştır. Sektörde, katılımcıların %60'ı mühendis, %40'ı ise mimardır. Akademide ise katılımcıların %30'u öğretim görevlisi ve %70'i araştırmacıdır.

İkinci bölüm, projenin yaşam döngüsünün farklı aşamaları arasındaki DT platformu modellerine odaklanırken, ikinci bölüm DT platformu içindeki paydaş etkileşimlerine odaklanmıştır. İlk bölümde, her bir modelin açıklığını, doğruluğunu, kullanılabilirliğini ve değerini değerlendirmek için dört ana soru sorulmuştur. Katılımcıların çoğunluğu, planlama ve tasarım aşamasındaki DT modelinin kolay ve net anlaşılır, doğru ve temsili olduğunu ve bu aşamada DT'nin daha iyi anlaşılmasını kolaylaştırdığını kabul etmiştir. Ayrıca, katılımcıların %73,4'ü modelde kullanılan tekniklerin sıralamasının optimum kullanımla tutarlı olduğunu kabul ederken, diğerleri buna tarafsız kalmışlardır. Yapım aşamasında, katılımcıların çoğunluğu modelin kolay ve net anlaşılır, doğru ve temsili olduğu ve bu aşamada DT'nin daha iyi anlaşılmasını kolaylaştırdığı konusunda hemfikirdir. Ayrıca, katılımcıların yarısı modelde kullanılan tekniklerin sıralamasının optimum kullanımla tutarlı olduğu konusunda hemfikirken, diğerleri bu konuda tarafsız belirtmişlerdir. İşletme ve bakım aşamasında, katılımcıların çoğunluğu bu aşamadaki modelin kolay ve net anlaşılır, doğru ve temsili olduğu ve DT'nin daha iyi anlaşılmasını kolaylaştırdığı konusunda hemfikirdir. Ayrıca, katılımcıların %73,3'i modelde kullanılan tekniklerin sıralamasının işletme ve bakım aşamasındaki en uygun kullanımla tutarlı olduğunu kabul ederken, diğerleri buna karar vermemiştir. Son olarak, yıkım aşamasında, katılımcıların çoğunluğu modelin kolay ve net anlaşılır, doğru ve temsili olduğu ve bu aşamada DT'nin daha iyi anlaşılmasını kolaylaştırdığı konusunda hemfikirdir. Ayrıca, katılımcıların %53,4'ü modelde kullanılan tekniklerin sıralamasının işletme ve bakım aşamasındaki optimum kullanımla tutarlı olduğunu kabul ederken, diğerleri kabul edip etmediklerine karar verememiştir.

Anketin, projenin yaşam döngüsünün her bir aşamasının DT modeli içindeki paydaş etkileşimlerine odaklanan üçüncü bölümü, açıklık, doğruluk ve kullanılabilirliği değerlendirmek için üç ana soru barındırmaktadır. Katılımcıların çoğunluğu, planlama ve tasarım aşamasındaki paydaş etkileşimleri modelinin açık ve kolay anlaşılır, doğru ve temsili olduğu ve paydaşların planlama ve tasarım aşamasında DT ile nasıl etkileşime girdiklerinin ve DT'den nasıl faydalandıklarının anlaşılmasını kolaylaştırdığı konusunda hemfikirdir. İnşaat aşamasında, katılımcıların çoğunluğu paydaş etkileşimleri modelinin açık ve kolay anlaşılır, doğru ve temsili olduğu ve bu aşamada paydaşların DT ile nasıl etkileşime girdiğinin ve DT'den nasıl faydalandığının anlaşılmasını kolaylaştırdığı konusunda hemfikirdir. İşletme ve bakım aşamasında, katılımcıların çoğunluğu paydaş etkileşimleri modelinin açık ve kolay anlaşılır, doğru ve temsili olduğu ve bu aşamada paydaşların DT ile nasıl etkileşime girdiğinin ve DT'den

nasıl faydalandığının anlaşılmasını kolaylaştırdığı konusunda hemfikir olmuştur. Son olarak, katılımcıların çoğunluğu yıkım aşamasındaki paydaş etkileşimleri modelinin açık ve kolay anlaşılır, doğru ve temsili olduğu ve bu aşamada paydaşların DT ile nasıl etkileşime girdiğinin ve DT'den nasıl faydalandığının anlaşılmasını kolaylaştırdığı konusunda anlaşmıştır.

4.2. KİRİŞ ÜZERİNDEN UYGULAMA

Oluşturulan DT modeli deney için üretilen betonarme bir kiriş için uygulanmıştır. Betonarme kiriş için oluşturulan model operasyonel aşamada tasarlanmıştır. Söz konusu aşama, IoT cihazlarının kullanıldığı deneylerden elde edilen gerçek sonuçlarla karşılaştırıldığında, uygulanan yüklere ve sıcaklık ve nem gibi çevresel faktörlere maruz kalan betonarme kirişteki gerilme sonuçlarını tahmin etmede araştırma yöntemlerinin etkinliğini değerlendirmektedir. Veri kümesi eğitim için yüzde yetmiş ve test için yüzde otuz olarak ayrılmıştır.

Başlangıç olarak, betonarme kiriş için bir DT modeli geliştirilmiştir. Şekil 4.12, betonarme kirişin işletme ve bakım aşaması sırasında DT modelini göstermektedir. Modelin ilk aşaması, BIM uygulaması yoluyla kirişin tasarlanmasını gerektirmektedir. Tasarım aşamasının ardından, bir sonraki prosedür laboratuvarda kiriş dökümünü gerçekleştirmiştir. Kirişin fiziksel imalatı, BIM modelinde detaylandırılan spesifikasyonlara göre belirlenmiştir. Kirişler döküldükten sonra, IoT sensörleri yapıya dahil edilmiştir. Bu sensörler sıcaklık, nem ve yapısal stres gibi parametreleri izlemek için gereklidir. Bu sensörler tarafından toplanan gerçek zamanlı veriler, inşaat boyunca ve sonrasında kirişlerin performansı hakkında önemli bilgiler sunmaktadır. Bir bulut platformu, toplanan verileri depolayarak hem erişilebilirliği hem de güvenliği sağlamaktadır. IoT sensörlerinden toplanan veriler daha sonra BIM'den gelen bilgilerle entegre edilerek daha fazla analiz için derlenmektedir. Bu aşama, ilgili tüm bilgilerin sistematik olarak toplanması ve böylece kirişin performansının kapsamlı bir şekilde anlaşılması için gereklidir. Toplanan veriler, önemli kavramlar elde etmek ve analize hazırlamak için işleme tabi tutulmuştur. AI uygulamaları, işlenmiş veriler üzerinde tahmine dayalı analiz yapmak için kullanılmış ve sonuçların ve eğilimlerin tahmin edilmesini sağlamıştır. Bu aşamada, olası sorunları tahmin etmek ve performansı artırmak için makine öğrenimi algoritmaları kullanılmıştır. Tahmine dayalı analiz, geçmiş ve gerçek zamanlı verilerden elde edilen eyleme geçirilebilir kavramlar sunarak karar verme sürecini geliştirmiştir. Gerçek zamanlı veri analizi, verilerin toplanması sırasında sürekli olarak incelenmesini kolaylaştırarak hızlı kavramlar

sağlayacaktır. İş akışı otomasyonu, manuel müdahaleyi en aza indirerek ve otomasyon yoluyla operasyonel verimliliği artırarak süreçleri geliştirmeyi amaçlamaktadır.

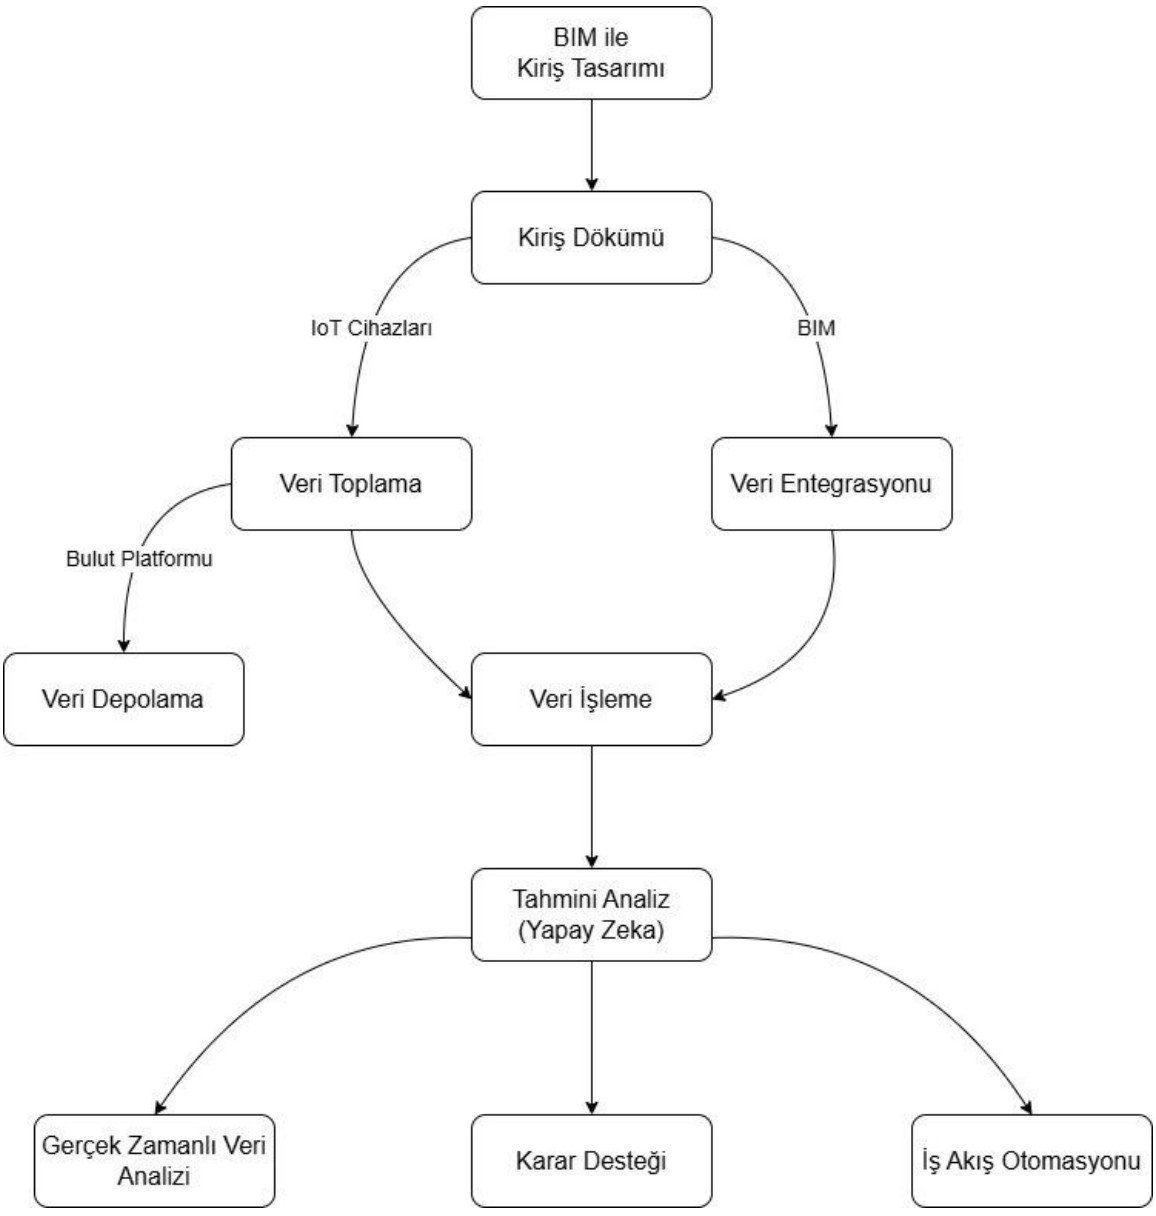

Şekil 4.12: Kiriş üzerinden işletme aşamasında DT modeli.

Betonarme kiriş üzerine uygulanan yük, deneyin ilk altı haftası boyunca kademeli olarak artırılmıştır. Analiz iki farklı aşamaya ayrılmıştır. İlk aşama, deneyin ilk altı haftasını kapsamakta olup, bu süre boyunca uygulanan yük kademeli olarak artırılmış ve basamaklı aşama olarak adlandırılmıştır. İkinci aşama, uygulanan yükün sabit kaldığı deneyin yedinci haftasından sonuna kadar olan süreyi kapsamaktadır. Bu aşama basamaksız aşama olarak adlandırılmıştır.

4.2.1. Basamaklı Aşama

Bu aşama altı haftadan oluşmaktadır. Uygulanan yük her haftanın başında artırılmıştır. Analiz her hafta için ayrı ayrı yapılmış ve daha sonra tüm döneme uygulanmıştır.

4.2.1.1. İstatistiksel Modeller

Veri kümeleri üzerinde regresyon algoritmalarını eğitme ve test için MATLAB kullanılmıştır. Doğrusal regresyonlar, ağaçlar, SVM, GPR, çekirdek modeli, ağaç toplulukları ve sinir ağı modelleri dahil olmak üzere 34 regresyon modeli kullanılmıştır.

Şekil 4.13, ilk hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağılımını göstermektedir.

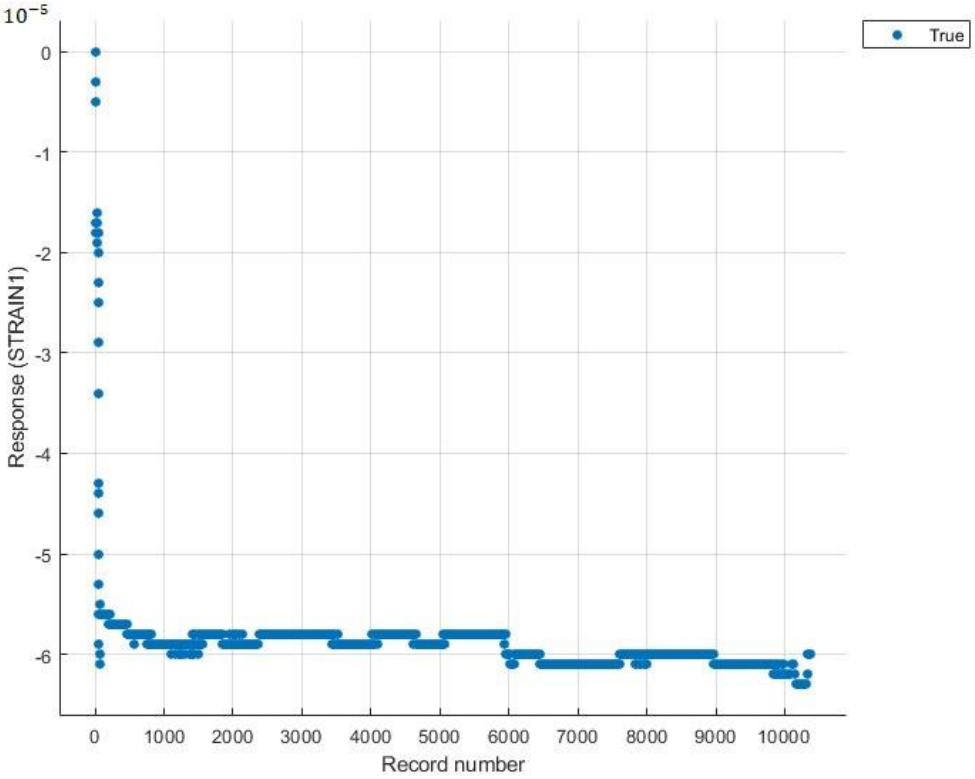

Şekil 4.13: Basamaklı aşamasında ilk haftanın gerilme dağıtımı.

Tablo 4.1, ilk hafta boyunca regresyon modelinin eğitim ve test sonuçlarını sunmaktadır. Modellerin sonuçlarını değerlendirmek için kullanılan RMSE ve belirleme katsayısıdır (R^2). Her iki faktör de eğitim ve test prosedürlerinde kullanılmaktadır. Sonuçlar, üstel GPR modelinin $6{,}03 \times 10^{-5}$ RMSE ve 1 R^2 ile eğitim dönemi boyunca en etkili model olduğunu göstermiştir. Ayrıca, eğitim sonuçları verimli doğrusal SVM hariç tüm modellerin

R^{2}'sinin pozitif olduğunu göstermiştir. Öte yandan, üstel GPR'nin test sonuçları 0,002 RMSE ve 0,649 R^2 ile daha üstün bir değere işaret etmiştir. Bununla birlikte, ince ağaç ve optimize ağaç modelleri, her ikisi için de 0.02237691 RMSE ve 0.996514 R^2 ile en iyi test değerlerini göstermiştir. Son olarak, kullanılan tüm modellerin test sonuçları, optimize SVM ve verimli doğrusal SVM dışında R^2 değerinin pozitif olduğunu göstermiştir.

Tablo 4.1: Basamaklı aşamasında ilk haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.297151	0.22842	0.34133796	0.188914
Doğrusal Etkileşimler	0.286907	0.280703	0.33018375	0.241057
Sağlam Doğrusal	0.300629	0.210252	0.34589444	0.167115
Kademeli Doğrusal	0.286933	0.280572	0.33026671	0.240675
İnce Ağaç	0.024326	0.994829	0.02237691	0.996514
Orta Ağaç	0.049307	0.978756	0.04936486	0.983036
Kaba Ağaç	0.187172	0.693868	0.20644494	0.703308
Optimize Ağaç	0.024326	0.994829	0.02237691	0.996514
Doğrusal SVM	0.300571	0.210556	0.34579751	0.167582
Karesel SVM	0.294677	0.241215	0.33964172	0.196955
Kübik SVM	0.291248	0.258772	0.33577699	0.215126
İnce Gauss SVM	0.264522	0.388564	0.31090561	0.327093
Orta Gauss SVM	0.288804	0.271157	0.33395185	0.223636
Kaba Gauss SVM	0.29732	0.227539	0.34263826	0.182723
Optimize SVM	0.308175	0.170107	0.38052687	-0.00802
Verimli Doğrusal En Küçük Kareler	0.305465	0.184639	0.34830457	0.155468
Verimli Doğrusal SVM	0.33869	-0.00238	0.3799815	-0.00513
Optimize Verimli Doğrusal	0.305463	0.184647	0.34830266	0.155477
Rasyonel Karesel GPR	0.023281	0.995264	0.04602892	0.985251

Tablo 4.1 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Kare Üstel GPR	0.025824	0.994172	0.04689417	0.984691
Matern 5/2 GPR	0.010027	0.999121	0.04380401	0.986642
Üstel GPR	6.03E-05	1	0.0613513	0.973797
SVM Çekirdeği	0.281712	0.306513	0.32854991	0.248549
En Küçük Kareler Çekirdeği	0.215605	0.593794	0.24107698	0.595415
Optimize Çekirdek	0.220444	0.575356	0.24437833	0.584259
Güçlendirilmiş Ağaçlar	0.25627	0.426117	0.25411313	0.550477
Torbalı Ağaçlar	0.037538	0.987687	0.04267452	0.987322
Optimize Topluluk	0.174395	0.734237	0.19373378	0.738719
Dar Sinir Ağı	0.116395	0.881616	0.14127624	0.861057
Orta Sinir Ağı	0.071261	0.955625	0.06538449	0.970239
Geniş Sinir Ağı	0.047531	0.980258	0.0471527	0.984522
Çift Katmanlı Sinir Ağı	0.07329	0.953063	0.06705404	0.9687
Üç Katmanlı Sinir Ağı	0.066889	0.960903	0.06710802	0.968649
Optimize Sinir Ağı	0.316969	0.122067	0.35754304	0.110073

Şekil 4.14, ikinci hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

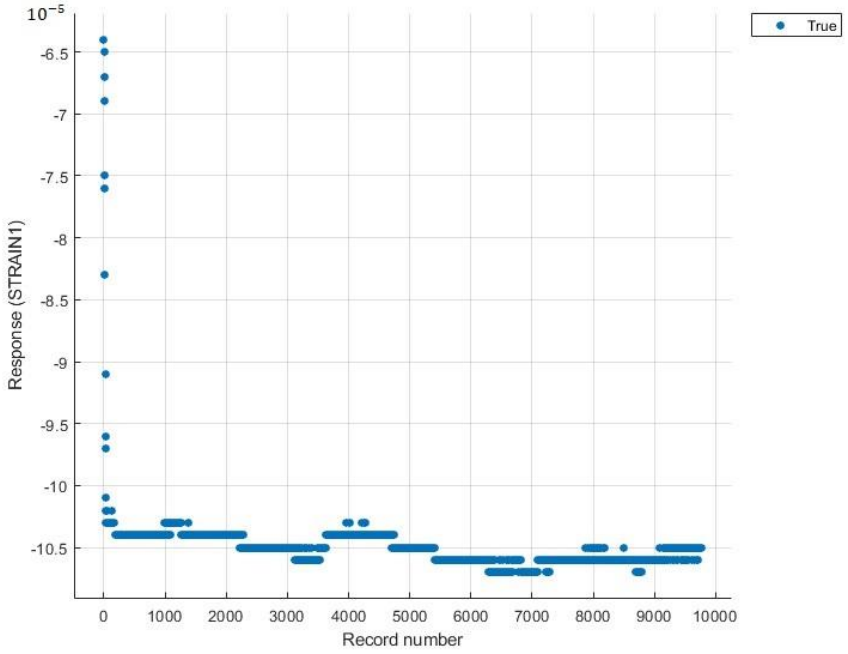

Şekil 4.14: Basamaklı aşamasında ikinci haftanın gerilme dağıtımı.

Regresyon modelinin ilk hafta için eğitim ve test sonuçları Tablo 4.2'de özetlenmiştir. Üstel GPR modeli, $6{,}03 \times 10^{-5}$'lük RMSE ve 0,99999986'luk R^2 değeri ile kanıtlandığı üzere eğitim dönemi boyunca en etkili model olmuştur. Ayrıca, eğitim sonuçları verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize topluluk hariç tüm modellerin pozitif bir R^2 değerine sahip olduğunu göstermiştir. Diğer taraftan, üstel GPR modeli, 0,03016875 RMSE ve 0,973637 R^2 değeri ile test döneminde olağanüstü bir sonuç göstermiş ve böylece en etkili model olarak belirlenmiştir. Sonuç olarak, kullanılan tüm modellerin test sonuçları, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize topluluk dışında R^2 değerinin pozitif olduğunu göstermiştir.

Tablo 4.2: Basamaklı aşamasında ikinci haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.15012	0.295257	0.15775168	0.279182
Doğrusal Etkileşimler	0.143023	0.36031	0.15115434	0.338212
Sağlam Doğrusal	0.157729	0.222002	0.16541923	0.207408
Kademeli Doğrusal	0.143039	0.360173	0.15118236	0.337966
İnce Ağaç	0.023952	0.98206	0.04049561	0.9525

Tablo 4.2 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Ağaç	0.043306	0.941353	0.06543915	0.875962
Kaba Ağaç	0.108762	0.63008	0.11965501	0.585295
Optimize Ağaç	0.023952	0.98206	0.04049561	0.9525
Doğrusal SVM	0.152817	0.269703	0.16072743	0.251731
Karesel SVM	0.14161	0.372887	0.15002027	0.348105
Kübik SVM	0.137341	0.41013	0.1454925	0.386861
İnce Gauss SVM	0.09023	0.745402	0.09496269	0.738794
Orta Gauss SVM	0.136831	0.4145	0.14527127	0.388724
Kaba Gauss SVM	0.144838	0.343978	0.15342545	0.318175
Optimize SVM	0.004414	0.999391	0.06689034	0.8704
Verimli Doğrusal En Küçük Kareler	0.177127	0.018875	0.18369012	0.022651
Verimli Doğrusal SVM	0.179297	-0.00531	0.18650755	-0.00756
Optimize Verimli Doğrusal	0.177127	0.018875	0.18369012	0.022651
Rasyonel Karesel GPR	0.02084423	0.98641289	0.03111087	0.971965
Kare Üstel GPR	0.02085878	0.98639392	0.03105943	0.972058
Matern 5/2 GPR	0.01915405	0.98852701	0.03046108	0.973124
Üstel GPR	6.75E-05	0.99999986	0.03016875	0.973637
SVM Çekirdeği	0.12967447	0.47414689	0.13743154	0.45292
En Küçük Kareler Çekirdeği	0.07188104	0.83842125	0.0739157	0.841747
Optimize Çekirdek	0.0691673	0.85039121	0.07193224	0.850126
Güçlendirilmiş Ağaçlar	0.44752084	-5.262994	0.44907331	-4.84134
Torbalı Ağaçlar	0.04314593	0.94178498	0.0701175	0.857593
Optimize Topluluk	0.23826895	-0.7753762	0.24092913	-0.68134
Dar Sinir Ağı	0.05111579	0.91829182	0.05721447	0.905182

Tablo 4.2 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Sinir Ağı	0.10110372	0.68033895	0.10021445	0.709103
Geniş Sinir Ağı	0.03050103	0.97090728	0.0391009	0.955716
Çift Katmanlı Sinir Ağı	0.04232918	0.94396813	0.04939031	0.929342
Üç Katmanlı Sinir Ağı	0.04422363	0.93884047	0.05040634	0.926405
Optimize Sinir Ağı	0.15011967	0.2952572	0.15775168	0.279182

Şekil 4.15, üçüncü hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

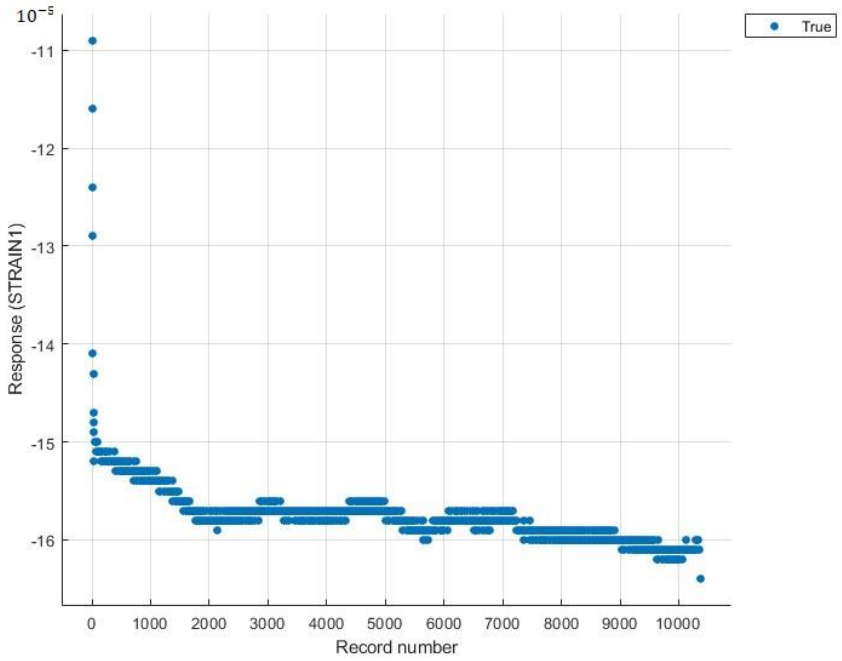

Şekil 4.15: Basamaklı aşamasında üçüncü haftanın gerilme dağıtımı.

Tablo 4.3, üçüncü hafta için regresyon modelinin eğitim ve test sonuçlarının bir özetini sunmaktadır. Üstel GPR modeli, 0,0182698 RMSE ve 0,9953672 R^2 değeri ile eğitim dönemi boyunca üstün performans göstermiştir. Eğitim sonuçları, verimli doğrusal SVM hariç her modelin pozitif bir R^2 değeri sergilediğini ortaya koymuştur. Üstel GPR modeli test aşamasında 0.0439858 RMSE ve 0.980211 R^2 değerine ulaşarak dikkate değer bir performans sergilemiştir.

Bununla birlikte, rasyonel karesel GPR 0,04075894 RMSE ve 0,983008 R^2 ile test verilerinin en iyi değerini temsil etmiştir. Son olarak, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı modelleri haricinde, kullanılan tüm modellerin test sonuçları pozitif bir R^2 değeri göstermiştir.

Tablo 4.3: Basamaklı aşamasında üçüncü haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.131661	0.759406	0.18496361	0.650077
Doğrusal Etkileşimler	0.122669	0.791147	0.16985782	0.704899
Sağlam Doğrusal	0.13327	0.75349	0.18899906	0.634641
Kademeli Doğrusal	0.122673	0.791132	0.16983393	0.704982
İnce Ağaç	0.052015	0.962449	0.09411411	0.909404
Orta Ağaç	0.073261	0.925507	0.08820425	0.920425
Kaba Ağaç	0.100759	0.859091	0.14244487	0.792464
Optimize Ağaç	0.050129	0.965122	0.09564066	0.906441
Doğrusal SVM	0.133688	0.751941	0.18933038	0.633359
Karesel SVM	0.114692	0.817425	0.16112705	0.734456
Kübik SVM	0.098482	0.865387	0.13684192	0.808469
İnce Gauss SVM	0.105861	0.844458	0.15701464	0.747838
Orta Gauss SVM	0.103982	0.849931	0.14954686	0.771253
Kaba Gauss SVM	0.122034	0.793303	0.17480555	0.687456
Optimize SVM	0.134338	0.749521	0.19084157	0.627483
Verimli Doğrusal En Küçük Kareler	0.239946	0.200905	0.28813592	0.15083
Verimli Doğrusal SVM	0.269095	-0.00504	0.31426195	-0.01014
Optimize Verimli Doğrusal	0.239932	0.2009957	0.28812097	0.150918
Rasyonel Karesel GPR	0.0381721	0.9797761	0.04075894	0.983008
Kare Üstel GPR	0.0396014	0.9782333	0.0426448	0.981399

Tablo 4.3 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Matern 5/2 GPR	0.0382647	0.9796778	0.04198662	0.981969
Üstel GPR	0.0182698	0.9953672	0.0439858	0.980211
SVM Çekirdeği	0.0811168	0.9086741	0.1119456	0.871822
En Küçük Kareler Çekirdeği	0.0558086	0.956771	0.06896392	0.951354
Optimize Çekirdek	0.0568095	0.9552065	0.07012486	0.949703
Güçlendirilmiş Ağaçlar	0.6705713	-5.2411218	0.67540081	-3.66577
Torbalı Ağaçlar	0.0543007	0.9590755	0.08744991	0.92178
Optimize Topluluk	0.2559393	0.0908265	0.30177818	0.068515
Dar Sinir Ağı	0.0957288	0.8728085	0.11731076	0.859241
Orta Sinir Ağı	0.0463302	0.9702079	0.04556788	0.978762
Geniş Sinir Ağı	0.0416079	0.9759716	0.04696239	0.977442
Çift Katmanlı Sinir Ağı	0.0733204	0.9253856	0.07948605	0.935378
Üç Katmanlı Sinir Ağı	0.0514327	0.9632844	0.0693094	0.950866
Optimize Sinir Ağı	0.2684192	5.58E-14	0.31292695	-0.00158

Şekil 4.16, dördüncü hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

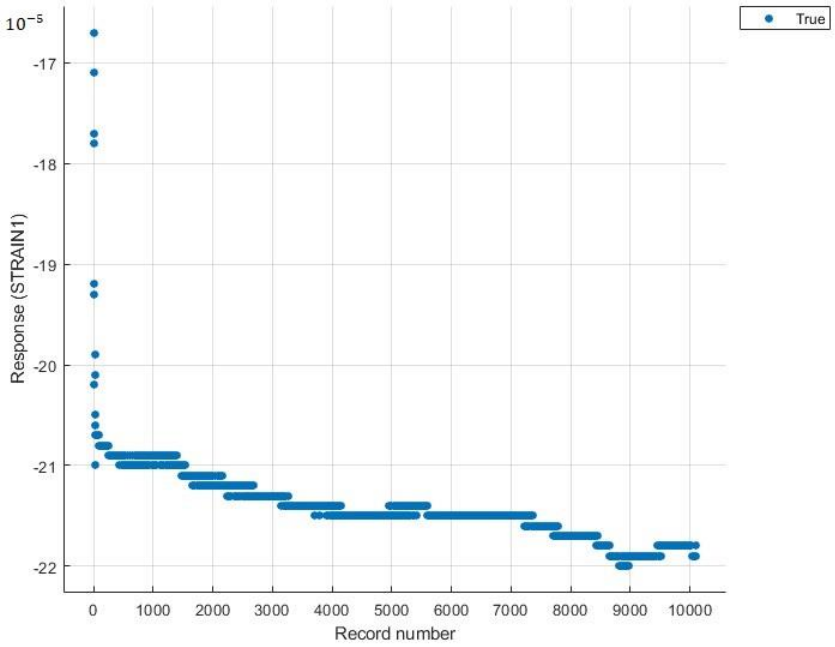

Şekil 4.16: Basamaklı aşamasında dördüncü haftanın gerilme dağıtımı.

Tablo 4.4, dördüncü hafta için regresyon modelinin eğitim ve test sonuçlarının kısa bir özetini sunmaktadır. Üstel GPR modeli, 0,000229'lük RMSE ve 0,999999'luk R^2 değeri ile kanıtlandığı üzere eğitim dönemi boyunca olağanüstü bir performans sergilemiştir. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç tüm modellerin pozitif bir R^2 değeri gösterdiğini ortaya koymuştur. Üstel GPR modeli test aşamasında 0.03365439 RMSE ve 0.989855 R^2 değerine ulaşarak olağanüstü bir performans göstermiştir. Bununla birlikte, Matern 5/2 GPR, 0,03186833 RMSE ve 0,990904 R^2 değeri elde ederek test verileri açısından en iyi performansı göstermiştir. Son olarak, kullanılan tüm modellerin test sonuçları, optimize SVM, verimli doğrusal SVM ve güçlendirilmiş ağaçlar modelleri hariç, pozitif bir R^2 değeri göstermiştir.

Tablo 4.4: Basamaklı aşamasında dördüncü haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.12646	0.847025	0.1555539	0.783273
Doğrusal Etkileşimler	0.110759	0.882652	0.13713487	0.831559
Sağlam Doğrusal	0.129563	0.839424	0.15916267	0.773101
Kademeli Doğrusal	0.111724	0.880599	0.13780329	0.829913

Tablo 4.4 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
İnce Ağaç	0.029721	0.99155	0.04626277	0.98083
Orta Ağaç	0.068504	0.955109	0.08633768	0.933235
Kaba Ağaç	0.095497	0.912763	0.11962359	0.87183
Optimize Ağaç	0.02821	0.992387	0.0474142	0.979864
Doğrusal SVM	0.129312	0.840045	0.15891759	0.773799
Karesel SVM	0.113046	0.877755	0.14209705	0.819149
Kübik SVM	0.10343	0.897668	0.13371822	0.839848
İnce Gauss SVM	0.08627	0.928807	0.10953208	0.892543
Orta Gauss SVM	0.10465	0.89524	0.13371266	0.839861
Kaba Gauss SVM	0.140217	0.81193	0.16586833	0.753579
Optimize SVM	0.150339	0.783798	0.33427911	-0.00085
Verimli Doğrusal En Küçük Kareler	0.322564	0.004711	0.332302	0.010953
Verimli Doğrusal SVM	0.325338	-0.01248	0.33543993	-0.00781
Optimize Verimli Doğrusal	0.322564	0.004709	0.33230246	0.01095
Rasyonel Karesel GPR	0.02799	0.992506	0.03896704	0.9864
Kare Üstel GPR	0.026753	0.993154	0.03726602	0.987561
Matern 5/2 GPR	0.023011	0.994935	0.03186833	0.990904
Üstel GPR	0.000229	0.999999	0.03365439	0.989855
SVM Çekirdeği	0.100026	0.904293	0.12906229	0.850807
En Küçük Kareler Çekirdeği	0.082714	0.934555	0.09659212	0.916433
Optimize Çekirdek	0.079933	0.938881	0.09475437	0.919583
Güçlendirilmiş Ağaçlar	0.91083	-6.93584	0.91380116	-6.47919
Torbalı Ağaçlar	0.054784	0.971291	0.07230411	0.953175
Optimize Topluluk	0.24032	0.447543	0.26046333	0.392363

Tablo 4.4 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Dar Sinir Ağı	0.081916	0.935812	0.08885772	0.92928
Orta Sinir Ağı	0.082739	0.934515	0.09192027	0.924321
Geniş Sinir Ağı	0.055228	0.970823	0.06679597	0.960038
Çift Katmanlı Sinir Ağı	0.068609	0.954972	0.09190011	0.924355
Üç Katmanlı Sinir Ağı	0.073782	0.947926	0.09628034	0.916972
Optimize Sinir Ağı	0.126953	0.845829	0.15613936	0.781639

Şekil 4.17, beşinci hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

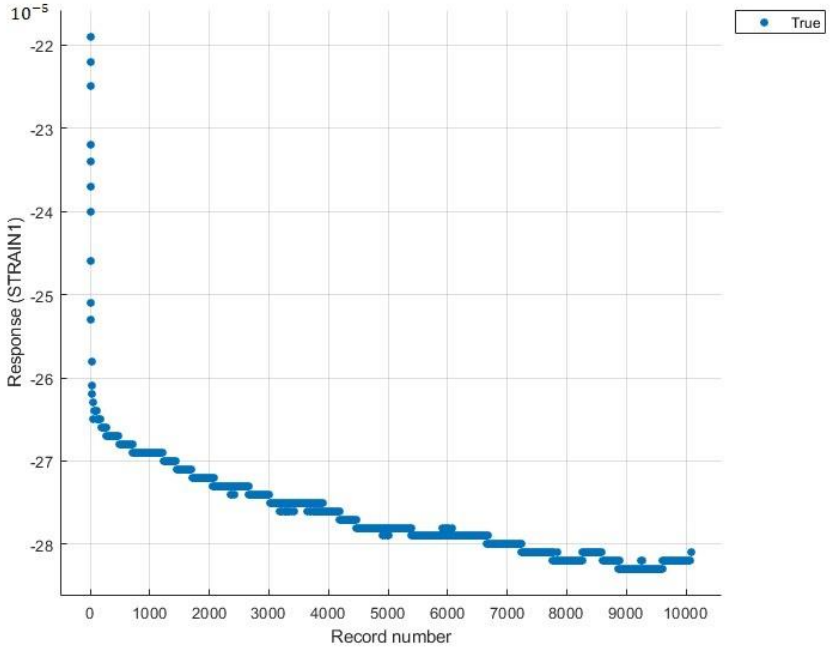

Şekil 4.17: Basamaklı aşamasında beşinci haftanın gerilme dağıtımı.

Tablo 4.5, beşinci hafta için regresyon modelinin eğitim ve test sonuçlarına genel bir bakış sunmaktadır. Üstel GPR modeli, 0,000317 RMSE ve 1 R^2 değeri ile gösterildiği üzere eğitim aşamasında üstün performans göstermiştir. Eğitim sonuçları, verimli doğrusal SVM hariç tüm modellerin pozitif bir R^2 değeri sergilediğini göstermiştir. Üstel GPR modeli, test

aşamasında 0,02308344 RMSE ve 0,998063 R^2 değerine ulaşarak güçlü bir performans sergilemiştir. Bununla birlikte, Matern 5/2 GPR, 0,02137857'lik bir RMSE ve 0,998339'luk bir R^2 değerine ulaşarak test verilerine ilişkin üstün performans sergilemiştir. Optimize SVM, verimli doğrusal SVM ve güçlendirilmiş ağaçlar modelleri haricinde, kullanılan tüm modeller için test sonuçları pozitif bir R^2 değeri göstermiştir.

Tablo 4.5: Basamaklı aşamasında beşinci haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.180411	0.877775	0.17921694	0.88327
Doğrusal Etkileşimler	0.1618	0.901692	0.16053127	0.906342
Sağlam Doğrusal	0.214639	0.826999	0.21877557	0.826051
Kademeli Doğrusal	0.161823	0.901664	0.16053376	0.90634
İnce Ağaç	0.021683	0.998235	0.02835801	0.997077
Orta Ağaç	0.042558	0.993199	0.04055611	0.994022
Kaba Ağaç	0.098975	0.963214	0.11156999	0.95476
Optimize Ağaç	0.019489	0.998574	0.02568564	0.997602
Doğrusal SVM	0.193251	0.859759	0.19483165	0.862043
Karesel SVM	0.138959	0.927489	0.13711956	0.931668
Kübik SVM	0.126653	0.939764	0.12540221	0.942848
İnce Gauss SVM	0.10276	0.960347	0.10722785	0.958213
Orta Gauss SVM	0.128692	0.937808	0.12785335	0.940592
Kaba Gauss SVM	0.156067	0.908535	0.15489009	0.912809
Optimize SVM	0.002755	0.999971	0.52498051	-0.00164
Verimli Doğrusal En Küçük Kareler	0.430362	0.304496	0.44005335	0.296225
Verimli Doğrusal SVM	0.543369	-0.10872	0.55854202	-0.1338
Optimize Verimli Doğrusal	0.430336	0.304581	0.43999125	0.296423
Rasyonel Karesel GPR	0.016756	0.998946	0.02176993	0.998278

Tablo 4.5 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Kare Üstel GPR	0.018395	0.998729	0.02324989	0.998035
Matern 5/2 GPR	0.01456	0.999204	0.02137857	0.998339
Üstel GPR	0.000317	1	0.02308344	0.998063
SVM Çekirdeği	0.126679	0.939738	0.12610767	0.942203
En Küçük Kareler Çekirdeği	0.098761	0.963373	0.10867844	0.957075
Optimize Çekirdek	0.096718	0.964872	0.10566578	0.959422
Güçlendirilmiş Ağaçlar	1.174741	-4.18222	1.17534562	-4.02059
Torbalı Ağaçlar	0.03064	0.996475	0.03689154	0.995054
Optimize Topluluk	0.245796	0.773127	0.25266533	0.767986
Dar Sinir Ağı	0.175993	0.883689	0.17457782	0.889235
Orta Sinir Ağı	0.066226	0.98353	0.08240409	0.975321
Geniş Sinir Ağı	0.046865	0.991752	0.05268147	0.989914
Çift Katmanlı Sinir Ağı	0.168208	0.893752	0.16626002	0.899539
Üç Katmanlı Sinir Ağı	0.176723	0.882721	0.17562694	0.8879
Optimize Sinir Ağı	0.073711	0.979597	0.0941677	0.967772

Şekil 4.18, altıncı hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

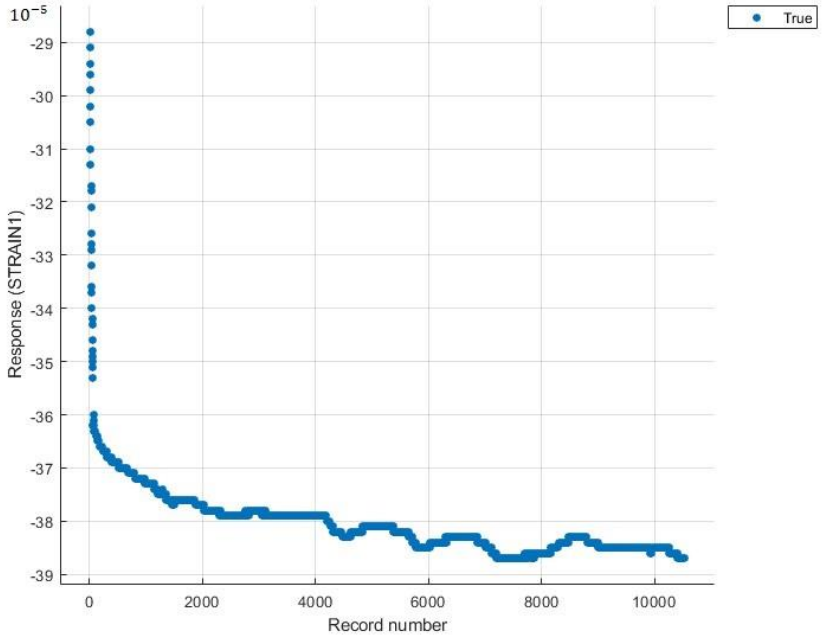

Şekil 4.18: Basamaklı aşamasında altıncı haftanın gerilme dağıtımı.

Tablo 4.6, altıncı hafta için regresyon modelinin eğitim ve test sonuçlarının bir özetini sunmaktadır. Üstel GPR modeli, 0,000183'lük RMSE ve 1'lik R^2 ile kanıtlandığı üzere eğitim aşamasında gelişmiş performans sergilemiştir. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç tüm modellerin pozitif bir R^2 değeri sergilediğini göstermiştir. Üstel GPR modeli test aşamasında 0.05034175 RMSE ve 0.994597 R^2 değerine ulaşarak güçlü bir performans göstermiştir. Bununla birlikte, kare üstel GPR, 0,03474348 RMSE ve 0,997426 R^2 değerine ulaşarak test verileri üzerinde gelişmiş performans göstermiştir. Optimize SVM, verimli doğrusal SVM ve güçlendirilmiş ağaçlar modelleri hariç, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri sergilemiştir.

Tablo 4.6: Basamaklı aşamasında altıncı haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.365613	0.706912	0.36879706	0.710004
Doğrusal Etkileşimler	0.331839	0.75856	0.33809746	0.756274
Sağlam Doğrusal	0.386316	0.67278	0.38972477	0.676158
Kademeli Doğrusal	0.331963	0.758379	0.33793679	0.756506
İnce Ağaç	0.025092	0.99862	0.03949066	0.996675

Tablo 4.6 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Ağaç	0.055822	0.993168	0.06707917	0.990406
Kaba Ağaç	0.157574	0.945559	0.18107193	0.930093
Optimize Ağaç	0.025723	0.998549	0.03923178	0.996718
Doğrusal SVM	0.380122	0.683189	0.38331151	0.686728
Karesel SVM	0.343399	0.741446	0.34657814	0.743894
Kübik SVM	0.331557	0.75897	0.33563808	0.759807
İnce Gauss SVM	0.220356	0.893535	0.23906753	0.878141
Orta Gauss SVM	0.320831	0.774313	0.32557597	0.773993
Kaba Gauss SVM	0.353099	0.726631	0.35601661	0.729755
Optimize SVM	0.025403	0.998585	0.68484435	-3.18E-06
Verimli Doğrusal En Küçük Kareler	0.674161	0.003489	0.68318769	0.004829
Verimli Doğrusal SVM	0.7061	-0.09317	0.71698312	-0.09606
Optimize Verimli Doğrusal	0.674161	0.003491	0.68318728	0.00483
Rasyonel Karesel GPR	0.031735	0.997792	0.04167553	0.996297
Kare Üstel GPR	0.022793	0.998861	0.03474348	0.997426
Matern 5/2 GPR	0.01825	0.99927	0.03804757	0.996913
Üstel GPR	0.000183	1	0.05034175	0.994597
SVM Çekirdeği	0.277492	0.831168	0.28462435	0.827272
En Küçük Kareler Çekirdeği	0.164822	0.940436	0.18559217	0.926559
Optimize Çekirdek	0.154326	0.94778	0.17640458	0.933651
Güçlendirilmiş Ağaçlar	1.614343	-4.71408	1.61424809	-4.55595
Torbalı Ağaçlar	0.036146	0.997135	0.05650538	0.993192
Optimize Topluluk	0.023793	0.998759	0.04316331	0.996028
Dar Sinir Ağı	0.108714	0.974086	0.11650489	0.97106

Tablo 4.6 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Sinir Ağı	0.341984	0.743572	0.34727211	0.742867
Geniş Sinir Ağı	0.080934	0.985638	0.0898959	0.98277
Çift Katmanlı Sinir Ağı	0.080131	0.985921	0.07951798	0.986518
Üç Katmanlı Sinir Ağı	0.079919	0.985996	0.08207138	0.985638
Optimize Sinir Ağı	0.184813	0.925111	0.14873308	0.952834

Şekil 4.19, altı hafta boyunca betonarme kirişte meydana gelen gerilme değerinin dağıtımını göstermektedir.

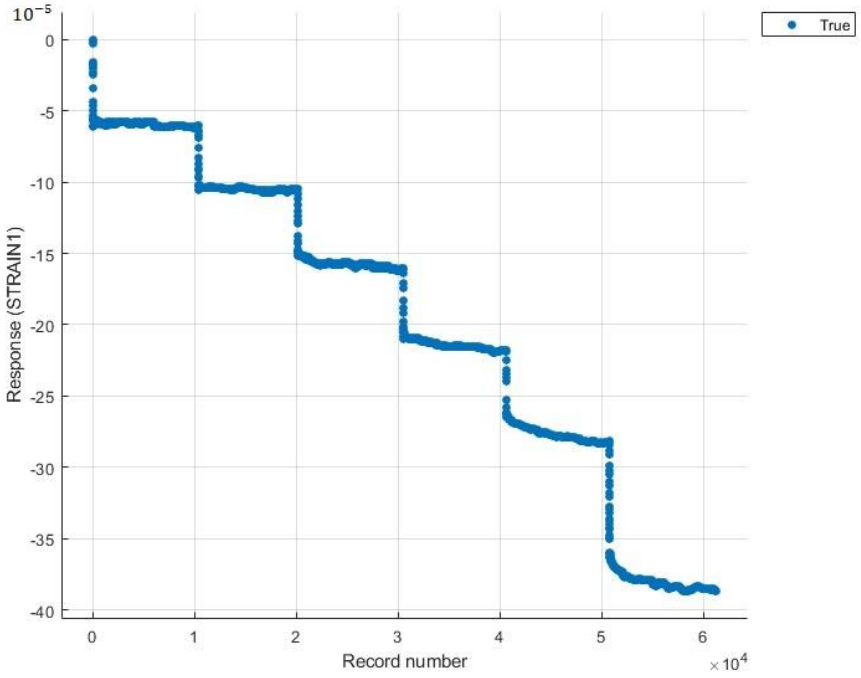

Şekil 4.19: Basamaklı aşamasında altı haftanın gerilme dağıtımı.

Tablo 4.7, basamaklı aşamasındaki altı haftanın regresyon modelinin eğitim ve test sonuçlarını özetlemektedir. Üstel GPR modeli, 0,014533'lük RMSE ve 0,999998'lik R^2 ile gösterildiği gibi eğitim aşamasında gelişmiş performans göstermiştir. Eğitim sonuçları, verimli doğrusal SVM hariç tüm modellerin pozitif bir R^2 değeri sergilediğini göstermiştir. Üstel GPR modeli, test aşamasında 0,05183789 RMSE ve 0,999977 R^2 değerine ulaşarak güçlü bir

performans sergilemiş ve böylece bu aşamada üstün model olarak belirlenmiştir. Verimli doğrusal SVM haricinde, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri göstermiştir.

Tablo 4.7: Basamaklı aşamasında altı haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.809101	0.994404	0.81524172	0.994369
Doğrusal Etkileşimler	0.258668	0.999428	0.25780612	0.999437
Sağlam Doğrusal	0.812027	0.994364	0.81770101	0.994335
Kademeli Doğrusal	0.258703	0.999428	0.25782515	0.999437
İnce Ağaç	0.062842	0.999966	0.08373177	0.999941
Orta Ağaç	0.090241	0.99993	0.11107266	0.999895
Kaba Ağaç	0.142504	0.999826	0.15421278	0.999799
Optimize Ağaç	0.062842	0.999966	0.08373177	0.999941
Doğrusal SVM	0.967333	0.992001	0.97109497	0.992011
Karesel SVM	0.705084	0.99575	0.70471738	0.995792
Kübik SVM	0.704912	0.995753	0.70311861	0.995812
İnce Gauss SVM	0.829776	0.994115	0.83437563	0.994102
Orta Gauss SVM	0.687359	0.995961	0.68107026	0.99607
Kaba Gauss SVM	0.709494	0.995697	0.71154742	0.995711
Optimize SVM	0.221566	0.99958	0.22067407	0.999587
Verimli Doğrusal En Küçük Kareler	7.000387	0.581107	7.03273475	0.580971
Verimli Doğrusal SVM	10.94762	-0.02447	11.0090586	-0.02682
Optimize Verimli Doğrusal	6.999908	0.581164	7.03226577	0.581027
Rasyonel Karesel GPR	0.075206	0.999952	0.0831913	0.999941
Kare Üstel GPR	0.128111	0.99986	0.13005944	0.999857
Matern 5/2 GPR	0.115878	0.999885	0.12050059	0.999877

Tablo 4.7 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Üstel GPR	0.014533	0.999998	0.05183789	0.999977
SVM Çekirdeği	0.71419	0.99564	0.71446227	0.995675
En Küçük Kareler Çekirdeği	0.321387	0.999117	0.32434183	0.999109
Optimize Çekirdek	0.369478	0.998833	0.37076649	0.998835
Güçlendirilmiş Ağaçlar	0.98322	0.991737	0.98631826	0.991758
Torbalı Ağaçlar	0.06707	0.999962	0.08253195	0.999942
Optimize Topluluk	0.088808	0.999933	0.09524993	0.999923
Dar Sinir Ağı	0.238582	0.999513	0.23941318	0.999514
Orta Sinir Ağı	0.170129	0.999753	0.17536748	0.999739
Geniş Sinir Ağı	0.174903	0.999739	0.17964743	0.999727
Çift Katmanlı Sinir Ağı	0.197479	0.999667	0.19686619	0.999672
Üç Katmanlı Sinir Ağı	0.201474	0.999653	0.20425956	0.999647
Optimize Sinir Ağı	0.809101	0.994404	0.81524172	0.994369

4.2.1.2. Sinir Ağı

Sinir ağı yöntemi Matlab kullanılarak uygulanmıştır. Veri kümesinin yüzde yetmişi eğitim kümesi ve yüzde otuzu test kümesi olarak ayrılmıştır. Analiz her haftaya ayrı ayrı uygulanmış ve daha sonra altı hafta olan tüm dönem için kullanılmıştır. Ayrıca, her aşama için analiz on kez yapılmış ve daha sonra ortalama alınarak analiz süreçlerinin nihai sonucu olarak kabul edilmiştir. Sinir ağı uyumu her analiz zamanı için bazı farklılıklar göstermektedir, bu nedenle analizin on kez yapılması daha doğru sonuçlar sağlayacaktır.

Tablo 4.8, basamaklı aşamanın ilk hafta boyunca sinir ağı kullanılarak yapılan 10 eğitim ve test iterasyonunun sonuçlarını göstermektedir. Bulgular birbirine yakın olsa da tablo aralarında küçük farklılıklar olduğunu göstermektedir. Sinir ağı ile elde edilen kesin sonuçlar, 0,046025'lik bir RMSE ve 0,991229'luk bir R^2 sergileyerek eğitim aşaması boyunca övgüye değer bir performans göstermiştir. Ayrıca, test aşamasının sonuçları da 0.056263 RMSE ve 0.986025 R^2 ile olağanüstüdür.

Tablo 4.8: Basamaklı aşamasında ilk haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0043269	0.065779	0.98351	0.0051	0.07141428	0.97565
2	0.0016674	0.040834	0.99429	0.0014	0.03741657	0.98954
3	0.0010963	0.03311	0.9959	0.0023	0.04795832	0.98929
4	0.0021837	0.04673	0.99067	0.0031	0.05567764	0.98851
5	0.0015997	0.039996	0.99352	0.003	0.05477226	0.98783
6	0.0025498	0.050496	0.98995	0.0033	0.05744563	0.9862
7	0.0018284	0.04276	0.99187	0.0057	0.07549834	0.98038
8	0.0028035	0.052948	0.98948	0.0029	0.05385165	0.98511
9	0.002961	0.054415	0.98776	0.0031	0.05567764	0.98766
10	0.0011007	0.033177	0.99534	0.0028	0.05291503	0.99008
Ortalama	**0.00221174**	**0.046025**	**0.991229**	**0.00327**	**0.05626274**	**0.986025**

Tablo 4.9, basamaklı aşamanın ikinci hafta boyunca sinir ağı kullanılarak eğitim ve test için gerçekleştirilen 10 iterasyonun sonuçlarını göstermektedir. Bulgular birbirine yakındır; ancak tablo aralarında küçük farklılıklar olduğunu ortaya çıkarmıştır. Sinir ağı yoluyla elde edilen sonuçlar, 0.033149 RMSE ve 0.982719 R^2 ile eğitim aşamasında güçlü bir performans göstermiştir. Ayrıca, test aşamasından elde edilen sonuçlar 0.036476 RMSE ve 0.977399 R^2 değeri ile yüksek performans göstermiştir.

Tablo 4.9: Basamaklı aşamasında ikinci haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00087967	0.029659	0.98684	8.94E-04	0.02990635	0.98536
2	0.0011492	0.0339	0.98324	0.0015	0.03872983	0.97263
3	0.00080845	0.028433	0.9884	8.02E-04	0.02832349	0.98561
4	0.00083284	0.028859	0.98679	9.68E-04	0.03111029	0.98628
5	0.00096097	0.031	0.98705	9.04E-04	0.03006027	0.97978
6	0.0016734	0.040907	0.97227	0.0017	0.04123106	0.97762
7	0.00074956	0.027378	0.98838	8.61E-04	0.02934859	0.98734
8	0.0017917	0.042328	0.97574	0.0024	0.04898979	0.94779
9	0.00074076	0.027217	0.98709	0.0017	0.04123106	0.98021
10	0.0017481	0.04181	0.97139	0.0021	0.04582576	0.97137
Ortalama	**0.001133465**	**0.033149**	**0.982719**	**1.38E-03**	**0.03647565**	**0.977399**

Tablo 4.10, basamaklı aşamanın üçüncü hafta boyunca sinir ağı yoluyla eğitim ve test için gerçekleştirilen 10 iterasyonun sonuçlarını göstermektedir. Bulgular birbirine yakındır; ancak sonuç aralarında küçük farklılıklar olduğunu gösterilmiştir. Sinir ağı işleminden elde edilen sonuçlar, 0.041027 RMSE ve 0.989434 R^2 ile kanıtlandığı üzere, eğitim aşamasında güçlü bir performans göstermiştir. Ayrıca, test aşaması sonuçları 0.044541 RMSE ve 0.987254 R^2 değeri ile yüksek performans sağlamıştır.

Tablo 4.10: Basamaklı aşamasında üçüncü haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0016973	0.041198	0.98972	1.90E-03	0.04358899	0.98663
2	0.001702	0.041255	0.99007	0.0019	0.04358899	0.98535
3	0.0015855	0.039818	0.99006	1.70E-03	0.04123106	0.98894
4	0.001619	0.040237	0.98971	1.80E-03	0.04242641	0.98901
5	0.0015854	0.039817	0.98968	3.10E-03	0.05567764	0.98269
6	0.0017662	0.042026	0.98791	0.0021	0.04582576	0.98879
7	0.0016288	0.040358	0.9895	1.80E-03	0.04242641	0.98904
8	0.001886	0.043428	0.98824	0.0021	0.04582576	0.987
9	0.0016913	0.041125	0.98993	0.0017	0.04123106	0.98725
10	0.0016814	0.041005	0.98952	0.0019	0.04358899	0.98784
Ortalama	**0.00168429**	**0.041027**	**0.989434**	**2.00E-03**	**0.04454111**	**0.987254**

Tablo 4.11, basamaklı aşamanın dördüncü hafta boyunca sinir ağı yoluyla eğitim ve test için gerçekleştirilen 10 iterasyonun sonuçlarını sunmaktadır. Sonuçlar birbiriyle yakından ilişkilidir; yine de tablo aralarında küçük farklılıklar olduğunu ortaya koymuştur. Sinir ağı sonuçları, 0,037399'luk RMSE ve 0,993258'lik R^2 ile gösterildiği gibi, eğitim aşaması boyunca güçlü bir performans sergilemiştir. Ayrıca, test aşamasından elde edilen bulgular 0.050838 RMSE ve 0.986908 R^2 değeri ile olağanüstü bir performans sergilemiştir.

Tablo 4.11: Basamaklı aşamasında dördüncü haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0018067	0.042505	0.99151	2.40E-03	0.04898979	0.98857
2	0.0011761	0.034294	0.99453	0.0013	0.03605551	0.99373
3	0.0010904	0.033021	0.99442	7.80E-03	0.08831761	0.96878
4	0.001134	0.033675	0.99473	3.80E-03	0.06164414	0.98185
5	0.0022633	0.047574	0.98877	3.20E-03	0.05656854	0.98649
6	0.001136	0.033705	0.9949	0.0013	0.03605551	0.99319

Tablo 4.11 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
7	0.0023352	0.048324	0.98917	4.20E-03	0.06480741	0.97949
8	0.0011043	0.033231	0.99521	0.001	0.03162278	0.99398
9	0.001164	0.034117	0.99466	0.0022	0.04690416	0.98965
10	0.0011249	0.03354	0.99468	0.0014	0.03741657	0.99335
Ortalama	**0.00143349**	**0.037399**	**0.993258**	**2.86E-03**	**0.0508382**	**0.986908**

Basamaklı aşamanın beşinci hafta boyunca, sinir ağı kullanılarak eğitim ve test amacıyla on iterasyon gerçekleştirilmiştir. Tablo 4.12'da bu iterasyonların sonuçları gösterilmektedir. Bulgular yüksek derecede korelasyon gösterirken, tablo bazı küçük farklılıkları da ortaya koymuştur. Eğitim aşamasında, sinir ağı sonuçları, 0.027454 RMSE değeri ve 0.998602 R^2 değeri ile gösterildiği gibi yüksek düzeyde bir performans sergilemiştir. Test aşamasından elde edilen sonuçlar 0,030864 RMSE ve 0,998209 R^2 değeri ile mükemmel bir performans ortaya koymuştur. Buna ek olarak, bulgular dikkate değer bir performans göstermiştir.

Tablo 4.12: Basamaklı aşamasında beşinci haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00068914	0.026251	0.99876	1.20E-03	0.03464102	0.99767
2	0.00080338	0.028344	0.99854	8.05E-04	0.02836565	0.99842
3	0.00064295	0.025356	0.99877	1.10E-03	0.03316625	0.99803
4	0.00086017	0.029329	0.99844	9.50E-04	0.03081655	0.99812
5	0.00086884	0.029476	0.99837	8.84E-04	0.02973903	0.99838
6	0.00073812	0.027168	0.99862	8.80E-04	0.0296685	0.99841
7	0.00077408	0.027822	0.99852	9.09E-04	0.03015079	0.99841
8	0.00073358	0.027085	0.99865	8.86E-04	0.02976071	0.99833
9	0.00072387	0.026905	0.99867	8.51E-04	0.02917002	0.99838
10	0.00071818	0.026799	0.99868	0.0011	0.03316625	0.99794
Ortalama	**0.000755231**	**0.027454**	**0.998602**	**9.56E-04**	**0.03086448**	**0.998209**

Basamaklı aşamanın altıncı hafta, eğitim ve test amacıyla sinir ağı işleminin kullanıldığı 10 iterasyondan oluşmuştur. Tablo 4.13'da bu iterasyonların sonuçları gösterilmektedir. Tablo 4.13, sonuçlar arasında güçlü bir korelasyon olduğunu ortaya koymakla birlikte bazı küçük farklılıkları da ortaya koymuştur. Eğitim sırasında sinir ağı sonuçları, 0,043198 RMSE ve 0,997956 R^2 ile mükemmel performans göstermiştir. R^2 değeri 0,997546 ve RMSE değeri

0,047249 olan test sonuçları da mükemmel performans göstermiştir. Ayrıca, sonuçlar iyi bir performans göstermiştir.

Tablo 4.13: Basamaklı aşamasında altıncı haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0020594	0.045381	0.99778	2.60E-03	0.0509902	0.99705
2	0.0024807	0.049807	0.9974	2.30E-03	0.04795832	0.99729
3	0.0017368	0.041675	0.9981	2.20E-03	0.04690416	0.99767
4	0.001712	0.041376	0.99803	2.60E-03	0.0509902	0.99757
5	0.0022413	0.047342	0.99772	1.80E-03	0.04242641	0.99765
6	0.0014287	0.037798	0.99854	2.10E-03	0.04582576	0.99742
7	0.001679	0.040976	0.99824	1.90E-03	0.04358899	0.99778
8	0.001307	0.036152	0.9986	2.40E-03	0.04898979	0.99733
9	0.0021282	0.046132	0.99754	2.10E-03	0.04582576	0.99798
10	0.0020554	0.045337	0.99761	0.0024	0.04898979	0.99772
Ortalama	**0.00188285**	**0.043198**	**0.997956**	**2.24E-03**	**0.04724894**	**0.997546**

Basamaklı aşamanın altı haftanın eğitim ve test için on sinir ağı iterasyonu gerçekleştirilmiştir. Tablo 4.14'da bu iterasyonların sonuçları gösterilmektedir. Tablo 4.14, sonuçlar birbirine yakın olsa da her bir iterasyonun sonuçları arasında bazı küçük farklılıklar olduğunu ortaya çıkarmıştır. Eğitim sırasında sinir ağı sonuçları, 0,13576 RMSE ve 0,999918 R^2 ile son derece mükemmel bir performans göstermiştir. R^2 değeri 0,999912 ve RMSE değeri 0,14078 olan test bulgularında da yöntemin çok iyi bir performans sergilediği görülmüştür. Ayrıca, sonuçlar yöntemin başarılı olduğunu göstermiştir.

Tablo 4.14: Basamaklı aşamasında altı haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.021142	0.145403	0.99991	2.71E-02	0.16462078	0.99988
2	0.02324	0.152447	0.9999	2.15E-02	0.14662878	0.99991
3	0.0067136	0.081937	0.99997	8.20E-03	0.09055385	0.99997
4	0.030356	0.17423	0.99987	3.46E-02	0.18601075	0.99985
5	0.014325	0.119687	0.99994	1.43E-02	0.1196662	0.99994
6	0.012156	0.110254	0.99995	9.90E-03	0.09949874	0.99996
7	0.019453	0.139474	0.99992	1.89E-02	0.13747727	0.99992
8	0.016044	0.126665	0.99993	1.65E-02	0.12845233	0.99993
9	0.03336	0.182647	0.99986	3.48E-02	0.18654758	0.99985
10	0.015588	0.124852	0.99993	0.022	0.14832397	0.99991
Ortalama	**0.01923776**	**0.13576**	**0.999918**	**2.08E-02**	**0.14077803**	**0.999912**

4.2.1.3. NARX

Sinir ağına benzer şekilde, NARX Matlab kullanılarak uygulanmıştır. Bu yöntemde veri kümesi yüzde yetmişlik bir eğitim kümesi ve yüzde otuzluk bir test kümesi olarak ikiye ayrılmıştır. NARX her eğitimde farklı sonuçlar verebilirken, analiz on kez yapılmış ve sonuçların ortalaması bu yöntemin nihai sonucu olarak kabul edilmiştir. Bu yol daha doğru sonuçlar sağlamıştır. Ayrıca, analiz basamaklı aşama sırasında her hafta için ayrı ayrı yapılmış ve daha sonra altı hafta olan tüm aşamaya uygulanmıştır.

Basamaklı aşamanın ilk haftasında gerçekleştirilen 10 NARX analizinin bulguları Tablo 4.15'da gösterilmektedir. Her iterasyonun sonuçları çok benzer olsa bile bazı farklılıklar bulunmuştur. 0,017321'lik RMSE ve 0,9986'lık R^2 ile eğitim aşamasından elde edilen NARX bulguları, yöntemin olağanüstü performansını ortaya koymuştur. Ayrıca, 0,97791 R^2 ve 0,068722 RMSE ile test aşaması bulguları yöntemin başarılı olduğunu göstermiştir. Son olarak, eğitim ve test sonuçları yöntemin ne kadar etkili olduğunu göstermiştir.

Tablo 4.15: Basamaklı aşamasında ilk haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0003	0.017321	0.9987	0.0017	0.04123106	0.9932
2	0.0003	0.017321	0.9985	0.0145	0.12041595	0.9386
3	0.0003	0.017321	0.9986	0.0028	0.05291503	0.9893
4	0.0003	0.017321	0.9986	0.0039	0.06244998	0.9847
5	0.0003	0.017321	0.9987	0.0017	0.04123106	0.9930
6	0.0003	0.017321	0.9988	0.0039	0.06244998	0.9689
7	0.0003	0.017321	0.9986	0.0085	0.09219544	0.9660
8	0.0003	0.017321	0.9985	0.0079	0.08888194	0.9759
9	0.0003	0.017321	0.9985	0.0054	0.07348469	0.9793
10	0.0003	0.017321	0.9985	0.0027	0.05196152	0.9902
Ortalama	**0.0003**	**0.017321**	**0.9986**	**0.0053**	**0.06872166**	**0.97791**

Tablo 4.16, basamaklı aşamanın ikinci haftasında gerçekleştirilen 10 NARX analizinin sonuçlarını sunmaktadır. Her bir iterasyonun sonuçları kayda değer benzerlikler gösterirken, bazı farklılıklar da tespit edilmiştir. Eğitim aşamasından elde edilen 0,022542 RMSE ve 0,99153 R^2 değerine sahip NARX bulguları, yöntemin performansında yüksek düzeyde etkinliğe işaret etmiştir. Ayrıca, 0,97482 R^2 ve 0,036573 RMSE ile gösterilen test aşamasından elde edilen bulgular da yöntemin başarısını göstermiştir. Son olarak, eğitim ve test sonuçları yöntemin etkinliğini açıkça ortaya koymuştur.

Tablo 4.16: Basamaklı aşamasında ikinci haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00053056	0.023034	0.992	0.0007273	0.02696924	0.9823
2	0.0005	0.022361	0.9914	0.0022	0.04690416	0.9632
3	0.0005	0.022361	0.9926	0.0013	0.03605551	0.9643
4	0.0005	0.022361	0.9912	0.0012	0.03464102	0.9813
5	0.00053414	0.023111	0.9911	0.0009546	0.03089579	0.9828
6	0.00048796	0.02209	0.992	0.0007905	0.0281153	0.9852
7	0.0005	0.022361	0.9915	0.004	0.06324555	0.944
8	0.0005	0.022361	0.9912	0.001	0.03162278	0.9841
9	0.0005	0.022361	0.9917	0.0017	0.04123106	0.9717
10	0.00053013	0.023025	0.9906	0.0006785	0.02604822	0.9893
Ortalama	**0.000508279**	**0.022542**	**0.99153**	**0.0014551**	**0.03657286**	**0.97482**

Basamaklı aşamanın üçüncü haftasında gerçekleştirilen 10 NARX analizinin sonuçları Tablo 4.17'da özetlenmiştir. Her bir iterasyonun sonuçları önemli benzerlikler gösterse de belirli farklılıklar da tespit edilmiştir. Yöntemin performansı, 0,039111'lik bir RMSE ve 0,98989'luk bir R^2 içeren eğitim aşamasından elde edilen NARX bulgularının da gösterdiği gibi oldukça etkilidir. Buna ek olarak, yöntemin etkinliği 0,98734 R^2 ve 0,042376 RMSE değerlerini veren test aşamasının sonuçlarıyla da ortaya konmuştur. Son olarak, yöntemin etkinliği eğitim ve test sonuçlarında açıkça görülmüştür.

Tablo 4.17: Basamaklı aşamasında üçüncü haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0015	0.03873	0.9903	0.0019	0.04358899	0.9864
2	0.0016	0.04	0.9898	0.0016	0.04	0.9878
3	0.0015	0.03873	0.99	0.0017	0.04123106	0.9879
4	0.0016	0.04	0.9901	0.0018	0.04242641	0.9864
5	0.0015	0.03873	0.9902	0.0019	0.04358899	0.986
6	0.0015	0.03873	0.9898	0.0016	0.04	0.9886
7	0.0015	0.03873	0.9902	0.0016	0.04	0.988
8	0.0015	0.03873	0.9895	0.0019	0.04358899	0.9882
9	0.0016	0.04	0.9889	0.0022	0.04690416	0.9865
10	0.0015	0.03873	0.9901	0.0018	0.04242641	0.9876
Ortalama	**0.00153**	**0.039111**	**0.98989**	**0.0018**	**0.0423755**	**0.98734**

Tablo 4.18, basamaklı aşamanın dördüncü haftasında gerçekleştirilen on NARX analizinin bulgularını özetlemektedir. Sonuçların iterasyonlar boyunca güçlü ortaklıklar göstermesine rağmen dikkate değer farklılıklar olmuştur. Eğitim aşamasında, sonuçlar tekniğin 0,026662 RMSE ve 0,99651 R^2 ile çok iyi performans gösterdiğini ortaya koymuştur. R^2 değerinin 0,99436 ve RMSE değerinin 0,033922 olduğu test aşamasından elde edilen sonuçlar, yöntemin verimliliğini daha da kanıtlamıştır. Son olarak hem eğitim hem de test aşamalarının sonuçları yöntemin etkili olduğunu göstermiştir.

Tablo 4.18: Basamaklı aşamasında dördüncü haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00072813	0.026984	0.9964	0.0008623	0.02936443	0.9959
2	0.0007	0.026458	0.9966	0.0012	0.03464102	0.994
3	0.00072282	0.026885	0.9965	0.0009427	0.03070326	0.9954
4	0.0007	0.026458	0.9965	0.001	0.03162278	0.9952
5	0.00071891	0.026812	0.9966	0.0007966	0.02822463	0.9957
6	0.0007	0.026458	0.9964	0.0013	0.03605551	0.9939
7	0.00073932	0.02719	0.9963	0.0009311	0.03051442	0.9957
8	0.0007	0.026458	0.9965	0.002	0.04472136	0.9904
9	0.0007	0.026458	0.9968	0.0012	0.03464102	0.9942
10	0.0007	0.026458	0.9965	0.0015	0.03872983	0.9932
Ortalama	**0.000710918**	**0.026662**	**0.99651**	**0.0011733**	**0.03392183**	**0.99436**

Tablo 4.19, basamaklı aşamanın beşinci haftasında gerçekleştirilen 10 NARX analizinin sonuçlarını özetlemektedir. Bulgular iterasyonlar boyunca önemli benzerlikler sergilerken değişiklikler de olmuştur. Eğitim aşamasında elde edilen bulgular, yaklaşımın 0,017155 RMSE ve 0,99945 R^2 ile olağanüstü bir performans sergilediğini göstermiştir. Test aşaması sonuçları, 0,99882 R^2 ve 0,024427 RMSE ile yöntemin etkinliğini daha da doğrulamıştır. Sonuç olarak hem eğitim hem de test aşamalarından elde edilen sonuçlar tekniğin başarılı olduğunu işaret etmiştir.

Tablo 4.19: Basamaklı aşamasında beşinci haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00031535	0.017758	0.9994	0.0003603	0.01898157	0.9993
2	0.00029658	0.017221	0.9994	0.0008792	0.02965131	0.9983
3	0.00027602	0.016614	0.9995	0.0006353	0.02520496	0.9988

Tablo 4.19 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
4	0.00030447	0.017449	0.9994	0.0008982	0.02996915	0.9983
5	0.00028869	0.016991	0.9995	0.0003957	0.0198912	0.9992
6	0.0003	0.017321	0.9994	0.0011	0.03316625	0.9981
7	0.00029464	0.017165	0.9995	0.0003837	0.01958826	0.9992
8	0.00030097	0.017348	0.9994	0.0006289	0.02507808	0.9988
9	0.00027597	0.016612	0.9995	0.0004551	0.02133284	0.9991
10	0.00029148	0.017073	0.9995	0.0004584	0.02141074	0.9991
Ortalama	**0.000294417**	**0.017155**	**0.99945**	**0.0006195**	**0.02442744**	**0.99882**

Tablo 4.20, basamaklı aşamanın altıncı haftasında gerçekleştirilen 10 NARX analizinden elde edilen bulguları sunmaktadır. Kayda değer değişiklikler mevcutken, sonuçlar iterasyonlar arasında önemli ölçüde tutarlılık göstermiştir. Eğitim aşaması sırasında sonuçlar, yöntemin 0,0169 RMSE ve 0,99969 R^2 değerlerine ulaşarak kayda değer bir performans sergilediğini göstermiştir. Test aşamasından elde edilen ve 0,99173 R^2 değeri ve 0,06241 RMSE ile gösterilen sonuçlar, kullanılan yöntemin etkinliği için ek destek sağlamıştır. Sonuç olarak hem eğitim hem de test aşamalarından elde edilen bulgular, tekniğin etkinliğini kanıtlamıştır.

Tablo 4.20: Basamaklı aşamasında altıncı haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0003	0.017321	0.9997	0.0037	0.06082763	0.9959
2	0.0003	0.017321	0.9997	0.0022	0.04690416	0.9976
3	0.00025294	0.015904	0.9997	0.0009019	0.03003098	0.999
4	0.0003	0.017321	0.9997	0.0044	0.0663325	0.9955
5	0.00030423	0.017442	0.9997	0.000746	0.02731355	0.9989
6	0.00027274	0.016515	0.9997	0.0007903	0.0281121	0.999
7	0.00033819	0.01839	0.9996	0.0006953	0.02636892	0.9991
8	0.0003	0.017321	0.9997	0.0017	0.04123106	0.9982
9	0.0002	0.014142	0.9997	0.0696	0.26381812	0.9352
10	0.0003	0.017321	0.9997	0.0011	0.03316625	0.9989
Ortalama	**0.00028681**	**0.0169**	**0.99969**	**0.0085834**	**0.06241053**	**0.99173**

Tablo 4.21, basamaklı aşamanın altı haftası boyunca gerçekleştirilen on NARX analizinden elde edilen sonuçları göstermektedir. Değişiklikler görülmekle birlikte, sonuçlar

iterasyonlar arasında önemli ölçüde tutarlılık sergilemiştir. Eğitim aşamasında bulgular, yaklaşımın 0,030393 RMSE ve 1 R^2 değerlerine ulaşarak olağanüstü bir performans sergilediğini göstermiştir. R^2 değerini 1 ve RMSE değerinin 0,035683 olduğu test aşaması bulguları, kullanılan tekniğin etkinliğini daha da kanıtlamıştır. Sonuç olarak hem eğitim hem de test aşamalarından elde edilen sonuçlar, stratejinin etkili olduğunu belirtmiştir.

Tablo 4.21: Basamaklı aşamasında altı haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0009	0.03	1	0.0011	0.03316625	1
2	0.0009644	0.031055	1	0.0008975	0.0299583	1
3	0.0009	0.03	1	0.0013	0.03605551	1
4	0.0009	0.03	1	0.0023	0.04795832	1
5	0.0009	0.03	1	0.0011	0.03316625	1
6	0.001	0.031623	1	0.0011	0.03316625	1
7	0.0009	0.03	1	0.0017	0.04123106	1
8	0.0009	0.03	1	0.0012	0.03464102	1
9	0.0009	0.03	1	0.0013	0.03605551	1
10	0.000977	0.031257	1	0.000988	0.03143183	1
Ortalama	**0.00092414**	**0.030393**	**1**	**0.0012985**	**0.03568303**	**1**

4.2.1.4. NARNN

NARNN, bu çalışmada kullanılan son yöntemdir. Bu yöntem de önceki yöntemlere benzer şekilde Matlab'da uygulanmıştır. Analitik veri kümesi eğitim için yüzde yetmiş ve test için yüzde otuz olarak bölümlendirilmiştir. Ayrıca, sinir ağı ve NARX'a benzer şekilde, analiz daha kesin sonuçlar elde etmek için 10 kez kullanılmıştır, ancak bulgular her iterasyonda değişebilirdir. Basamaklı aşama boyunca analiz haftalık olarak gerçekleştirilmiş ve ardından altı haftalık sürenin tamamı için toplanmıştır.

Basamaklı aşamanın ilk haftasında NARNN kullanılarak yapılan on zamanlı analizin sonuçları Tablo 4.22'da sunulmuştur. Her bir zaman analizinin sonuçları neredeyse aynıdır; ancak aralarında küçük farklılıklar vardır. Eğitim aşaması sonuçları, 0,044663 RMSE ve 0,99139 R^2 ile kullanılan yöntemin oldukça etkili olduğunu göstermiştir. Ayrıca, test aşamasının sonuçları da 0.06473 RMSE ve 0.982 R^2 ile performansın kalitesini yansıtmıştır. Kullanılan yöntemin verimliliği, eğitim ve test aşamalarının sonuçlarıyla nihai olarak kanıtlanmıştır.

Tablo 4.22: Basamaklı aşamasında ilk haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0026	0.05099	0.9880	0.0045	0.06708204	0.9844
2	0.0016	0.04	0.9915	0.0092	0.09591663	0.9750
3	0.0020	0.044721	0.9915	0.0032	0.05656854	0.9871
4	0.0020	0.044721	0.9911	0.0045	0.06708204	0.9850
5	0.0024	0.04899	0.9902	0.0030	0.05477226	0.9855
6	0.0013	0.036056	0.9949	0.0026	0.0509902	0.9854
7	0.0023	0.047958	0.9914	0.0029	0.05385165	0.9822
8	0.0017	0.041231	0.9925	0.0050	0.07071068	0.9799
9	0.0027	0.051962	0.9894	0.0045	0.06708204	0.9746
10	0.0016	0.04	0.9934	0.0040	0.06324555	0.9809
Ortalama	**0.00202**	**0.044663**	**0.99139**	**0.00434**	**0.06473016**	**0.982**

Basamaklı aşamanın ikinci haftasında NARNN kullanılarak gerçekleştirilen on sefer bir çalışmanın sonuçları Tablo 4.23'da gösterilmektedir. Her bir zamansal analizin sonuçları neredeyse aynıdır, yine de analizler arasında bazı farklılıklar bulunmuştur. Eğitim aşaması bulguları, 0.030918 RMSE ve 0.98416 R^2 ile kullanılan yöntemin yüksek başarısını göstermiştir. Test aşamasından elde edilen bulgular, 0.037784 RMSE ve 0.97062 R^2 ile performans kalitesini sergilemiştir. Yöntemin etkinliği son olarak eğitim ve test aşamalarının sonuçlarıyla gösterilmiştir.

Tablo 4.23: Basamaklı aşamanın ikinci haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0023	0.047958	0.9644	0.0026	0.0509902	0.9465
2	0.0009	0.03	0.9863	0.0011	0.03316625	0.9776
3	0.0010	0.031623	0.9824	0.0014	0.03741657	0.9784
4	0.0009	0.03	0.9847	0.0013	0.03605551	0.9770
5	0.0008	0.028284	0.9854	0.0013	0.03605551	0.9826
6	0.0007	0.026458	0.9890	0.0012	0.03464102	0.9768
7	0.0008	0.028284	0.9862	0.0011	0.03316625	0.9827
8	0.0008	0.028284	0.9886	0.0020	0.04472136	0.9474
9	0.0009	0.03	0.9860	0.0016	0.04	0.9678
10	0.0008	0.028284	0.9886	0.0010	0.03162278	0.9694
Ortalama	**0.00099**	**0.030918**	**0.98416**	**0.00146**	**0.03778354**	**0.97062**

Tablo 4.24, NARNN kullanılarak basamaklı aşamanın üçüncü haftasında gerçekleştirilen on zamanlı analizin sonuçlarını içermektedir. Her bir zaman analizinin sonuçları hemen hemen aynıdır; ancak analizler arasında küçük farklılıklar görülmüştür. Eğitim aşamanın sonuçları, 0,040848 RMSE ve 0,9888 R^2 ile yöntemin oldukça etkili olduğunu göstermiştir. Buna ek olarak, performansın kalitesi, 0,98536 R^2 ve 0,046342 RMSE içeren test aşamanın sonuçlarıyla da kanıtlanmıştır. Eğitim ve test aşaması sonuçları sonuçta yöntemin etkinliğinin bir kanıtı olarak hizmet etmiştir.

Tablo 4.24: Basamaklı aşamanın üçüncü haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0016	0.04	0.9884	0.0019	0.04358899	0.9890
2	0.0016	0.04	0.9889	0.0017	0.04123106	0.9892
3	0.0017	0.041231	0.9889	0.0024	0.04898979	0.9827
4	0.0016	0.04	0.9893	0.0018	0.04242641	0.9885
5	0.0018	0.042426	0.9883	0.0025	0.05	0.9817
6	0.0016	0.04	0.9895	0.0018	0.04242641	0.9872
7	0.0016	0.04	0.9892	0.0017	0.04123106	0.9885
8	0.0019	0.043589	0.9870	0.0029	0.05385165	0.9824
9	0.0016	0.04	0.9895	0.0021	0.04582576	0.9850
10	0.0017	0.041231	0.9890	0.0029	0.05385165	0.9794
Ortalama	**0.00167**	**0.040848**	**0.9888**	**0.00217**	**0.04634228**	**0.98536**

Tablo 4.25, NARNN kullanılarak basamaklı aşamanın dördüncü haftasında gerçekleştirilen on zamanlı bir analizin sonuçlarını sunmaktadır. Her bir zaman analizinin sonuçları neredeyse aynıdır; yine de analizler arasında küçük farklılıklar bulunmuştur. Eğitim aşamasından elde edilen sonuçlar, 0,033071'lik bir RMSE ve 0,99468'lik bir R^2 elde ederek yöntemin oldukça etkili olduğunu göstermiştir. Performansın kalitesi, 0,98467'lik bir R^2 ve 0,052205'lik bir RMSE gösteren test aşamasından elde edilen sonuçlarla kanıtlanmıştır. Son olarak, eğitim ve test aşamalarından elde edilen sonuçlar yöntemin etkinliğini göstermiştir.

Tablo 4.25: Basamaklı aşamanın dördüncü haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0010	0.031623	0.9952	0.0029	0.05385165	0.9859
2	0.0011	0.033166	0.9945	0.0020	0.04472136	0.9901
3	0.0010	0.031623	0.9953	0.0033	0.05744563	0.9840

Tablo 4.25 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
4	0.0015	0.03873	0.9924	0.0034	0.05830952	0.9848
5	0.0013	0.036056	0.9937	0.0102	0.10099505	0.9478
6	0.0010	0.031623	0.9953	0.0036	0.06	0.9819
7	0.0012	0.034641	0.9942	0.0014	0.03741657	0.9931
8	0.0010	0.031623	0.9950	0.0011	0.03316625	0.9950
9	0.0010	0.031623	0.9953	0.0015	0.03872983	0.9919
10	0.0009	0.03	0.9959	0.0014	0.03741657	0.9922
Ortalama	**0.0011**	**0.033071**	**0.99468**	**0.00308**	**0.05220524**	**0.98467**

NARNN'ın kullanıldığı basamaklı aşamanın beşinci haftasında gerçekleştirilen on zamanlı analizin sonuçları Tablo 4.26'da özetlenmiştir. Her bir zaman analizinin sonuçları hemen hemen aynıdır ancak analizler arasında küçük farklılıklar bulunmuştur. RMSE 0,028297 ve R^2 0,99844 olan eğitim aşamanın sonuçlarının da gösterdiği gibi yöntem oldukça etkilidir. Test aşamasından elde edilen 0,99712'lik R^2 ve 0,038303'lük RMSE sonuçları performansın kalitesinin kanıtlanmıştır. Sonuç olarak, prosedürün etkinliği eğitim ve test bölümlerinin sonuçlarıyla gösterilmiştir.

Tablo 4.26: Basamaklı aşamanın beşinci haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00088517	0.029752	0.9983	0.0009798	0.03130144	0.9981
2	0.0007	0.026458	0.9986	0.0012	0.03464102	0.9977
3	0.0008	0.028284	0.9984	0.0011	0.03316625	0.9980
4	0.00071331	0.026708	0.9986	0.0007952	0.02819982	0.9985
5	0.0007	0.026458	0.9987	0.0018	0.04242641	0.9966
6	0.0007	0.026458	0.9987	0.0020	0.04472136	0.9965
7	0.0008	0.028284	0.9985	0.0013	0.03605551	0.9975
8	0.0007	0.026458	0.9986	0.0030	0.05477226	0.9943
9	0.0013	0.036056	0.9975	0.0023	0.04795832	0.9958
10	0.00078733	0.028059	0.9985	0.0008875	0.02979094	0.9982
Ortalama	**0.000808581**	**0.028297**	**0.99844**	**0.0015363**	**0.03830333**	**0.99712**

Tablo 4.27, basamaklı aşamanın altıncı haftasında NARNN kullanılarak yapılan on zamanlı bir çalışmanın sonuçlarını göstermektedir. Çalışmalar arasında bazı küçük farklılıklar olsa da zaman analizi sonuçları çoğunlukla aynı kalmıştır. RMSE'nin 0,047062 ve R^2'nin

0,99752 olduğu eğitim sonuçları, yöntemin çok iyi çalıştığını göstermiştir. Test kısmında ise R^2 değerinin 0,99571 ve RMSE değerinin 0,059099 olması kullanılan yöntemin performans kalitesini yansıtmıştır. Sonuç olarak, eğitim ve test bölümlerinin sonuçları sürecin çalıştığını göstermiştir.

Tablo 4.27: Basamaklı aşamanın altıncı haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0021	0.045826	0.9977	0.0028	0.05291503	0.9970
2	0.0017	0.041231	0.9982	0.0072	0.08485281	0.9906
3	0.0024	0.04899	0.9974	0.0025	0.05	0.9969
4	0.0014	0.037417	0.9984	0.0024	0.04898979	0.9971
5	0.0020	0.044721	0.9978	0.0026	0.0509902	0.9968
6	0.0028	0.052915	0.9968	0.0043	0.06557439	0.9953
7	0.0029	0.053852	0.9970	0.0030	0.05477226	0.9958
8	0.0027	0.051962	0.9968	0.0038	0.06164414	0.9963
9	0.0024	0.04899	0.9972	0.0031	0.05567764	0.9972
10	0.0020	0.044721	0.9979	0.0043	0.06557439	0.9941
Ortalama	**0.00224**	**0.047062**	**0.99752**	**0.0036**	**0.05909906**	**0.99571**

Tablo 4.28, basamaklı aşamanın altı hafta boyunca gerçekleştirilen ve NARNN'ın kullanıldığı on zamanlı analizin sonuçlarını özetlemektedir. Her bir zaman analizinin sonuçları neredeyse aynıdır ancak analizler arasında küçük farklılıklar bulunmuştur. RMSE'nin 0,11312 ve R^2'nin 0,99995 olduğu eğitim aşamanın sonuçları, yöntemin olağanüstü etkinliğinin bir göstergesidir. Performansın kalitesi, 0,99853'lük bir R^2 ve 0,25682'lik bir RMSE gösteren test aşamasının sonuçları ile desteklenmiştir. Sonuç olarak, eğitim ve test bölümleri prosedürün etkinliğinin kanıtı olmuştur.

Tablo 4.28: Basamaklı aşamanın altı haftanın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0324	0.18	0.9999	0.0236	0.15362291	0.9999
2	0.0131	0.114455	0.9999	0.0125	0.1118034	0.9999
3	0.0164	0.128062	0.9999	0.0194	0.13928388	0.9999
4	0.0107	0.103441	1	0.0142	0.11916375	0.9999
5	0.0082	0.090554	1	0.0111	0.10535654	1
6	0.0156	0.1249	0.9999	0.0149	0.12206556	0.9999
7	0.0098	0.098995	1	0.7562	0.86959761	0.9884

Tablo 4.28 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
8	0.0146	0.12083	0.9999	0.6020	0.77588659	0.9974
9	0.0058	0.076158	1	0.0069	0.08306624	1
10	0.0088	0.093808	1	0.0078	0.08831761	1
Ortalama	**0.01354**	**0.11312**	**0.99995**	**0.14686**	**0.25681641**	**0.99853**

4.2.2. Basamaksız Aşama

Bu aşama, uygulanan yükün herhangi bir değişiklik olmadan stabilize olduğu deneyin yedinci haftasında başlamıştır. Analiz ilk hafta içinde gerçekleştirilecek ve daha sonra ilk 15 gün boyunca uygulanmıştır. Bundan sonra, analiz ilk ayda ve daha sonra ilk iki ay boyunca yapılmıştır. Daha sonra, analiz üç aylık bir süre boyunca ve nihayetinde altı ay boyunca kullanılmıştır. Bu teknik, uzun bir analiz süresi boyunca modellerin performansının etkinliğini değerlendirmeyi amaçlamaktadır.

4.2.2.1. İstatistiksel Modeller

Basamaklı aşamada belirtildiği gibi, veri kümesi yüzde yetmişi eğitim kümesi ve yüzde otuzu test kümesi olmak üzere ikiye ayrılmıştır. Basamaklı aşamada kullanılan regresyon modellerinin aynısı bu aşamada da uygulanmıştır.

Şekil 4.20'de, basamaksız aşamanın ilk haftasında betonarme kirişteki gerilme dağılımı gösterilmektedir.

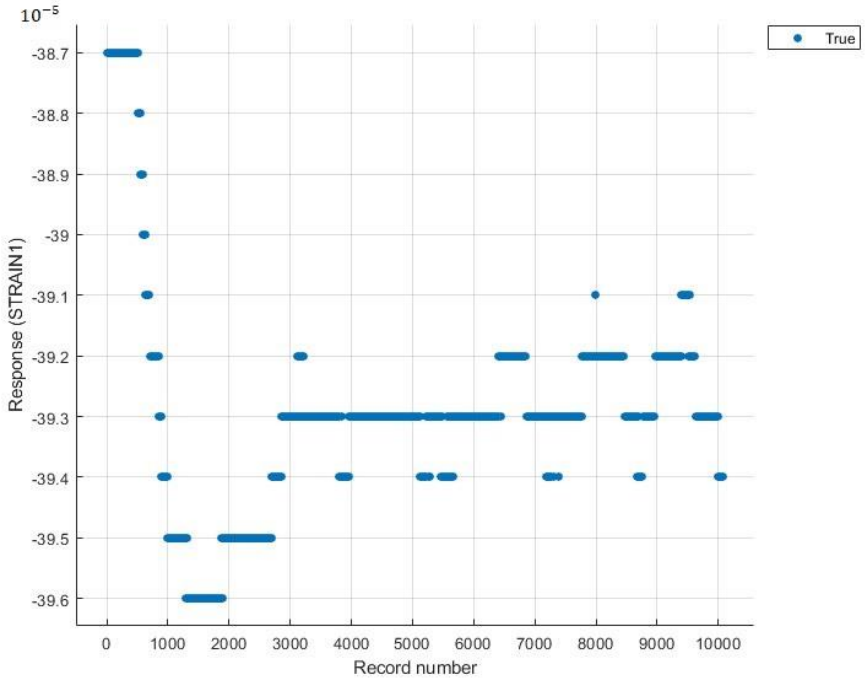

Şekil 4.20: Basamaksız aşamasında ilk haftanın gerilme dağıtımı.

Tablo 4.29, basamaksız aşamanın ilk haftası için regresyon modelinin eğitim ve test sonuçlarına genel bir bakış sunmaktadır. Üstel GPR modeli, eğitim aşamasında 0,000208 RMSE ve 0,999999 R^2 değeri ile gösterilen güçlü bir performans sergilemiştir. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç tüm modellerin pozitif bir R^2 değeri sergilediğini göstermiştir. Üstel GPR modeli, test sırasında 0,015486 RMSE ve 0,992526 R^2 değerine ulaşarak güçlü bir performans sergilemiş ve bu da onu test setindeki en iyi model haline getirmiştir. Son olarak, verimli doğrusal en küçük kareler, verimli doğrusal SVM ve güçlendirilmiş ağaçlar modelleri haricinde, kullanılan tüm modeller için test sonuçları pozitif bir R^2 değeri göstermiştir.

Tablo 4.29: Basamaksız aşamasında ilk haftanın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.100339	0.702051	0.10316671	0.668303
Doğrusal Etkileşimler	0.087501	0.773417	0.09092378	0.742358
Sağlam Doğrusal	0.10628	0.665725	0.11024002	0.62126
Kademeli Doğrusal	0.087513	0.773355	0.09088024	0.742604

Tablo 4.29 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
İnce Ağaç	0.010899	0.996485	0.01545974	0.992552
Orta Ağaç	0.013791	0.994371	0.01609407	0.991928
Kaba Ağaç	0.019705	0.988509	0.02088142	0.986411
Optimize Ağaç	0.00902	0.997592	0.01612443	0.991897
Doğrusal SVM	0.109795	0.643251	0.11217149	0.607872
Karesel SVM	0.089382	0.763572	0.09480386	0.719899
Kübik SVM	0.040848	0.95062	0.04219815	0.944506
İnce Gauss SVM	0.017105	0.991341	0.01891837	0.988846
Orta Gauss SVM	0.034337	0.965109	0.03589671	0.959842
Kaba Gauss SVM	0.096499	0.724423	0.09975414	0.689884
Optimize SVM	0.004869	0.999298	0.03995311	0.950253
Verimli Doğrusal En Küçük Kareler	0.183338	0.005264	0.17913034	-1.78E-06
Verimli Doğrusal SVM	0.183871	-0.00053	0.17932534	-0.00218
Optimize Verimli Doğrusal	0.183338	0.005265	0.17913005	1.44E-06
Rasyonel Karesel GPR	0.011323	0.996206	0.01440903	0.99353
Kare Üstel GPR	0.013676	0.994465	0.0157348	0.992284
Matern 5/2 GPR	0.011682	0.995961	0.01459965	0.993357
Üstel GPR	0.000208	0.999999	0.01548616	0.992526
SVM Çekirdeği	0.024033	0.982908	0.02610237	0.978766
En Küçük Kareler Çekirdeği	0.028559	0.975863	0.03010978	0.971746
Optimize Çekirdek	0.024836	0.981746	0.02589606	0.979101
Güçlendirilmiş Ağaçlar	1.66578	-81.1178	1.66641754	-85.5426
Torbalı Ağaçlar	0.011845	0.995848	0.01427565	0.993649
Optimize Topluluk	0.071933	0.84687	0.07238498	0.83671

Tablo 4.29 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Dar Sinir Ağı	0.087298	0.774465	0.08988878	0.74819
Orta Sinir Ağı	0.086869	0.776673	0.08940361	0.750901
Geniş Sinir Ağı	0.026841	0.97868	0.02716762	0.976998
Çift Katmanlı Sinir Ağı	0.038374	0.956422	0.03850671	0.95379
Üç Katmanlı Sinir Ağı	0.100339	0.702051	0.10316927	0.668286
Optimize Sinir Ağı	0.100339	0.702051	0.10316673	0.668303

Basamaksız aşamanın ilk 15 günde betonarme kirişteki gerilme dağılımı Şekil 4.21'de gösterilmiştir.

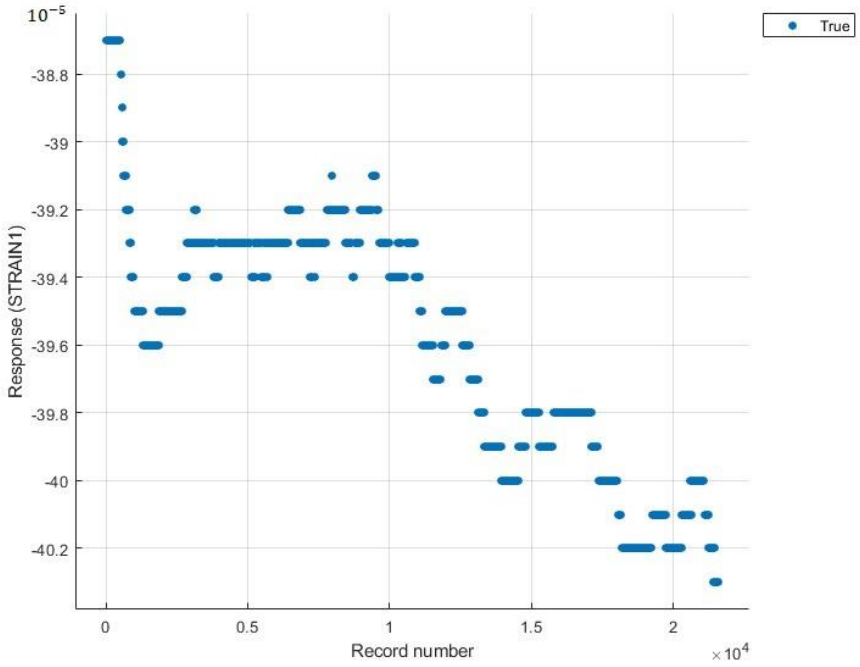

Şekil 4.21: Basamaksız aşamasında ilk 15 günün gerilme dağıtımı.

Tablo 4.30, basamaksız aşamanın ilk 15 günün regresyon modelinin eğitim ve test sonuçlarının bir özetini sunmaktadır. Optimize SVM ve üstel GPR modelleri, optimize SVM için 0,000444 RMSE ve 0,999999 R^2 ve üstel GPR için 0,000785 RMSE ve 0,999995 R^2 ile eğitim aşamasında güçlü bir performans sergilemiş ve eğitim süreçlerinde en iyi iki model

olarak belirlenmiştir. Eğitim sonuçları, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı hariç tüm modellerin pozitif bir R^2 değeri sergilediğini göstermiştir. Üstel GPR modeli, 0,014239'luk bir RMSE ve 0,998465'lik bir R^2 elde ederek testte güçlü bir performans göstermiştir. Rasyonel karesel GPR, 0,014135 RMSE ve 0,998487 R^2 değerine ulaşarak test verileri üzerinde gelişmiş performans göstermiştir. Ayrıca, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı modelleri hariç, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri sergilemiştir.

Tablo 4.30: Basamaksız aşamasında ilk 15 günün regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.088934	0.941155	0.08900204	0.940028
Doğrusal Etkileşimler	0.080401	0.951906	0.08041884	0.951038
Sağlam Doğrusal	0.097075	0.92989	0.09726119	0.928381
Kademeli Doğrusal	0.080412	0.951893	0.08041363	0.951044
İnce Ağaç	0.011523	0.999012	0.0149178	0.998315
Orta Ağaç	0.015256	0.998268	0.01714639	0.997774
Kaba Ağaç	0.020636	0.996832	0.02148175	0.996506
Optimize Ağaç	0.009004	0.999397	0.01491017	0.998317
Doğrusal SVM	0.091076	0.938288	0.09122476	0.936995
Karesel SVM	0.078196	0.954508	0.07754324	0.954477
Kübik SVM	0.048283	0.982655	0.04790918	0.982623
İnce Gauss SVM	0.030955	0.992871	0.03162324	0.992429
Orta Gauss SVM	0.041547	0.987157	0.04182781	0.986754
Kaba Gauss SVM	0.077852	0.954907	0.07786233	0.954101
Optimize SVM	0.000444	0.999999	0.3591644	0.023363
Verimli Doğrusal En Küçük Kareler	0.364706	0.010408	0.36175424	0.009227
Verimli Doğrusal SVM	0.370271	-0.02002	0.36694832	-0.01943
Optimize Verimli Doğrusal	0.364705499	0.010413	0.36175323	0.009233

Tablo 4.30 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Rasyonel Karesel GPR	0.011253448	0.999058	0.01413484	0.998487
Kare Üstel GPR	0.021535916	0.996549	0.02290605	0.996028
Matern 5/2 GPR	0.013488375	0.998646	0.01579468	0.998111
Üstel GPR	0.00078488	0.999995	0.01423927	0.998465
SVM Çekirdeği	0.03577423	0.990478	0.03638314	0.989978
En Küçük Kareler Çekirdeği	0.037472174	0.989553	0.0380488	0.98904
Optimize Çekirdek	0.034895422	0.99094	0.03529937	0.990566
Güçlendirilmiş Ağaçlar	1.679216027	-19.9789	1.67869858	-20.335
Torbalı Ağaçlar	0.012176744	0.998897	0.01431737	0.998448
Optimize Topluluk	0.036255374	0.990221	0.03852231	0.988765
Dar Sinir Ağı	0.083545189	0.948071	0.08340666	0.947332
Orta Sinir Ağı	0.057496836	0.975404	0.05799587	0.974535
Geniş Sinir Ağı	0.040010812	0.98809	0.04070739	0.987454
Çift Katmanlı Sinir Ağı	0.074413382	0.958802	0.0745922	0.957876
Üç Katmanlı Sinir Ağı	0.080616485	0.951648	0.08038533	0.951078
Optimize Sinir Ağı	0.366619384	-1.46E-11	0.36343692	-1.11E-05

Basamaksız aşamanın bir ayda betonarme kirişteki gerilme dağılımı Şekil 4.22’de görülmektedir.

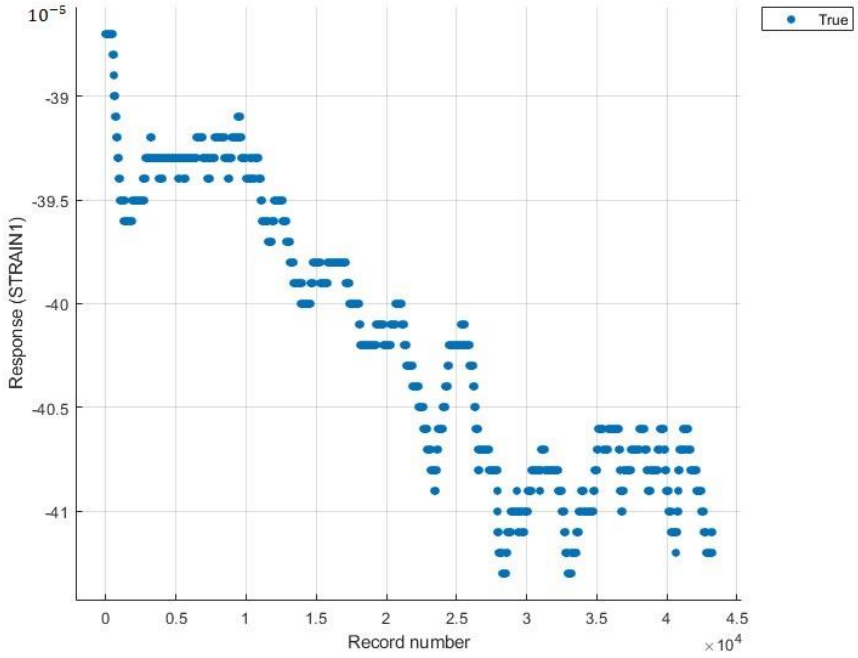

Şekil 4.22: Basamaksız aşamasında bir ayın gerilme dağıtımı.

Tablo 4.31, regresyon modelinin hem eğitim hem de test sonuçlarını içeren basamaksız aşamanın bir ay sonuçlarını özetlemektedir. Üstel GPR modelleri eğitim aşamasında etkileyici bir performans göstererek 0001265 RMSE ve 0,999996 R^2 elde etmiş ve böylece eğitim süreçlerinde lider model olarak konumlandırılmıştır. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç her modelin pozitif bir R^2 değeri sergilediğini göstermiştir. Ayrıca, üstel GPR modeli test sırasında güçlü bir performans sergileyerek 0,014938 RMSE ve 0,999497 R^2 değeri elde etmiş ve böylece test aşamasında en iyi model olarak kendini göstermiştir. Son olarak, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı modelleri haricinde, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri göstermiştir.

Tablo 4.31: Basamaksız aşamasında bir ayın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.151193	0.948979	0.15046898	0.948917
Doğrusal Etkileşimler	0.087797	0.982795	0.08776633	0.98262
Sağlam Doğrusal	0.152519	0.94808	0.15135384	0.948314
Kademeli Doğrusal	0.087804	0.982793	0.08777436	0.982617

Tablo 4.31 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
İnce Ağaç	0.011149	0.999723	0.01531594	0.999471
Orta Ağaç	0.015549	0.99946	0.0171947	0.999333
Kaba Ağaç	0.023427	0.998775	0.02415998	0.998683
Optimize Ağaç	0.009442	0.999801	0.01571311	0.999443
Doğrusal SVM	0.152296	0.948231	0.15116515	0.948443
Karesel SVM	0.086303	0.983376	0.08590947	0.983348
Kübik SVM	0.062165	0.991375	0.0619483	0.991342
İnce Gauss SVM	0.058774	0.99229	0.05924264	0.992081
Orta Gauss SVM	0.059522	0.992092	0.06015119	0.991837
Kaba Gauss SVM	0.085449	0.983703	0.08491618	0.983731
Optimize SVM	0.003087	0.999979	0.07358752	0.987782
Verimli Doğrusal En Küçük Kareler	0.65868	0.031642	0.65615013	0.028618
Verimli Doğrusal SVM	0.669909	-0.00166	0.66608503	-0.00102
Optimize Verimli Doğrusal	0.65868	0.031642	0.65615013	0.028618
Rasyonel Karesel GPR	0.02181	0.998938	0.0234952	0.998755
Kare Üstel GPR	0.030848	0.997876	0.03171757	0.99773
Matern 5/2 GPR	0.02	0.999107	0.02200692	0.998907
Üstel GPR	0.001265	0.999996	0.01493771	0.999497
SVM Çekirdeği	0.056122	0.99297	0.05672412	0.99274
En Küçük Kareler Çekirdeği	0.053665	0.993572	0.05451613	0.993294
Optimize Çekirdek	0.052165	0.993926	0.05313971	0.993629
Güçlendirilmiş Ağaçlar	1.704759	-5.48655	1.70556005	-5.56323
Torbalı Ağaçlar	0.012184	0.999669	0.01461981	0.999518
Optimize Topluluk	0.081806	0.985063	0.08171642	0.984934

Tablo 4.31 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Dar Sinir Ağı	0.08623	0.983404	0.08586908	0.983364
Orta Sinir Ağı	0.082249	0.984901	0.08190289	0.984865
Geniş Sinir Ağı	0.065523	0.990417	0.0659225	0.990195
Çift Katmanlı Sinir Ağı	0.090997	0.981518	0.09088591	0.981363
Üç Katmanlı Sinir Ağı	0.080269	0.985619	0.08017723	0.985496
Optimize Sinir Ağı	0.669355	6.66E-16	0.66577183	-7.92E-05

Şekil 4.23, basamaksız aşamanın iki ayın betonarme kirişteki gerilme dağılımını göstermektedir.

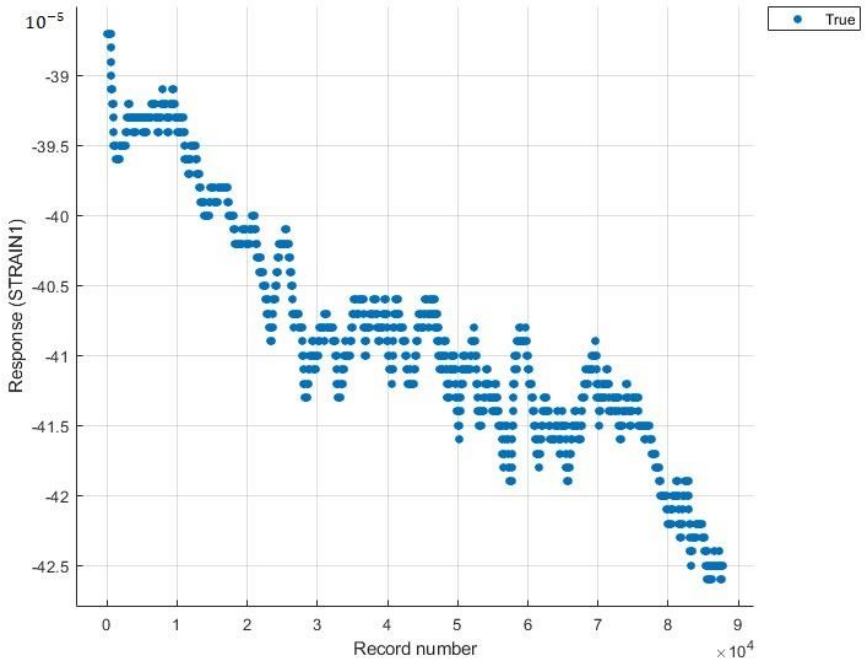

Şekil 4.23: Basamaksız aşamasında iki ayın gerilme dağıtımı.

Basamaksız aşamanın iki ay için regresyon modelinin sonuçları hem eğitim hem de test aşamalarından elde edilen bulguların özeti Tablo 4.32'de sunulmuştur. Eğitim aşamasında, optimize SVM ve üstel GPR modelleri çok iyi performans göstermiştir. Optimize SVM için 0,001404 RMSE ve 0,999997 R^2, GPR için ise 0,001528 RMSE ve 0,999997 R^2 elde ederek

eğitim süreçlerindeki en iyi modeller olmuşlardır. Eğitim sonuçları, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı hariç tüm modellerin pozitif bir R^2 değeri gösterdiğini ortaya koymuştur. Ayrıca, üstel GPR modeli test aşamasında etkileyici bir performans göstererek 0,017475 RMSE ve 0,999591 R^2 değerine ulaşmış ve bu da onu bu değerlendirmede lider model olarak konumlandırmıştır. Son olarak, optimize SVM, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı modelleri haricinde, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri sergilemiştir.

Tablo 4.32: Basamaksız aşamasında iki ayın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.176	0.95895	0.17573239	0.958654
Doğrusal Etkileşimler	0.150204	0.970102	0.15091542	0.969507
Sağlam Doğrusal	0.176286	0.958817	0.17603244	0.958513
Kademeli Doğrusal	0.150213	0.970098	0.15093044	0.969501
İnce Ağaç	0.015496	0.999682	0.01932214	0.9995
Orta Ağaç	0.017595	0.99959	0.02041621	0.999442
Kaba Ağaç	0.025647	0.999128	0.02736954	0.998997
Optimize Ağaç	0.015292	0.99969	0.01929075	0.999502
Doğrusal SVM	0.176642	0.958651	0.17637317	0.958352
Karesel SVM	0.141725	0.973382	0.14334556	0.972489
Kübik SVM	0.079308	0.991665	0.07972922	0.991489
İnce Gauss SVM	0.054369	0.996083	0.05453215	0.996019
Orta Gauss SVM	0.064048	0.994564	0.06369701	0.994568
Kaba Gauss SVM	0.120123	0.980878	0.12062308	0.98052
Optimize SVM	0.001404	0.999997	0.8642533	-3.07E-05
Verimli Doğrusal En Küçük Kareler	0.856887	0.026963	0.85228238	0.027481
Verimli Doğrusal SVM	0.877133	-0.01956	0.87211563	-0.01831
Optimize Verimli Doğrusal	0.856887	0.026963	0.85228238	0.027481

Tablo 4.32 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Rasyonel Karesel GPR	0.029381	0.998856	0.03022465	0.998777
Kare Üstel GPR	0.042534	0.997602	0.04254236	0.997577
Matern 5/2 GPR	0.027882	0.99897	0.02900569	0.998874
Üstel GPR	0.001528	0.999997	0.01747545	0.999591
SVM Çekirdeği	0.064739	0.994446	0.06463905	0.994406
En Küçük Kareler Çekirdeği	0.06892	0.993705	0.068947	0.993636
Optimize Çekirdek	0.065455	0.994322	0.06528091	0.994294
Güçlendirilmiş Ağaçlar	1.734413	-2.98646	1.73426594	-3.02682
Torbalı Ağaçlar	0.014888	0.999706	0.01776945	0.999577
Optimize Topluluk	0.635311	0.465122	0.63417521	0.461545
Dar Sinir Ağı	0.176	0.958951	0.17573228	0.958654
Orta Sinir Ağı	0.148048	0.970954	0.14765536	0.97081
Geniş Sinir Ağı	0.061875	0.994926	0.06185532	0.994877
Çift Katmanlı Sinir Ağı	0.126821	0.978686	0.12683942	0.97846
Üç Katmanlı Sinir Ağı	0.083224	0.990821	0.08304755	0.990766
Optimize Sinir Ağı	3.48606	-15.1047	3.48932529	-15.301

Basamaksız aşamanın üç ayın betonarme kirişteki gerilme dağılımı Şekil 4.24‘de gösterilmiştir.

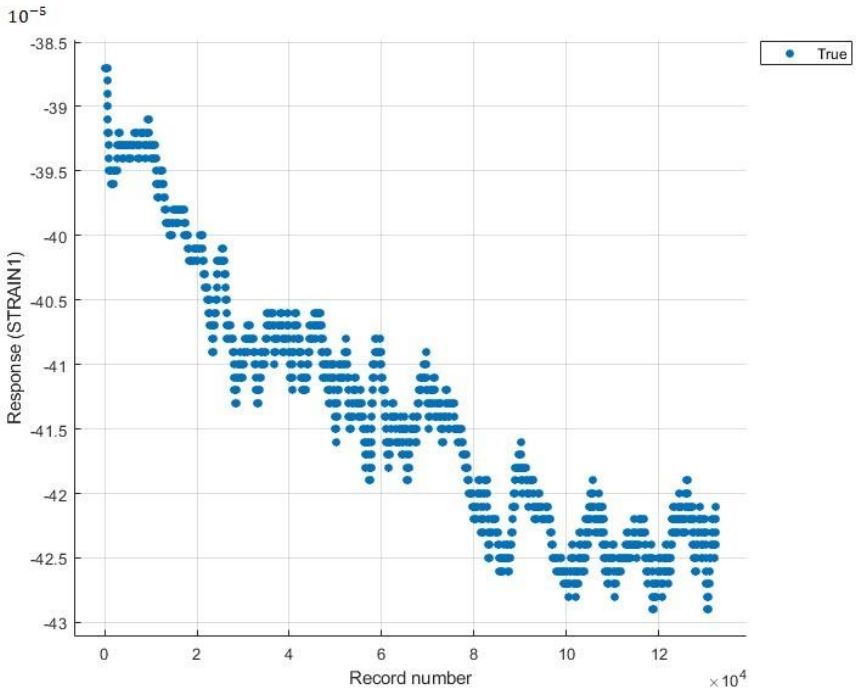

Şekil 4.24: Basamaksız aşamasında üç ayın gerilme dağıtımı.

Basamaksız aşamanın üç ay için regresyon modeli sonuçları hem eğitim hem de test dönemlerinden elde edilen sonuçlar dahil olmak üzere Tablo 4.33'de gösterilmektedir. Eğitim aşaması boyunca, optimize SVM ve üstel GPR modelleri, optimize SVM için 0,001259 RMSE ve 0,999998 R^2 ve üstel GPR için 0,001919 RMSE ve 0,999996 R^2 elde ederek olağanüstü performans göstermiş ve böylece eğitim prosedürlerinde lider modeller olarak konumlanmışlardır. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç tüm modellerin pozitif bir R^2 değerine sahip olduğunu göstermiştir. Ayrıca, üstel GPR modeli test aşaması boyunca 0,022608 RMSE ve 0999505 R^2 değeri ile kayda değer bir performans göstermiş, dolayısıyla bu değerlendirmede önde gelen model olarak belirlenmiştir. Son olarak, verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı modelleri haricinde, kullanılan tüm modeller test sonuçlarında pozitif R^2 değeri göstermiştir.

Tablo 4.33: Basamaksız aşamasında üç ayın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.262508	0.932947	0.26426691	0.932434
Doğrusal Etkileşimler	0.246079	0.941078	0.24778125	0.940601
Sağlam Doğrusal	0.271539	0.928254	0.27340666	0.92768

Tablo 4.33 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Kademeli Doğrusal	0.246083	0.941075	0.24777395	0.940605
İnce Ağaç	0.02234	0.999514	0.02472102	0.999409
Orta Ağaç	0.02346	0.999464	0.02588787	0.999352
Kaba Ağaç	0.032523	0.998971	0.03381814	0.998894
Optimize Ağaç	0.022257	0.999518	0.02468063	0.999411
Doğrusal SVM	0.269529	0.929312	0.27144384	0.928715
Karesel SVM	0.158503	0.975554	0.15897838	0.975548
Kübik SVM	0.095784	0.991073	0.09631412	0.991025
İnce Gauss SVM	0.065408	0.995837	0.06587015	0.995802
Orta Gauss SVM	0.072177	0.994931	0.07222123	0.994954
Kaba Gauss SVM	0.140257	0.980858	0.14085124	0.980806
Optimize SVM	0.001259	0.999998	0.9814396	0.068105
Verimli Doğrusal En Küçük Kareler	1.005805	0.015625	1.00927172	0.014502
Verimli Doğrusal SVM	1.016037	-0.0045	1.01898621	-0.00456
Optimize Verimli Doğrusal	1.005805	0.015625	1.00927172	0.014502
Rasyonel Karesel GPR	0.033193	0.998928	0.03423629	0.998866
Kare Üstel GPR	0.043914	0.998124	0.04413176	0.998116
Matern 5/2 GPR	0.028038	0.999235	0.0298094	0.99914
Üstel GPR	0.001919	0.999996	0.02260835	0.999505
SVM Çekirdeği	0.079165	0.993902	0.07932029	0.993913
En Küçük Kareler Çekirdeği	0.07988	0.993791	0.08023087	0.993772
Optimize Çekirdek	0.080027	0.993768	0.08023727	0.993771
Güçlendirilmiş Ağaçlar	1.75666	-2.00267	1.75540869	-1.98123
Torbalı Ağaçlar	0.020674	0.999584	0.02262928	0.999505

Tablo 4.33 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Optimize Topluluk	0.175399	0.970065	0.17679179	0.969761
Dar Sinir Ağı	0.262483	0.93296	0.26423647	0.93245
Orta Sinir Ağı	0.237799	0.944976	0.23851977	0.944959
Geniş Sinir Ağı	0.069253	0.995333	0.06912324	0.995377
Çift Katmanlı Sinir Ağı	0.251091	0.938653	0.25195773	0.938582
Üç Katmanlı Sinir Ağı	0.101389	0.989997	0.10165019	0.990003
Optimize Sinir Ağı	1.013756	8.88E-16	1.01667053	-3.76E-07

Şekil 4.25, basamaksız aşamanın altı ayın betonarme kirişteki gerilme dağılımını göstermektedir.

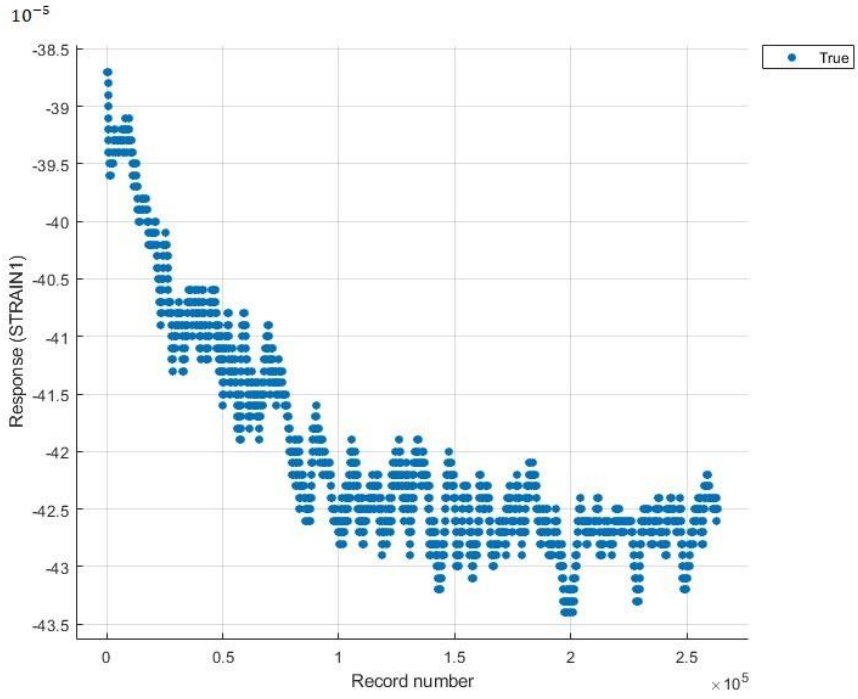

Şekil 4.25: Basamaksız aşamasında altı ayın gerilme dağıtımı.

Tablo 4.34, hem eğitim hem de test sonuçlarını kapsayan basamaksız aşamanın altı ay için regresyon modelinin bulgularını göstermektedir. Üstel GPR modeli, 0,001286 RMSE ve 0,999998 R^2 ile eğitim aşamasında olağanüstü bir performans göstermiş ve böylece eğitim

aşamasında en üstün model olarak belirlenmiştir. Eğitim sonuçları, verimli doğrusal SVM ve güçlendirilmiş ağaçlar hariç tüm modellerin pozitif R^2 değerine sahip olduğunu göstermiştir. Ayrıca, üstel GPR modeli test aşamasında 0,0217387 RMSE ve 0,999512 R^2 değeri ile olağanüstü bir performans göstermiş ve böylece test aşamasında lider model olarak konumlandırılmıştır. Son olarak, verimli doğrusal SVM ve güçlendirilmiş ağaçlar modelleri hariç, kullanılan tüm modeller test sonuçlarında pozitif bir R^2 değeri sergilemiştir.

Tablo 4.34: Basamaksız aşamasında altı ayın regresyon sonuçları.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.541123	0.697176	0.54176018	0.6970353
Doğrusal Etkileşimler	0.396311	0.837568	0.39881573	0.8358192
Sağlam Doğrusal	0.542495	0.695638	0.54308627	0.6955503
Kademeli Doğrusal	0.396315	0.837565	0.39879971	0.8358324
İnce Ağaç	0.02441	0.999384	0.02600705	0.9993018
Orta Ağaç	0.025016	0.999353	0.02657068	0.9992712
Kaba Ağaç	0.028595	0.999154	0.02981285	0.9990825
Optimize Ağaç	0.02431	0.999389	0.02595916	0.9993044
Doğrusal SVM	0.556654	0.679543	0.55708908	0.6796482
Karesel SVM	0.168107	0.970774	0.1675543	0.9710206
Kübik SVM	0.122667	0.984438	0.12198674	0.9846396
İnce Gauss SVM	0.052159	0.997186	0.05252388	0.9971523
Orta Gauss SVM	0.078338	0.993653	0.07859332	0.993624
Kaba Gauss SVM	0.158916	0.973882	0.15844205	0.9740869
Optimize SVM	0.124023	0.984092	0.1234077	0.9842796
Verimli Doğrusal En Küçük Kareler	0.980544	0.005665	0.98158574	0.0054323
Verimli Doğrusal SVM	1.061224	-0.1647	1.06195754	-0.164105
Optimize Verimli Doğrusal	0.980543	0.005665	0.98158571	0.0054323

Tablo 4.34 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Rasyonel Karesel GPR	0.037945	0.998511	0.03856497	0.9984648
Kare Üstel GPR	0.051703	0.997235	0.0518606	0.9972238
Matern 5/2 GPR	0.032423	0.998913	0.03363697	0.9988321
Üstel GPR	0.001286	0.999998	0.02173869	0.9995122
SVM Çekirdeği	0.088911	0.991825	0.08930161	0.9917682
En Küçük Kareler Çekirdeği	0.090936	0.991448	0.09141209	0.9913745
Optimize Çekirdek	0.084517	0.992613	0.08473804	0.992588
Güçlendirilmiş Ağaçlar	1.784361	-2.29279	1.78437495	-2.286625
Torbalı Ağaçlar	0.022023	0.999498	0.02349759	0.9994301
Optimize Topluluk	0.838472	0.27293	0.84038655	0.2709856
Dar Sinir Ağı	0.541123	0.697176	0.54176015	0.6970353
Orta Sinir Ağı	0.118785	0.985408	0.11822668	0.9855719
Geniş Sinir Ağı	0.07848	0.99363	0.07807013	0.9937086
Çift Katmanlı Sinir Ağı	0.532354	0.706911	0.53248504	0.7073202
Üç Katmanlı Sinir Ağı	0.135147	0.981111	0.13510137	0.9811593
Optimize Sinir Ağı	0.085465	0.992446	0.08514374	0.9925169

4.2.2.2. Sinir Ağı

Sinir ağı işlemi Matlab kullanılarak uygulanmıştır. Veri kümesi yüzde yetmiş eğitim kümesi ve yüzde otuz test kümesi olarak ayrılmıştır. Ayrıca, analiz bu aşamanın ilk haftasında ve daha sonra ilk 15 gün boyunca yapılmıştır. Daha sonra, çalışma bu aşamada bir ay ve ardından iki ay boyunca yapılmıştır. Son olarak, analiz üç ay içinde ve ardından altı ay boyunca yapılmıştır. Bu yöntem, zaman aralığı arttıkça uygulanan modelin verimliliğini ölçmek için uygulanmıştır. Ayrıca, analiz her bir dönem için on kez yapılmış ve daha sonra ortalama sonuçlar alınarak her bir çalışmanın nihai sonuçları olarak kabul edilmiştir. Bunun nedeni, sinir

ağı uyumunun her eğitim aşamasının sonuçlarında bazı farklılıklar sağlamasıdır, bu nedenle analizin on kez yapılması daha doğru sonuçlar sağlayacaktır.

Basamaksız aşamanın ilk hafta, eğitim ve test hedefleri için sinir ağı kullanılarak on iterasyon gerçekleştirilmiştir. Bu iterasyonların sonuçları Tablo 4.35'da sunulmuştur. Tablo 4.35'teki sonuçlar birbirine yakın olmasına rağmen her bir iterasyonun sonuçlarında küçük farklılıklar olduğunu göstermektedir. Eğitim sırasındaki sinir ağı uyumu, 0,022769 RMSE ve 0,992156 R^2 ile kanıtlanan olağanüstü bir performans sergilemiştir. Test bulguları, 0,991973 R^2 değeri ve 0,023108 RMSE ile kanıtlandığı üzere yöntemin yüksek performansına işaret etmiştir.

Tablo 4.35: Basamaksız aşamasında ilk haftanın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00050173	0.022399	0.99238	5.31E-04	0.02304018	0.99212
2	0.00050307	0.022429	0.99244	5.30E-04	0.02302043	0.99195
3	0.00057518	0.023983	0.99152	5.89E-04	0.02427406	0.99061
4	0.00053852	0.023206	0.99195	5.79E-04	0.02405327	0.99107
5	0.00053503	0.023131	0.99179	5.63E-04	0.02372783	0.99184
6	0.00054281	0.023298	0.99184	5.18E-04	0.02275412	0.99213
7	0.00047828	0.02187	0.99281	4.76E-04	0.02181284	0.99281
8	0.00051788	0.022757	0.99188	5.09E-04	0.02255527	0.99294
9	0.00049383	0.022222	0.9926	5.35E-04	0.02311947	0.99183
10	0.00050139	0.022392	0.99235	5.16E-04	0.02272488	0.99243
Ortalama	**0.000518772**	**0.022769**	**0.992156**	**5.34E-04**	**0.02310823**	**0.991973**

Basamaksız aşamanın ilk 15 gün boyunca, sinir ağı yoluyla eğitim ve test hedeflerine ulaşmak için on iterasyon gerçekleştirilmiştir. Tablo 4.36'da bu iterasyonların sonuçları gösterilmektedir. Sonuçlardaki küçük farklılıklara rağmen her bir iterasyonun sonuçlarının neredeyse aynı olduğunu görülmektedir. Eğitim sırasında sinir ağı işlemi, 0,031264 RMSE ve 0,996324 R^2 ile gösterildiği gibi olağanüstü bir performans sergilemiştir. Yöntemin yüksek etkinliği, 0,996305 R^2 değeri ve 0,03158 RMSE içeren test sonuçlarıyla kanıtlanmıştır. Sonuçlar, yöntemin başarılı olduğunu göstermiştir.

Tablo 4.36: Basamaksız aşamasında ilk 15 günün sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0010014	0.031645	0.99625	1.00E-03	0.03162278	0.99629
2	0.0010491	0.03239	0.99609	1.10E-03	0.03316625	0.99601
3	0.0010839	0.032923	0.99594	1.10E-03	0.03316625	0.99591
4	0.00086659	0.029438	0.99676	8.62E-04	0.02935728	0.99676
5	0.00084591	0.029085	0.99682	8.26E-04	0.02874196	0.99692
6	0.0010266	0.032041	0.99613	1.10E-03	0.03316625	0.99611
7	0.0010063	0.031722	0.99621	1.00E-03	0.03162278	0.99618
8	0.00076042	0.027576	0.99714	8.20E-04	0.02862761	0.99697
9	0.001055	0.032481	0.99604	1.10E-03	0.03316625	0.99605
10	0.0011114	0.033338	0.99586	1.10E-03	0.03316625	0.99585
Ortalama	**0.000980662**	**0.031264**	**0.996324**	**1.00E-03**	**0.03158036**	**0.996305**

Basamaksız aşamanın bir ay, sinir ağı yoluyla test ve eğitim hedeflerini gerçekleştirmek için 10 iterasyon gerçekleştirilmiştir. Tablo 4.37'da bu döngülerin sonuçları gösterilmektedir. İterasyonlar arasında küçük farklılıklar olmasına rağmen, sonuçlar nispeten tutarlı kalmıştır. R^2 değerinin 0,997664 ve RMSE değerinin 0,045673 olması, eğitim sırasında takılan sinir ağının çok iyi performans gösterdiğini ortaya koymuştur. Test sonuçları, 0,997644 R^2 değeri ve 0,045683 RMSE ile yaklaşımın çok etkili olduğunu göstermiştir. Bulgulara dayanarak, çalışmaların verimli olduğu görülmüştür.

Tablo 4.37: Basamaksız aşamasında bir ayın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0020355	0.045117	0.99772	2.00E-03	0.04472136	0.99777
2	0.0019694	0.044378	0.9978	2.00E-03	0.04472136	0.99781
3	0.0023734	0.048718	0.99735	2.40E-03	0.04898979	0.99726
4	0.0020685	0.045481	0.99769	2.10E-03	0.04582576	0.99767
5	0.0019155	0.043766	0.99786	1.90E-03	0.04358899	0.99781
6	0.002376	0.048744	0.99735	2.40E-03	0.04898979	0.99728
7	0.0020639	0.04543	0.99769	2.00E-03	0.04472136	0.99772
8	0.002026	0.045011	0.99774	2.00E-03	0.04472136	0.99771
9	0.0020811	0.045619	0.99766	2.10E-03	0.04582576	0.99768
10	0.0019769	0.044462	0.99778	2.00E-03	0.04472136	0.99773
Ortalama	**0.00208862**	**0.045673**	**0.997664**	**2.09E-03**	**0.04568269**	**0.997644**

Basamaksız aşamanın iki ay boyunca, sinir ağı yoluyla test ve eğitim hedeflerine ulaşmak için toplam 10 iterasyon gerçekleştirilmiştir. Tablo 4.38'da bu döngülerin sonuçları sunulmaktadır. Sonuçlar iterasyonlar arasında küçük farklılıklar gösterse de büyük ölçüde tutarlı kalmıştır. Sinir ağı, 0,997299 R^2 değeri ve 0,063633 RMSE ile gösterildiği gibi eğitim sırasında yüksek performans sergilemiştir. Test sonuçları, 0,997303 R^2 değeri ve 0,063675 RMSE ile kanıtlandığı üzere yaklaşımın yüksek etkinlik gösterdiğini ortaya koymuştur. Bulgular, çalışmaların başarılı olduğunu göstermiştir.

Tablo 4.38: Basamaksız aşamasında iki ayın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0039832	0.063113	0.99735	4.00E-03	0.06324555	0.99733
2	0.0041543	0.064454	0.99723	4.20E-03	0.06480741	0.99724
3	0.0040626	0.063739	0.99729	4.00E-03	0.06324555	0.99731
4	0.0047276	0.068758	0.99683	4.80E-03	0.06928203	0.99689
5	0.0038528	0.062071	0.99743	3.80E-03	0.06164414	0.99747
6	0.0041679	0.064559	0.99722	4.10E-03	0.06403124	0.9973
7	0.0041662	0.064546	0.99724	4.10E-03	0.06403124	0.99724
8	0.0036864	0.060716	0.99755	3.70E-03	0.06082763	0.99753
9	0.0036466	0.060387	0.99757	3.70E-03	0.06082763	0.99753
10	0.0040944	0.063987	0.99728	4.20E-03	0.06480741	0.99719
Ortalama	**0.0040542**	**0.063633**	**0.997299**	**4.06E-03**	**0.06367498**	**0.997303**

Sinir ağı yoluyla test ve eğitim hedeflerine ulaşmak için basamaksız aşamanın üç ay boyunca toplam 10 iterasyon gerçekleştirilmiştir. Tablo 4.39, bu döngülerin sonuçlarını özetlemektedir. İterasyonlar arasındaki ufak değişikliklere rağmen sonuçlar esasen tutarlı olmuştur. Sinir ağı, 0,997672 R^2 değeri ve 0,069158 RMSE ile kanıtlandığı üzere eğitim sürecinde olağanüstü bir performans göstermiştir. Yaklaşımın yüksek etkinliği, verilerdeki 0,997678'lik R^2 değeri ve 0,069104'lük RMSE ile kanıtlandığı üzere test sonuçlarıyla ortaya konmuştur. Sonuçlar, uygulamaların verimli olduğunu göstermiştir.

Tablo 4.39: Basamaksız aşamasında üç ayın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0047753	0.069104	0.99767	4.80E-03	0.06928203	0.99768
2	0.0046977	0.06854	0.99771	4.70E-03	0.06855655	0.9977
3	0.0052132	0.072202	0.99747	5.20E-03	0.07211103	0.99748

Tablo 4.39 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
4	0.0046926	0.068503	0.99773	4.60E-03	0.0678233	0.99773
5	0.0046166	0.067946	0.99776	4.60E-03	0.0678233	0.99778
6	0.0046977	0.06854	0.99771	4.70E-03	0.06855655	0.99772
7	0.0042857	0.065465	0.99792	4.30E-03	0.06557439	0.99791
8	0.00457	0.067602	0.99778	4.60E-03	0.0678233	0.99778
9	0.0054074	0.073535	0.99737	5.40E-03	0.07348469	0.99737
10	0.0049207	0.070148	0.9976	4.90E-03	0.07	0.99763
Ortalama	**0.00478769**	**0.069158**	**0.997672**	**4.78E-03**	**0.06910351**	**0.997678**

Sinir ağı yoluyla test ve eğitim hedeflerine ulaşmak için, basamaksız aşamanın altı ay boyunca toplam 10 iterasyon yürütülmüştür. Bu döngülerin sonuçları Tablo 4.40'da sunulmuştur. Sonuçlar, iterasyonlar boyunca gözlemlenen sadece küçük farklılıklar ile dikkat çekici bir şekilde aynı olmuştur. Sinir ağı, eğitim süreci boyunca 0,996519 R^2 değeri ve 0,081845 RMSE ile vurgulanan olağanüstü bir performans sergilemiştir. Yaklaşımın dikkate değer etkinliği, verilerde 0,996493 R^2 değeri ve 0,081945 RMSE ile vurgulanan test sonuçları ile gösterilmiştir. Sonuçlar, yöntemin oldukça faydalı olduğunu göstermiştir.

Tablo 4.40: Basamaksız aşamasında altı ayın sinir ağının sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0069441	0.083331	0.99641	6.90E-03	0.08306624	0.99641
2	0.006171	0.078556	0.99681	6.20E-03	0.07874008	0.99678
3	0.0069208	0.083191	0.99643	6.90E-03	0.08306624	0.99639
4	0.0060702	0.077911	0.99687	6.10E-03	0.0781025	0.99679
5	0.0073374	0.085659	0.9962	7.40E-03	0.08602325	0.99617
6	0.0079758	0.089307	0.99587	8.00E-03	0.08944272	0.99586
7	0.006664	0.081633	0.99656	6.70E-03	0.08185353	0.9965
8	0.0054936	0.074119	0.99716	5.50E-03	0.07416198	0.99714
9	0.0084012	0.091658	0.99564	8.50E-03	0.09219544	0.99564
10	0.0053406	0.073079	0.99724	5.30E-03	0.0728011	0.99725
Ortalama	**0.00673187**	**0.081845**	**0.996519**	**6.75E-03**	**0.08194531**	**0.996493**

4.2.2.3. NARX

Bu aşamada veri kümesi yüzde yetmiş eğitim kümesi ve yüzde otuz test kümesi olarak ayrılmıştır. Analiz, basamaksız aşamanın ilk haftasında ve ardından ilk 15 gün boyunca

yapılmıştır. Daha sonra, çalışma bir ay boyunca ve ardından iki ay boyunca uygulanmıştır. Son olarak, analiz üç ay boyunca ve ardından altı ay boyunca yapılmıştır. Bu yöntemin amacı, zaman çizelgesini artırırken yöntemin verimliliğini araştırmaktır. Ayrıca, NARX her analiz zamanında farklı sonuçlar verebileceğinden, analiz her zaman çizelgesi için on kez yapılmış ve daha sonra ortalama sonuç bu yöntemin nihai sonucu olarak kabul edilmiştir.

Tablo 4.41, basamaksız aşamanın ilk haftasında gerçekleştirilen on NARX analizinden elde edilen sonuçları göstermektedir. Sonuçlar iterasyonlar arasında önemli ölçüde tutarlılık gösterirken değişiklikler gözlemlenmiştir. Eğitim aşaması sonuçları, yöntemin 0,013498 RMSE ve 0,99726 R^2 değerlerine ulaşarak olağanüstü bir performans sergilediğini göstermiştir. Ayrıca, R^2 değeri 0,99667 ve RMSE değeri 0,014803 olan test aşaması sonuçları, kullanılan yöntemin etkinliğini daha da kanıtlamıştır. Eğitim ve test aşamalarından elde edilen sonuçlar, tekniğin etkili olduğunu yansıtmıştır.

Tablo 4.41: Basamaksız aşamasında ilk haftanın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00017457	0.013212	0.9974	0.0002314	0.01521052	0.9965
2	0.00018977	0.013776	0.9972	0.0002069	0.01438437	0.9967
3	0.00019446	0.013945	0.9971	0.0001919	0.01385244	0.9971
4	0.00017378	0.013183	0.9973	0.0002309	0.01519605	0.9967
5	0.00018154	0.013474	0.9972	0.0002195	0.01481553	0.9969
6	0.00017484	0.013223	0.9974	0.0002537	0.01592765	0.9961
7	0.00017922	0.013387	0.9973	0.0002277	0.01508841	0.9965
8	0.0001863	0.013649	0.9972	0.0002023	0.01422428	0.9968
9	0.00018515	0.013607	0.9972	0.0002156	0.01468332	0.9967
10	0.0001828	0.01352	0.9973	0.0002146	0.01464923	0.9967
Ortalama	**0.000182243**	**0.013498**	**0.99726**	**0.0002194**	**0.01480318**	**0.99667**

Basamaksız aşamanın ilk 15 gününde gerçekleştirilen on NARX analizinin sonuçları Tablo 4.42'da sunulmuştur. Sonuçlar, iterasyonlar arasında yüksek derecede tutarlılık gösterirken, değişiklikler de gözlemlenmiştir. Teknik, 0,013167 RMSE ve 0,99935 R^2 ile kanıtlandığı üzere, eğitim aşamasında olağanüstü bir performans göstermiştir. Kullanılan yöntemin etkinliği, 0,99927 R^2 değeri ve 0,014031 RMSE ile karakterize edilen test aşaması sonuçlarıyla da ortaya konmuştur. Son olarak, tekniğin etkinliği eğitim ve test aşamalarının sonuçları ile desteklenmiştir.

Tablo 4.42: Basamaksız aşamasında ilk 15 günün NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0001714	0.013092	0.9994	0.0001979	0.01406912	0.9992
2	0.00017172	0.013104	0.9994	0.0002001	0.01414602	0.9993
3	0.00017188	0.01311	0.9994	0.0002001	0.01414426	0.9992
4	0.00017527	0.013239	0.9993	0.0001926	0.01387948	0.9993
5	0.00017378	0.013183	0.9993	0.0001932	0.01390072	0.9993
6	0.00017538	0.013243	0.9993	0.0001913	0.0138304	0.9993
7	0.00017991	0.013413	0.9993	0.0001907	0.01380833	0.9993
8	0.00017277	0.013144	0.9994	0.0001956	0.01398642	0.9993
9	0.00016685	0.012917	0.9994	0.0002162	0.01470204	0.9992
10	0.00017492	0.013226	0.9993	0.0001915	0.0138398	0.9993
Ortalama	**0.000173388**	**0.013167**	**0.99935**	**0.0001969**	**0.01403066**	**0.99927**

Tablo 4.43, basamaksız aşamanın bir ayının gerçekleştirilen on NARX analizinin sonuçlarını açıklamaktadır. Değişiklikler gözlemlenmiştir, ancak sonuçlar iterasyonlar arasında yüksek derecede tutarlılık sergilemiştir. Teknik, 0,01367 RMSE ve 0,9998 R^2 ile örneklendiği üzere, eğitim aşamasında olağanüstü bir performans sergilemiştir. R^2 değeri 0,9998 ve RMSE değeri 0,01381 olan test aşaması sonuçları, kullanılan yöntemin etkinliğini daha da kanıtlamıştır. Sonuç olarak, eğitim ve test bölümleri tekniğin etkinliğinin kanıtı olarak hizmet etmiştir.

Tablo 4.43: Basamaksız aşamasında bir ayın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00018426	0.013574	0.9998	0.000196	0.01399964	0.9998
2	0.00018688	0.01367	0.9998	0.0001899	0.01378042	0.9998
3	0.0001872	0.013682	0.9998	0.0001921	0.0138611	0.9998
4	0.00018334	0.01354	0.9998	0.0002	0.01414284	0.9998
5	0.00019382	0.013922	0.9998	0.0001756	0.01324953	0.9998
6	0.00018974	0.013775	0.9998	0.0001842	0.0135735	0.9998
7	0.00018948	0.013765	0.9998	0.0001843	0.01357608	0.9998
8	0.00018082	0.013447	0.9998	0.0002048	0.01430944	0.9998
9	0.0001905	0.013802	0.9998	0.0001821	0.01349481	0.9998
10	0.00018295	0.013526	0.9998	0.0001993	0.0141163	0.9998
Ortalama	**0.000186899**	**0.01367**	**0.9998**	**0.0001908**	**0.01381037**	**0.9998**

Tablo 4.44, basamaksız aşamanın iki ayında gerçekleştirilen on NARX analizinin sonuçlarını sunmaktadır. Gözlemler değişikliklere işaret etmiştir; ancak sonuçlar iterasyonlar arasında önemli düzeyde tutarlılık göstermiştir. Teknik, eğitim aşamasında 0,06463 RMSE ve 0,9998 R^2 ile kanıtlanan olağanüstü bir performans sergilemiştir. Test aşamasından elde edilen 0,9998 R^2 değeri ve 0,016631 RMSE ile karakterize edilen sonuçlar, kullanılan yöntemin etkinliğini güçlendirmiştir. Sonuç olarak, eğitim ve test bileşenleri tekniğin etkinliğini kanıtlamıştır.

Tablo 4.44: Basamaksız aşamasında iki ayın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00027212	0.016496	0.9998	0.0002688	0.01639604	0.9998
2	0.00027075	0.016454	0.9998	0.0002854	0.01689379	0.9998
3	0.00026734	0.016351	0.9998	0.0002805	0.01674813	0.9998
4	0.00026992	0.016429	0.9998	0.0002755	0.01659849	0.9998
5	0.00026639	0.016321	0.9998	0.0002841	0.01685497	0.9998
6	0.00027118	0.016468	0.9998	0.000275	0.01658312	0.9998
7	0.00027831	0.016683	0.9998	0.000259	0.01609441	0.9998
8	0.0002734	0.016535	0.9998	0.0002702	0.01643715	0.9998
9	0.00027338	0.016534	0.9998	0.0002717	0.01648241	0.9998
10	0.00026766	0.01636	0.9998	0.0002965	0.01721801	0.9998
Ortalama	**0.000271045**	**0.016463**	**0.9998**	**0.0002767**	**0.01663065**	**0.9998**

Basamaksız aşamanın üç ayında gerçekleştirilen on NARX analizinin sonuçları Tablo 4.45'te özetlenmiştir. Sonuçlar, gözlemlerin değişikliklere işaret etmesine rağmen iterasyonlar arasında önemli ölçüde tutarlılık göstermiştir. Teknik, 0,01641 RMSE ve 0,9998 R^2 ile kanıtlandığı üzere, eğitim aşamasında olağanüstü bir performans sergilemiştir. Kullanılan yöntemin etkinliği, 0,9998'lik bir R^2 değeri ve 0,016601'lik bir RMSE sergileyen test aşaması sonuçları ile daha da desteklenmiştir. Sonuç olarak, tekniğin etkinliği eğitim ve test bileşenleri tarafından gösterilmiştir.

Tablo 4.45: Basamaksız aşamasında üç ayın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00026679	0.016334	0.9998	0.0002819	0.01678839	0.9998
2	0.00026373	0.01624	0.9998	0.0002898	0.01702234	0.9998
3	0.00027069	0.016453	0.9998	0.0002655	0.01629448	0.9998

Tablo 4.45 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
4	0.00027248	0.016507	0.9998	0.0002731	0.01652604	0.9998
5	0.00027102	0.016463	0.9998	0.000272	0.01649182	0.9998
6	0.00027126	0.01647	0.9998	0.0002667	0.01633095	0.9998
7	0.00026615	0.016314	0.9998	0.0002822	0.0167994	0.9998
8	0.00027101	0.016462	0.9998	0.0002664	0.01632023	0.9998
9	0.00026952	0.016417	0.9998	0.000284	0.016852	0.9998
10	0.00027015	0.016436	0.9998	0.0002771	0.01664692	0.9998
Ortalama	**0.00026928**	**0.01641**	**0.9998**	**0.0002759**	**0.01660726**	**0.9998**

Tablo 4.46, basamaksız aşamanın altı ayında gerçekleştirilen 10 NARX analizinin bulgularını özetlemektedir. Değişikliklere işaret eden gözlemlere rağmen, bulgular iterasyonlar arasında yüksek düzeyde tutarlılık göstermiştir. RMSE'nin 0,020844 ve R^2'nin 0,9998 olması, yaklaşımın eğitim aşaması boyunca çok iyi performans gösterdiğini ortaya koymuştur. Test aşamasından elde edilen sonuçlar, 0,9998 R^2 ve 0,020831 RMSE ile yaklaşımın faydalı olduğuna dair daha fazla kanıt sağlamıştır. Sonuç olarak, eğitim ve test bölümleri yöntemin ne kadar başarılı olduğunu göstermiştir.

Tablo 4.46: Basamaksız aşamasında altı ayın NARX'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.00043362	0.020824	0.9998	0.0004378	0.02092415	0.9998
2	0.00043175	0.020779	0.9998	0.0004347	0.02084946	0.9998
3	0.00043426	0.020839	0.9998	0.0004335	0.02082066	0.9998
4	0.00043444	0.020843	0.9998	0.0004384	0.02093729	0.9998
5	0.0004346	0.020847	0.9998	0.000434	0.02083363	0.9998
6	0.00043628	0.020887	0.9998	0.0004263	0.02064728	0.9998
7	0.00043868	0.020945	0.9998	0.0004261	0.02064098	0.9998
8	0.00043653	0.020893	0.9998	0.0004332	0.02081418	0.9998
9	0.00043579	0.020876	0.9998	0.0004351	0.02085905	0.9998
10	0.00042883	0.020708	0.9998	0.0004404	0.02098666	0.9998
Ortalama	**0.000434478**	**0.020844**	**0.9998**	**0.000434**	**0.02083133**	**0.9998**

4.2.2.4. NARNN

Veri kümesi eğitim kümesi olarak yüzde yetmişe ve test kümesi olarak yüzde otuza bölünmüştür. Analiz, basamaksız aşamanın ilk haftasında ve ardından ilk 15 gün boyunca

yapılmıştır. Daha sonra, analiz bir aylık basamaksız aşama ve ardından iki ay boyunca kullanılmıştır. Son olarak, analiz üç aylık basamaksız aşamada ve daha sonra aşamanın altı ayı boyunca uygulanmıştır. Ayrıca, doğru sonuçlar elde etmek için analiz her bir zaman çizelgesi üzerinde on kez yapılmıştır.

Tablo 4.47,basamaksız aşamanın ilk haftasında gerçekleştirilen ve NARNN'ın kullanıldığı on zamanlı analizin sonuçlarını özetlemektedir. Analizler arasında çok az tutarsızlık vardır ancak her bir zaman analizinin sonuçları neredeyse aynı çıkmıştır. RMSE'nin 0,022005 ve R^2'nin 0,99266 olduğu eğitim aşaması sonuçlarının da gösterdiği gibi, yöntem son derece etkili olmuştur. Performansın kalitesinin göstergesi olan 0,022767'lik RMSE ve 0,99218'lik R^2 test aşamasının sonuçlarıdır. Öğretim ve test bölümlerinin sonuçları sonuçta prosedürün etkinliğini kanıtlamıştır.

Tablo 4.47: Basamaksız aşamanın ilk haftanın NARNN'ın sonuçları.

Analiz Sayısı	**MSE Eğitim**	**RMSE Eğitim**	**R^2 Eğitim**	**MSE Test**	**RMSE Test**	**R^2 Test**
1	0.00047881	0.021882	0.9928	0.0005041	0.02245306	0.9924
2	0.00049885	0.022335	0.9923	0.0005826	0.02413649	0.9915
3	0.00049329	0.02221	0.9923	0.0005248	0.02290786	0.9926
4	0.00050464	0.022464	0.9924	0.0005711	0.02389665	0.9912
5	0.000456	0.021354	0.993	0.0004688	0.02165064	0.9933
6	0.00048145	0.021942	0.9929	0.0005004	0.02236985	0.992
7	0.00045076	0.021231	0.9932	0.0004819	0.02195131	0.9927
8	0.00047602	0.021818	0.9928	0.0005155	0.02270507	0.9922
9	0.00047526	0.0218	0.993	0.0005292	0.02300326	0.9914
10	0.0005298	0.023017	0.9919	0.0005105	0.02259358	0.9925
Ortalama	0.000484488	0.022005	0.99266	0.0005189	0.02276678	0.99218

Tablo 4.48, basamaksız aşamanın ilk 15 gününde NARNN kullanılarak yapılan on zamanlı bir çalışmanın sonuçlarını göstermektedir. Çalışmalar arasında bazı küçük farklılıklar olsa da her bir zaman analizinin sonuçları çoğunlukla aynı olmuştur. RMSE'nin 0,03129 ve R^2'nin 0,99632 olduğu eğitim sonuçları, yöntemin çok iyi çalıştığını göstermiştir. Test kısmında R^2 değeri 0.99626 ve RMSE değeri 0.03165'tir. Sonuç olarak, eğitim ve test bölümlerinin sonuçları sürecin işe yaradığını göstermiştir.

Tablo 4.48: Basamaksız aşamanın ilk 15 günün NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.001	0.031623	0.9962	0.001	0.03162278	0.9964
2	0.001	0.031623	0.9961	0.0011	0.03316625	0.9961
3	0.00098053	0.031313	0.9963	0.0009839	0.03136782	0.9963
4	0.001	0.031623	0.9963	0.001	0.03162278	0.9961
5	0.001	0.031623	0.9964	0.001	0.03162278	0.9962
6	0.001	0.031623	0.9962	0.001	0.03162278	0.9963
7	0.00093787	0.030625	0.9965	0.0009777	0.03126756	0.9963
8	0.00091162	0.030193	0.9966	0.0009202	0.03033513	0.9965
9	0.001	0.031623	0.9962	0.0011	0.03316625	0.996
10	0.00096272	0.031028	0.9964	0.0009443	0.03072946	0.9964
Ortalama	**0.000979274**	**0.03129**	**0.99632**	**0.0010026**	**0.03165236**	**0.99626**

Basamaksız aşamanın bir ay için, NARNN'ın kullanıldığı on zamanlı bir araştırmanın sonuçları Tablo 4.49'da gösterilmiştir. Her bir zaman analizinin bulguları, aralarında birkaç küçük farklılık olmakla birlikte çoğunlukla tutarlıdır. Yöntemin etkinliği, 0,044597 RMSE ve 0,99777 R^2 gösteren eğitim sonuçlarıyla gösterilmiştir. Test bölümü, 0,99772 R^2 değeri ve 0,045039 RMSE değeri ile mükemmel performansı doğrulamıştır. Sonuç olarak yöntemin etkili olduğu test ve eğitim aşamalarının sonuçlarıyla gösterilmiştir.

Tablo 4.49: Basamaksız aşamanın bir ayın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0021	0.045826	0.9976	0.002	0.04472136	0.9977
2	0.002	0.044721	0.9978	0.002	0.04472136	0.9977
3	0.0021	0.045826	0.9977	0.0021	0.04582576	0.9977
4	0.0019	0.043589	0.9979	0.0019	0.04358899	0.9978
5	0.002	0.044721	0.9978	0.0022	0.04690416	0.9976
6	0.0019	0.043589	0.9978	0.0019	0.04358899	0.9978
7	0.0018	0.042426	0.998	0.0019	0.04358899	0.9979
8	0.0021	0.045826	0.9976	0.0022	0.04690416	0.9976
9	0.002	0.044721	0.9977	0.0021	0.04582576	0.9977
10	0.002	0.044721	0.9978	0.002	0.04472136	0.9977
Ortalama	**0.00199**	**0.044597**	**0.99777**	**0.00203**	**0.04503909**	**0.99772**

Basamaksız aşamanın iki ayda NARNN'ın kullanıldığı on zamanlı bir araştırmanın sonuçları Tablo 4.50'da sunulmuştur. Her bir zaman analizinin sonuçları arasında birkaç küçük farklılık olmasına rağmen, büyük ölçüde tutarlı olmuşlardır. Eğitim sonuçları, 0,061608'lik RMSE ve 0,99748'luk R^2 ile kanıtlandığı üzere yöntemin etkinliğini göstermiştir. R^2 değerinin 0,99742 ve RMSE değerinin 0,062009 olması test bölümünde de teyit edilmiş ve olağanüstü bir performansa işaret etmiştir. Son olarak, değerlendirme ve eğitim aşamalarının sonuçları prosedürün etkinliğini kanıtlamıştır.

Tablo 4.50: Basamaksız aşamanın iki ayın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.004	0.063246	0.9973	0.004	0.06324555	0.9973
2	0.0038	0.061644	0.9975	0.0039	0.06244998	0.9974
3	0.0035	0.059161	0.9977	0.0035	0.0591608	0.9977
4	0.0035	0.059161	0.9977	0.0036	0.06	0.9976
5	0.004	0.063246	0.9974	0.004	0.06324555	0.9973
6	0.0039	0.06245	0.9974	0.0038	0.06164414	0.9974
7	0.004	0.063246	0.9974	0.0041	0.06403124	0.9972
8	0.0033	0.057446	0.9978	0.0035	0.0591608	0.9977
9	0.0039	0.06245	0.9974	0.004	0.06324555	0.9974
10	0.0041	0.064031	0.9972	0.0042	0.06480741	0.9972
Ortalama	**0.0038**	**0.061608**	**0.99748**	**0.00386**	**0.0620991**	**0.99742**

Tablo 4.51, basamaksız aşamanın üç ayın NARNN kullanan on zamanlı bir araştırmanın bulgularını göstermektedir. Zaman analizlerinin bulguları, sadece küçük farklılıklarla çoğunlukla benzerlik göstermiştir. Eğitimden elde edilen sonuçlar, 0,067815 RMSE ve 0,99776 R^2 ile tekniğin başarılı olduğunu göstermiştir. Test bölümünün sonuçları, 0.99774 R^2 değeri ve 0.067975 RMSE değeri ile mükemmel performansı doğrulamıştır. Eğitim ve test aşamalarının sonuçları prosedürün etkinliğini kanıtlamıştır.

Tablo 4.51: Basamaksız aşamanın üç ayın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0048	0.069282	0.9977	0.0047	0.06855655	0.9977
2	0.0047	0.068557	0.9977	0.0047	0.06855655	0.9977
3	0.0041	0.064031	0.998	0.0041	0.06403124	0.998
4	0.004	0.063246	0.9981	0.0043	0.06557439	0.9979

Tablo 4.51 (devam):

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R2 Eğitim	MSE Test	RMSE Test	R2 Test
5	0.0053	0.072801	0.9974	0.0053	0.0728011	0.9974
6	0.0045	0.067082	0.9978	0.0045	0.06708204	0.9978
7	0.0044	0.066332	0.9979	0.0044	0.0663325	0.9979
8	0.0045	0.067082	0.9978	0.0045	0.06708204	0.9978
9	0.0043	0.065574	0.9979	0.0043	0.06557439	0.9979
10	0.0055	0.074162	0.9973	0.0055	0.07416198	0.9973
Ortalama	**0.00461**	**0.067815**	**0.99776**	**0.00463**	**0.06797528**	**0.99774**

Tablo 4.52, basamaksız aşamanın altı ayın NARNN'ın kullanıldığı on zamanlı bir araştırmanın sonuçlarını sunmaktadır. Zaman analizlerinin sonuçları, yalnızca küçük farklılıklarla birlikte, temelde tutarlı olmuştur. Yöntem, eğitim sonuçlarının gösterdiği gibi 0,081599'luk RMSE ve 0,99655'lik R^2 ile kanıtlandığı üzere başarılı olmuştur. Olağanüstü performans, 0,99652 R^2 değeri ve 0,081840 RMSE değeri gösteren test sonuçlarıyla doğrulanmıştır. Son olarak, prosedürün etkinliği eğitim ve test aşamalarının sonuçlarıyla kanıtlanmıştır.

Tablo 4.52: Basamaksız aşamanın altı ayın NARNN'ın sonuçları.

Analiz Sayısı	MSE Eğitim	RMSE Eğitim	R^2 Eğitim	MSE Test	RMSE Test	R^2 Test
1	0.0072	0.084853	0.9963	0.0072	0.08485281	0.9963
2	0.0064	0.08	0.9967	0.0064	0.08	0.9967
3	0.0056	0.074833	0.9971	0.0057	0.07549834	0.9971
4	0.0062	0.07874	0.9968	0.0063	0.07937254	0.9967
5	0.0052	0.072111	0.9973	0.0052	0.07211103	0.9973
6	0.0076	0.087178	0.9961	0.0076	0.08717798	0.9961
7	0.0067	0.081854	0.9966	0.0067	0.08185353	0.9965
8	0.0078	0.088318	0.996	0.0079	0.08888194	0.9959
9	0.0061	0.078102	0.9968	0.0061	0.0781025	0.9969
10	0.0081	0.09	0.9958	0.0082	0.09055385	0.9957
Ortalama	**0.00669**	**0.081599**	**0.99655**	**0.00673**	**0.08184045**	**0.99652**

4.3. İLERİYE TAHMİN

Çalışmada gerçekleştirilen analiz, uygulanan yük, sıcaklık ve bağıl nemin bir sonucu olarak betonarme kirişteki gerilme değerlerini tahmin etmeye ve etkinliklerini değerlendirmeye yöneliktir. Söz konusu analiz, uygulanan yükün tutarlı hale geldiği basamaksız aşamada gerçekleşmektedir. Ayrıca, süreçler üç farklı eğitim veri kümesi üzerinde kullanılmıştır. İlk eğitim veri kümesi bir haftalık verileri, ikinci veri kümesi altı haftalık verileri ve üçüncü eğitim veri kümesi üç aylık verileri içermektedir. Eğitimi alan üç grup, bir sonraki haftanın sonuçlarını tahmin etmek ve eğitim verilerinin büyüklüğüne bağlı olarak oluşabilecek farklılıkları karşılaştırmak için aynı tarih ve saatte eğitimi tamamlamıştır.

4.3.1. İstatistiksel Modeller

Otuz dört regresyon modeli, üç farklı eğitim veri kümesinde bir sonraki haftanın gerilme değerini tahmin etmek için kullanılmıştır.

Tablo 4.53'da bir sonraki haftanın değerlerini tahmin etmek için bir haftalık eğitim verilerine uygulanan eğitim ve test veri kümelerinin sonuçları gösterilmektedir. Eğitim aşamasında, Matern 5/2 GPR ve üstel GPR modelleri, 0,03073 RMSE ve 0,97408 R^2 değerleri ile en iyi performansı göstermiştir. Bununla birlikte, verimli doğrusal SVM ve güçlendirilmiş ağaçlar eğitim aşamasında negatif bir R^2 değeri sergilemiş, bu da test setinde negatif ve hatalı bir R^2 değeri ile sonuçlanmıştır. Test aşamasında, birkaç model tatmin edici R^2 değerleri sergilemiştir. En uygun değer, 0,11674 RMSE ve 0,87386 R^2 değeri veren sağlam doğrusal bir model kullanılarak elde edilirken, üstel GPR test sonuçları 0,18736 RMSE ve 0,67508 R^2 değeri göstermiştir. Sonuç olarak, karesel SVM, kübik SVM, optimize SVM, verimli doğrusal en küçük kareler, verimli doğrusal SVM, optimize verimli doğrusal, optimize çekerdik, güçlendirilmiş ağaçlar, orta sinir ağı, geniş sinir ağı ve çift katmanlı sinir ağı modelleri test aşaması boyunca yetersiz R^2 değerlerine sahip olmuştur.

Tablo 4.53: Bir haftalık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.087232	0.791168	0.12098103	0.864533
Doğrusal Etkileşimler	0.075551	0.843354	0.25685639	0.389369
Sağlam Doğrusal	0.087193	0.791356	0.11674047	0.873864

Tablo 4.53 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Kademeli Doğrusal	0.075607	0.843121	0.25692361	0.38905
İnce Ağaç	0.033731	0.968776	0.26480085	0.351012
Orta Ağaç	0.032411	0.971171	0.26210092	0.364179
Kaba Ağaç	0.035464	0.965485	0.26469868	0.351513
Optimize Ağaç	0.03233	0.971315	0.26199116	0.364711
Doğrusal SVM	0.08813	0.786846	0.11366185	0.880429
Karesel SVM	0.066272	0.879469	0.59884022	-2.3191
Kübik SVM	0.04405	0.946749	1.84744048	-30.5892
İnce Gauss SVM	0.031267	0.973171	0.32395211	0.028686
Orta Gauss SVM	0.042006	0.951574	0.25678198	0.389723
Kaba Gauss SVM	0.071784	0.858584	0.24409629	0.448532
Optimize SVM	0.045085	0.944215	1.32094154	-15.1497
Verimli Doğrusal En Küçük Kareler	0.189593	0.013517	0.3349546	-0.03841
Verimli Doğrusal SVM	0.192581	-0.01782	0.33966726	-0.06784
Optimize Verimli Doğrusal	0.189594	0.013516	0.3349546	-0.03841
Rasyonel Karesel GPR	0.030963	0.97369	0.26011238	0.37379
Kare Üstel GPR	0.031529	0.972719	0.32410424	0.027774
Matern 5/2 GPR	0.03073	0.974084	0.31296116	0.093477
Üstel GPR	0.030956	0.973702	0.18736482	0.675082
SVM Çekirdeği	0.036375	0.963689	0.32853465	0.001012
En Küçük Kareler Çekirdeği	0.038404	0.959524	0.30633662	0.131448
Optimize Çekirdek	0.035573	0.965272	0.33899524	-0.06362
Güçlendirilmiş Ağaçlar	1.793177	-87.2448	1.91176669	-32.8273
Torbalı Ağaçlar	0.030959	0.973696	0.26499523	0.350059

Tablo 4.53 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Optimize Topluluk	0.127004	0.557329	0.26663373	0.341997
Dar Sinir Ağı	0.087232	0.791168	0.18296134	0.690175
Orta Sinir Ağı	0.057465	0.909374	0.7483359	-4.18312
Geniş Sinir Ağı	0.039237	0.957748	0.78971534	-4.77217
Çift Katmanlı Sinir Ağı	0.069844	0.866126	0.76922638	-4.47654
Üç Katmanlı Sinir Ağı	0.050835	0.92908	0.28365173	0.255322
Optimize Sinir Ağı	0.107486	0.789069	0.1227822	0.86047

Tablo 4.54'da bir sonraki haftanın değerlerini tahmin etmek için altı haftanın eğitim verilerine uygulanan eğitim ve test veri kümelerinden elde edilen sonuçlar sunulmaktadır. Sonuçlar, torbalı ağaçlar ve üstel GPR modellerinin eğitim aşamasında en iyi sonucu verdiğini göstermiştir. Torbalı ağaçlar modeli 0,02403 RMSE ve 0,99561 R^2 değerine sahipken, üstel GPR model 0,02607 RMSE ve 0,99483 R^2 değerine sahip olmuştur. Buna rağmen verimli doğrusal SVM, güçlendirilmiş ağaçlar ve optimize sinir ağı eğitim aşamasında negatif bir R^2 değeri göstermiş, bu da sonuç olarak test setinde negatif ve hatalı bir R^2 değerine yol açmıştır. Test aşaması boyunca, çeşitli modeller övgüye değer R^2 değerleri göstermiştir. Rasyonel karesel GPR modelin uygulanmasıyla en uygun değere ulaşılmış, bu da 0,14698'lik RMSE ve 0,79267'lik R^2 ile sonuçlanırken, üstel GPR testi 0,15979'luk bir RMSE ve 0,76369'luk bir R^2 üretmiştir. Sonuç olarak, karesel SVM, kübik SVM, verimli doğrusal en küçük kareler, verimli doğrusal SVM, optimize verimli doğrusal, SVM çekirdeği, güçlendirilmiş ağaçlar, dar sinir ağı, geniş sinir ağı ve optimize sinir ağı modelleri test aşamasında yetersiz R2 değerleri sergilemiştir.

Tablo 4.54: Altı haftalık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.151238	0.825979	0.20140966	0.624545
Doğrusal Etkileşimler	0.121593	0.887514	0.22660515	0.524733
Sağlam Doğrusal	0.16261	0.798824	0.29390441	0.200516

Tablo 4.54 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Kademeli Doğrusal	0.121586	0.887528	0.22659536	0.524774
İnce Ağaç	0.026746	0.994557	0.18825862	0.671975
Orta Ağaç	0.026928	0.994483	0.18994711	0.666064
Kaba Ağaç	0.030894	0.992739	0.18643084	0.678313
Optimize Ağaç	0.026362	0.994713	0.18909758	0.669044
Doğrusal SVM	0.158727	0.808317	0.26879114	0.331306
Karesel SVM	0.107869	0.911474	0.59409374	-2.26669
Kübik SVM	0.083028	0.947552	0.5322533	-1.62201
İnce Gauss SVM	0.030583	0.992884	0.29374293	0.201394
Orta Gauss SVM	0.067447	0.96539	0.15073556	0.789705
Kaba Gauss SVM	0.120725	0.889115	0.31420924	0.086232
Optimize SVM	0.0312	0.992594	0.20278858	0.619386
Verimli Doğrusal En Küçük Kareler	0.3614	0.006299	0.38356833	-0.36171
Verimli Doğrusal SVM	0.363717	-0.00649	0.34237931	-0.08496
Optimize Verimli Doğrusal	0.3613998	0.006299	0.38356833	-0.36171
Rasyonel Karesel GPR	0.0265309	0.994645	0.14968457	0.792627
Kare Üstel GPR	0.036004	0.990138	0.30954167	0.113179
Matern 5/2 GPR	0.02715	0.994392	0.19476356	0.648914
Üstel GPR	0.0260734	0.994828	0.15978608	0.763693
SVM Çekirdeği	0.0583742	0.974075	0.4383309	-0.77829
En Küçük Kareler Çekirdeği	0.0647181	0.968134	0.16477463	0.748708
Optimize Çekirdek	0.0543322	0.977541	0.22379449	0.53645
Güçlendirilmiş Ağaçlar	1.7926753	-23.4502	1.94232259	-33.9173
Torbalı Ağaçlar	0.0240262	0.995608	0.17602289	0.713228

Tablo 4.54 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Optimize Topluluk	0.0499839	0.980992	0.21432215	0.57486
Dar Sinir Ağı	0.1512382	0.825979	0.41232638	-0.57355
Orta Sinir Ağı	0.0775342	0.954263	0.16474019	0.748813
Geniş Sinir Ağı	0.0613587	0.971356	0.41759835	-0.61404
Çift Katmanlı Sinir Ağı	0.1234528	0.884047	0.32813519	0.00344
Üç Katmanlı Sinir Ağı	0.0912286	0.93668	0.22194344	0.544087
Optimize Sinir Ağı	0.3625469	-1.93E-05	0.35283553	-0.15224

Tablo 4.55'da bir sonraki haftanın değerlerini tahmin etmek için üç aylık eğitim verileri üzerinden kullanılan eğitim ve test veri kümelerinden elde edilen sonuçlar gösterilmektedir. Bulgular, eğitim aşamasında en iyi performansı gösteren üstel GPR modelinin 0,02224'lük bir RMSE ve 0,99952'lik bir R^2 sergilediğini göstermiştir. Verimli doğrusal SVM, güçlendirilmiş ağaçlar, optimize topluluk ve optimize sinir ağı eğitim aşamasında negatif bir R^2 değeri sergilemiş, bu da test setinde negatif ve hatalı bir R^2 değeri ile sonuçlanmıştır. Test aşamasında, farklı modeller kayda değer R^2 değerleri sergilemiştir. En uygun değer, 0,13475 RMSE ve 0,83195 R^2 değeri veren çift katmanlı sinir ağı bir model kullanılarak elde edilmiştir. Buna karşılık, üstel GPR testi 0,16297'lik bir RMSE ve 0,79419'luk bir R^2 ile sonuçlanmıştır. Sonuç olarak, değerlendirilen 34 modelden 16'sı test aşamasında pozitif R^2 gösterirken, kalan modeller negatif R^2 değerleri sergilemiştir.

Tablo 4.55: Üç aylık regresyon eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Doğrusal	0.260769	0.934244	0.64547333	-2.85615
Doğrusal Etkileşimler	0.244168	0.942349	0.69841639	-3.51468
Sağlam Doğrusal	0.270206	0.929398	0.76795775	-4.45849
Kademeli Doğrusal	0.244162	0.942352	0.69865105	-3.51771
İnce Ağaç	0.024797	0.999405	0.23202113	0.501744

Tablo 4.55 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Ağaç	0.025486	0.999372	0.22603904	0.527105
Kaba Ağaç	0.033058	0.998943	0.21619901	0.567381
Optimize Ağaç	0.024727	0.999409	0.23108753	0.505745
Doğrusal SVM	0.271123	0.928911	0.74933273	-4.19693
Karesel SVM	0.159483	0.975402	0.22866247	0.516064
Kübik SVM	0.098717	0.990575	0.4825774	-1.15542
İnce Gauss SVM	0.065725	0.995822	0.76817204	-4.46154
Orta Gauss SVM	0.072251	0.994951	0.2697803	0.326375
Kaba Gauss SVM	0.140436	0.980927	0.16776853	0.739493
Optimize SVM	0.233834	0.94712	0.6531361	-2.94826
Verimli Doğrusal En Küçük Kareler	1.009592	0.014259	1.14253369	-11.0819
Verimli Doğrusal SVM	1.019111	-0.00442	0.99319267	-8.12987
Optimize Verimli Doğrusal	1.009592	0.014259	1.14253369	-11.0819
Rasyonel Karesel GPR	0.033186	0.998935	0.23232923	0.500419
Kare Üstel GPR	0.045813	0.99797	0.39762244	-0.46332
Matern 5/2 GPR	0.030509	0.9991	0.23116923	0.505396
Üstel GPR	0.022243	0.999522	0.16296843	0.794187
SVM Çekirdeği	0.078278	0.994074	0.36177058	-0.21134
En Küçük Kareler Çekirdeği	0.08202	0.993494	0.35040933	-0.13645
Optimize Çekirdek	0.078196	0.994087	0.31551002	0.078651
Güçlendirilmiş Ağaçlar	1.757424	-1.98661	1.94110089	-33.8734
Torbalı Ağaçlar	0.022749	0.9995	0.21613757	0.567627
Optimize Topluluk	1.016921	-2.58E-14	0.38626717	-0.38094
Dar Sinir Ağı	0.264202	0.932494	0.49208059	-1.24115

Tablo 4.55 (devam):

Model	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
Orta Sinir Ağı	0.136773	0.981909	0.17790125	0.707075
Geniş Sinir Ağı	0.076658	0.994317	0.23451578	0.490972
Çift Katmanlı Sinir Ağı	0.130347	0.983569	0.13474717	0.831951
Üç Katmanlı Sinir Ağı	0.121212	0.985791	0.31177105	0.100359
Optimize Sinir Ağı	1.016867	-3.43E-12	1.06613665	-9.52019

4.3.2. Sinir Ağı

Sinir ağı kullanılarak analiz on kez yapılmış ve daha sonra on kez yapılan analiz sonuçlarının ortalama değeri nihai sonuç olarak kabul edilmiştir. Kullanılan yöntemin performans verimliliğini değerlendirmek için nihai sonuç için RMSE ve R^2 hesaplanmıştır.

Bir sonraki haftanın değerlerini tahmin etmek için, Tablo 4.56'da bir hafta boyunca gerçekleştirilen sinir ağının eğitim ve test sonuçları gösterilmektedir. Sonuçlar, on zamanlı analizin eğitim sonuçlarının birkaç küçük tutarsızlık dışında neredeyse aynı olduğunu göstermiştir. Buna ek olarak, her bir analiz zamanının test RMSE'si, ara sıra farklılıklar olsa da karşılaştırılabilir sonuçlar vermiştir. Nihayetinde, eğitim aşamasının nihai sonuçları 0,036103 RMSE ve 0,982 R^2 ile tatmin edici bir performans göstermiştir. Buna karşılık, test sonuçları 0,235106 RMSE ve 0,488 R^2 olmuştur.

Tablo 4.56: Bir haftalık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.03674	0.98133	0.28519	
2	0.03619	0.98184	0.47770	
3	0.03619	0.98196	0.26458	
4	0.03619	0.98196	0.25475	
5	0.03493	0.98321	0.33719	
6	0.03521	0.98286	0.46701	
7	0.03768	0.98037	0.28965	
8	0.03592	0.98225	0.43382	
9	0.03606	0.98201	0.21071	
10	0.03592	0.98226	0.22978	
Nihai Sonuç	**0.036103**	**0.982005**	**0.235106**	**0.488052**

Tablo 4.57'da bir sonraki haftanın değerlerini tahmin etmek amacıyla altı hafta boyunca sinir ağının eğitilmesi ve test edilmesinin sonuçları sunulmaktadır. Bulgular, 10 analizin sonuçlarının benzer olduğunu, ancak küçük farklılıklar olduğunu göstermiştir. Ayrıca, her analiz dönemi için test RMSE'si karşılaştırılabilir bulgular sergilemiş, ancak zaman zaman farklılıklar göstermiştir. Eğitim aşamasının kesin sonuçları 0,05007 RMSE ve 0,990327 R^2 ile övgüye değer bir performans gösterirken, test sonuçları 0,14704 RMSE ve 0,799751 R^2 vermiştir.

Tablo 4.57: Altı haftalık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	**RMSE Eğitim**	**R^2 Eğitim**	**RMSE Test**	**R^2 Test**
1	0.05009	0.99032	0.20976	
2	0.04929	0.99066	0.14832	
3	0.04827	0.99102	0.12728	
4	0.04889	0.99079	0.16401	
5	0.04969	0.99047	0.21	
6	0.05128	0.98988	0.23896	
7	0.04909	0.99072	0.24759	
8	0.04979	0.99043	0.25059	
9	0.04899	0.99077	0.14283	
10	0.05532	0.98821	0.22271	
Nihai Sonuç	**0.05007**	**0.990327**	**0.14704**	**0.799751**

Tablo 4.58, bir sonraki haftanın değerlerini tahmin etmeyi amaçlayan ve üç ay boyunca yürütülen bir sinir ağı modelinin eğitim ve test sonuçlarını sunmaktadır. Bulgular, bazı farklılıklar gözlemlense de on analiz iterasyonunun sonuçlarının nispeten tutarlı olduğunu göstermiştir. Ayrıca, her bir analiz zamanının test RMSE'si, zaman zaman farklılıklar olsa da karşılaştırılabilir sonuçlar vermiştir. Sonuç olarak, eğitim aşamasının kesin sonuçları, 0,074415'lik bir RMSE ve 0,997301'lik bir R^2 ile kanıtlanan övgüye değer bir performansa işaret etmiştir. Buna karşılık, test sonuçları 0,114267'lik bir RMSE ve 0,879067'lik bir R^2 vermiştir.

Tablo 4.58: Üç aylık sinir ağının eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.07635	0.99716	0.22449	
2	0.07887	0.99698	0.20273	
3	0.07635	0.99716	0.22450	
4	0.07887	0.99698	0.20273	
5	0.07335	0.99738	0.19672	
6	0.07335	0.99738	0.19672	
7	0.06914	0.99768	0.15906	
8	0.07099	0.99755	0.17146	
9	0.07681	0.99713	0.13304	
10	0.07007	0.99761	0.09949	
Nihai Sonuç	**0.074415**	**0.997301**	**0.114267**	**0.879067**

4.3.3. NARX

NARX kullanılarak yapılan analiz on kez yapılmış ve daha sonra on kez yapılan analiz sonuçlarının ortalama değeri nihai test sonucu olarak kabul edilmiştir. Bu yöntemin performans verimliliğini değerlendirmek için RMSE ve R2 hesaplanmıştır.

Bir sonraki haftanın değerlerini tahmin etmek için, Tablo 4.59'da bir hafta boyunca gerçekleştirilen NARX eğitim ve test sonuçları gösterilmektedir. Sonuçlar, on zamanlı analizin eğitim sonuçlarının birkaç küçük tutarsızlık dışında neredeyse aynı olduğunu göstermiştir. Buna ek olarak, her bir analiz zamanının test RMSE'si, ara sıra farklılıklar olsa da karşılaştırılabilir sonuçlar vermiştir. Nihayetinde, eğitim aşamasının nihai sonuçları 0,057631 RMSE ve 0,987 R^2 ile tatmin edici bir performans göstermiştir. Buna karşılık, test sonuçları 0,205707 RMSE ve 0,608 R^2 olmuştur.

Tablo 4.59: Bir haftalık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.03049	0.98719	0.30773	
2	0.03068	0.98704	0.28178	
3	0.03035	0.98731	0.26401	
4	0.03056	0.98714	0.30332	
5	0.03056	0.98713	0.16186	
6	0.03055	0.98714	0.24083	

Tablo 4.59 (devam):

Analiz Sayısı	RMSE Eğitim	R2 Eğitim	RMSE Test	R2 Test
7	0.03043	0.98724	0.31289	
8	0.30199	0.98744	0.24454	
9	0.03035	0.98732	0.19079	
10	0.03035	0.98731	0.22226	
Nihai Sonuç	**0.057631**	**0.987226**	**0.205707**	**0.608081**

Tablo 4.60, bir sonraki haftanın değerlerini tahmin etmek için altı hafta boyunca gerçekleştirilen NARX işleminin eğitim ve test aşamalarından elde edilen sonuçları göstermektedir. Bulgular, yapılan on analizin sonuçlarının, bazı farklılıklar olsa da nispeten tutarlı olduğunu göstermiştir. Ayrıca, her bir analiz zamanı için test RMSE sonuçları, zaman zaman farklılıklar olsa da karşılaştırılabilir olmuştur. Eğitim aşamasından elde edilen sonuçlar 0,025454 RMSE ve 0,997513 R^2 değeri ile övgüye değer bir performans göstermiştir. Buna karşılık, test aşaması 0,140896'lık bir RMSE ve 0,816135'lik bir R^2 değeri vermiştir.

Tablo 4.60: Altı haftalık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.02546	0.99751	0.19672	
2	0.02518	0.99757	0.25807	
3	0.02546	0.99751	0.18303	
4	0.02548	0.99751	0.28125	
5	0.02549	0.9975	0.21401	
6	0.02565	0.99747	0.16971	
7	0.02567	0.99747	0.25534	
8	0.02518	0.99757	0.23173	
9	0.02549	0.99751	0.23324	
10	0.02548	0.99751	0.20049	
Nihai Sonuç	**0.025454**	**0.997513**	**0.140896**	**0.816135**

Tablo 4.61, bir sonraki haftanın değerlerini tahmin etmek için üç ay boyunca NARX'ın eğitme ve test etme sonuçlarını göstermektedir. Bulgular, 10 analizin sonuçlarının benzer olduğunu, ancak küçük farklılıklar olduğunu göstermiştir. Ayrıca, her bir çalışma dönemi için

test RMSE'si, zaman zaman tutarsızlıklar olsa da karşılaştırılabilir sonuçlar sergilemiştir. Eğitim aşamasının kesin bulguları, 0,020623 RMSE ve 0,999771 R^2 ile övgüye değer bir performans gösterirken, test sonuçları 0,139415 RMSE ve 0,823317 R^2 vermiştir.

Tablo 4.61: Üç aylık NARX'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	**RMSE Eğitim**	**R^2 Eğitim**	**RMSE Test**	**R^2 Test**
1	0.02161	0.99977	0.16643	
2	0.02159	0.99977	0.15362	
3	0.02159	0.99978	0.20000	
4	0.01187	0.99977	0.20248	
5	0.02161	0.99977	0.14832	
6	0.02159	0.99977	0.19261	
7	0.02161	0.99977	0.21119	
8	0.02161	0.99977	0.21633	
9	0.02159	0.99977	0.15937	
10	0.02156	0.99977	0.1833	
Nihai Sonuç	**0.020623**	**0.999771**	**0.139415**	**0.823317**

4.3.4. NARNN

NARNN kullanılarak analiz on kez yapılmış ve daha sonra on kez yapılan analiz sonuçlarının ortalama değeri nihai test sonucu olarak kabul edilmiştir. Bu yöntemin performans verimliliğini değerlendirmek için RMSE ve R^2 hesaplanmıştır.

Bir sonraki haftanın değerlerini tahmin etmek için, Tablo 4.62'da bir hafta boyunca gerçekleştirilen NARNN'ın eğitim ve test sonuçları gösterilmektedir. Sonuçlar, on zamanlı analizin eğitim sonuçlarının birkaç küçük tutarsızlık dışında neredeyse aynı olduğunu göstermiştir. Buna ek olarak, her bir analiz zamanının test RMSE'si, ara sıra farklılıklar olsa da karşılaştırılabilir sonuçlar vermiştir. Nihayetinde, eğitim aşamasının nihai sonuçları 0,03586 RMSE ve 0,982252 R^2 ile tatmin edici bir performans göstermiştir. Buna karşılık, test sonuçları 0,25297 RMSE ve 0,407296 R^2 olmuştur.

Tablo 4.62: Bir haftalık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.03647	0.9816	0.25709	
2	0.03493	0.98322	0.22226	
3	0.03592	0.98223	0.46119	
4	0.03493	0.9832	0.43417	
5	0.03564	0.98245	0.31209	
6	0.03701	0.98113	0.23579	
7	0.03661	0.98152	0.27185	
8	0.03521	0.98289	0.31953	
9	0.03564	0.98243	0.23749	
10	0.03619	0.98185	0.24062	
Nihai Sonuç	**0.035855**	**0.982252**	**0.25297**	**0.407296**

Tablo 4.63, bir sonraki haftanın değerlerini tahmin etmek için altı hafta boyunca gerçekleştirilen NARNN işleminin eğitim ve test sonuçlarını göstermektedir. Sonuçlar, bazı farklılıklar olsa da on analizin sonuçlarının benzer olduğunu göstermiştir. Her analiz zamanı için test RMSE sonuçları, zaman zaman farklılıklar olsa da karşılaştırılabilir olmuştur. Eğitim aşaması, 0,047981 RMSE ve 0,991134 R^2 ile olumlu sonuçlar vermiştir. Buna karşılık, test aşaması 0,168712 RMSE ve 0,736374 R^2 ile sonuçlanmıştır.

Tablo 4.63: Altı haftalık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	RMSE Eğitim	R^2 Eğitim	RMSE Test	R^2 Test
1	0.04959	0.99053	0.24474	
2	0.04806	0.99112	0.27749	
3	0.04701	0.9915	0.2076	
4	0.04754	0.99128	0.23238	
5	0.04827	0.99103	0.14213	
6	0.04827	0.99102	0.35384	
7	0.04785	0.99118	0.20273	
8	0.04669	0.9916	0.16912	
9	0.04868	0.99088	0.22561	
10	0.04785	0.9912	0.26134	
Nihai Sonuç	**0.047981**	**0.991134**	**0.168712**	**0.736374**

Tablo 4.64, bir sonraki haftanın değerlerini tahmin etmek için üç ay boyunca gerçekleştirilen NARNN işleminin eğitim ve test sonuçlarını göstermektedir. Bulgular, yapılan 10 analizin sonuçlarının benzer olduğunu, ancak küçük farklılıklar olduğunu göstermiştir. Ayrıca, her bir analiz dönemi için test RMSE'si karşılaştırılabilir bulgular sergilemiş, ancak zaman zaman farklılıklar göstermiştir. Eğitim aşamasının kesin sonuçları 0,067589 RMSE ve 0,99 R^2 ile övgüye değer bir performans gösterirken, test sonuçları 0,113823 RMSE ve 0,88 R^2 sergilemiştir.

Tablo 4.64: Üç aylık NARNN'ın eğitimi üzerinden ileriye bir haftalık verilerin tahmini.

Analiz Sayısı	**RMSE Eğitim**	**R^2 Eğitim**	**RMSE Test**	**R^2 Test**
1	0.06534	0.99793	0.27767	
2	0.06603	0.99788	0.31353	
3	0.06403	0.99801	0.35171	
4	0.06768	0.99777	0.15716	
5	0.06512	0.99794	0.24145	
6	0.07308	0.9974	0.19698	
7	0.07509	0.99725	0.22825	
8	0.06907	0.99768	0.23043	
9	0.06626	0.99787	0.17916	
10	0.06419	0.998	0.20785	
Nihai Sonuç	**0.067589**	**0.997773**	**0.113823**	**0.880006**

5. TARTIŞMA

Tez çalışmasında, dijital ikiz platformu için temel kabul edilen teknolojilerin birbirine bağlanması ve entegrasyonunu vurgulayarak projenin ömrü boyunca bir dijital ikiz modeli geliştirmiştir. Ayrıca yazar, projenin ömrü boyunca paydaş etkileşimlerini dikkate alarak inşaat projesinin her aşaması için farklı modeller tanımlamıştır. AlBalkhy ve diğ. (2024), yapılı çevre içinde DT'nin anlaşılması için sistematik bir çerçeve sağlamak üzere tasarlanmış bir DT modelini temsil etmiştir. Modelin beş temel bileşeni vardır: DT'nin tanımı ve yapısı, fiziksel katman, dijital katman, uygulama katmanı ve kullanıcı katmanı. Ancak model, teknolojilerin projenin ömrü boyunca DT uygulamasına nasıl entegre edileceğini açıklamamıştır.

Long ve diğ. (2024), inşaat sektöründe DT kullanımı için entegre bir çerçeve önermiştir. Çerçeve, yardımcı teknolojilerin DT uygulamasına nasıl katkıda bulunduğunu göstermiştir. DT uygulama sürecinin ilk adımında, veriyle ilgili teknolojiler fiziksel nesnelerden gerçek zamanlı veri toplayarak zemin hazırlamıştır. İkinci aşamada, DT'den elde edilen verilere dayalı görsel bir model oluşturulmasına yardımcı olmak için yüksek doğruluklu modelleme araçları kullanılmıştır. 3. aşamada, model tabanlı simülasyon teknolojileri DT'nin dijital modeller ve gerçek zamanlı veriler kullanarak çeşitli değerlendirme ve tahmin görevlerini yerine getirmesini sağlamıştır. Bu aşamaya kadar tez çalışmasıyla uyum gösterse de araştırma, paydaşların çerçevede kullanılan farklı teknolojilerle nasıl etkileşime girdiğini düzenlememiştir.

Jiang ve diğ. (2024) inşaat yönetimini senkronize süreçler aracılığıyla dönüştürmek için kapsamlı bir dijital ikiz tabanlı teknik çerçeve sunmuştur. Çerçeve, yatay senkronizasyon (H-Sync) ve dikey senkronizasyonu (V-Sync) içeren ortogonal olarak senkronize dijital ikiz (SDT) paradigmasını tanıtmıştır. Bu ikili strateji, inşaat süreci boyunca insan, makine, malzeme ve enerji kaynaklarının verimli bir şekilde koordine edilmesini garanti ederek çeşitli inşaat bileşenlerinin bir araya getirilmesini sağlamıştır. SDT konsepti, fiziksel ve dijital alanlar arasında anlık veri alışverişinin önemini vurgulamıştır. Bu entegrasyon, proje planlaması, kaynak tahsisi ve operasyonel verimliliğin artırılması için gerekli olan dinamik düzenleme ve bilgi aktarımını kolaylaştırmıştır. Çerçeve, karmaşık ve öngörülemeyen bina ortamlarında çabaları azaltmayı ve ödülleri artırmayı amaçlamıştır. SDT modeli, maliyet, kalite ve güvenlik

dahil olmak üzere birçok hedefi optimize etmek için IoT ve BIM gibi teknolojileri kullanmıştır. Çerçeve, mimarlar, mühendisler ve proje yöneticileri de dahil olmak üzere inşaat sektöründeki çeşitli oyuncular arasında karşılıklı bir anlayış geliştirmek için geliştirilmiştir. SDT konsepti, uyumlu bir dil ve sistematik bir metodoloji sunarak çeşitli disiplinler arasında iş birliği ve iletişimi geliştirmiştir. Bununla birlikte yazarlar, çeşitli dijital dönüşüm teknolojilerindeki paydaş ilişkilerini tanımlamakta yetersiz kalmıştır.

Su ve diğ. (2023), DT destekli bina yaşam döngüsü yönetimi için, sosyal konuların etkisini vurgularken çeşitli inşaat aşamalarını entegre eden eksiksiz bir "3 + 1" çerçevesi oluşturmuştur. Çerçeve, bina yaşam döngüsünün planlama, yapım, işletme, bakım ve yıkım gibi tüm aşamaları kapsamıştır. Bu çerçevedeki önemli bir gelişme, geleneksel fiziksel ve sanal alanlara ek olarak bir sosyal alanın da dahil edilmesidir. Bu değişiklik, politikalar, ekonomik durumlar ve çevresel kaygılar da dahil olmak üzere sosyal unsurların bina projeleri üzerindeki etkisini kabul etmiştir. Bu yaklaşım, bina yaşam döngüsü boyunca gerçek zamanlı veri toplama ve analizinin önemini vurgulamıştır. Ayrıca çerçeve, DT modelinden elde edilen verilerin karar alma süreçlerine rehberlik edebileceği bir geri bildirim döngüsü içermiştir. Ancak yazar, DT'nin bina projesinin her aşamasında uygulanmasını, Dijital İkiz çerçevesinde kullanılan teknolojileri ve teknolojiyi çevreleyen paydaş etkileşimlerini ana hatlarıyla belirtmeyi atlamıştır.

Alsakka ve diğ. (2024), gelişmiş yöntemler kullanarak şantiye dışı inşaatlarda üretim sürelerini tahmin etmek ve programlama yapmak için kapsamlı bir strateji sunmuştur. Kullanılan ana tahmin tekniği, doğrusal regresyon ve rastgele orman gibi geleneksel yaklaşımlara göre gelişmiş tahmin etkinliği nedeniyle seçilen bir sinir ağı algoritması olmuştur. Bu karar, özellikle hassas zaman tahmininin proje başarısı için çok önemli olduğu inşaat sektöründe uygulanmıştır. Sinir ağı modeli, 40 panelden oluşan farklı bir test veri setinin yanı sıra 172 duvar panelinden oluşan bir veri seti üzerinde eğitilmiştir. Bu sıkı eğitim süreci, modelin şantiye dışı inşaatta yaygın bir zorluk olan üretim süreçlerindeki öngörülemezliği yönetmek için iyi hazırlanmış olmasını garanti etmiştir. Tahmin yaklaşımının etkinliği ortalama mutlak hata (MAE) kullanılarak ölçülmüştür. Sinir ağı modeli, panel işlem sürelerini (PT) tahmin etmede 1,57 dakika ve çevrim süreleri (CT) için yaklaşık 3 dakika ortalama mutlak hataya ulaşmıştır. Yazarlar, bu çalışmada da kullanılan bir tahmin metodolojisi olan sinir ağını kullanmışlardır. Bununla birlikte, yazarlar performans değerlendirmesi için MAE kullanırken, bu çalışmada aynı amaçla RMSE ve R2 kullanılmıştır.

Pan ve Zhang (2021), önceki verilere dayanarak gelecekteki görev tamamlamalarını tahmin etmek için otoregresif entegre hareketli ortalama (ARIMA), dışsal girdili otoregresif entegre hareketli ortalama (ARIMAX), mevsimsel otoregresif entegre hareketli ortalama (SARIMA) ve dışsal faktörlü mevsimsel otoregresif entegre hareketli ortalama (SARIMAX) gibi birçok istatistiksel model kullanmıştır. Bu öngörü kapasitesi, bina projelerinde gelişmiş planlama ve kaynak dağılımını kolaylaştırmaktadır. Araştırma, ARIMAX'ın 2,635 RMSE ile en uygun sonuçları sağladığını göstermiştir. Pan ve Zhang (2021) modelin sonuçlarını değerlendirmek için sadece RMSE'ye dayanırken, bu çalışmadaki yazar modelin sonuçlarını değerlendirmek için daha doğru bir değerlendirme sağlayan RMSE ve R^2'ye dayanmaktadır.

ElArwady ve diğ. (2024), iki makine öğrenimi modeli kullanarak iç mekân termal konforunu tahmin etmek için kapsamlı bir metodoloji ortaya koymuştur. Facebook Prophet, zaman serisi verilerini tahmin etmek için tasarlanmıştır ve özellikle mevsimsel değişimleri ve eksik verileri yönetmede ustadır. Neural Prophet, Facebook Prophet'in sinir ağı işlevlerini entegre eden ve daha karmaşık veri modellerinin yakalanmasını sağlayan bir geliştirmesidir. Veriler, modellerin performansını etkili bir şekilde değerlendirmek için 80-20 oranıyla eğitim ve test setleri arasında bölünmüştür. Modeller MSE, MAE ve R^2 değerleri dahil olmak üzere çeşitli ölçütler kullanılarak değerlendirilmiştir. Neural Prophet, Facebook Prophet'e kıyasla daha düşük MSE ve MAE değerleri ve daha yüksek R^2 değerleri ile gösterildiği gibi Facebook Prophet'ten biraz daha iyi performans göstermiştir. Bu, termal konforu tahmin etmede iyi olduğunu göstermektedir. Araştırma, bu tahmin modellerinin DT çerçevesine dahil edilmesinin iç ortamların izlenmesini ve yönetimini önemli ölçüde geliştirdiğini ve dolayısıyla yolcu konforunu artırdığını belirlemiştir. Yazarlar, iç mekân termal konforunu tahmin etmek için bu araştırmada kullanılanlara kıyasla farklı yöntemler kullanmışlardır; ancak performans değerlendirme ölçütleri aynı kalmıştır.

6. SONUÇ VE ÖNERİLER

Tez çalışmasında, inşaat projelerinde DT'lerin kullanımına yönelik net bir çerçeve oluşturulması amaçlanmıştır. Yazar, DT teknolojisinin daha iyi anlaşılmasına, diğer sektörlerdeki kullanımından elde edilen kavramlardan yararlanılmasına ve inşaat sektöründe DT ile ilgili mevcut literatürün kapsamlı bir değerlendirmesinin yapılmasına dayalı olarak inşaat sektöründe DT modelleri oluşturmuştur. Oluşturulan modeli doğrulamak için yazar, oluşturulan modelleri ve ilgili soruları içeren bir anket düzenlemiştir. İnşaat sektöründe DT modelleri için nihai formül, geliştirilen modellerin anket katılımcılarından gelen yorum ve fikirlerle karşılaştırılmasıyla elde edilmiştir.

Üretilen modeller, inşaat sektörü için gelecekte uygulanmak üzere bir DT çerçevesi oluşturmayı amaçlamıştır. Analiz, DT'nin çeşitli teknolojiler aracılığıyla geliştirilebileceğini göstermektedir. Sensörler, uzun menzilli telsiz, insansız hava araçlarıyla görüntü tarama, lazer tarama nokta bulutları, mobil tarayıcılar, dronlar ve robotlar dahil olmak üzere IoT teknikleri, inşaat sektöründeki DT uygulamalarında veri toplama için kritik teknolojilerdir. GIS, inşaat projelerinde DT için veri toplama yöntemi olarak da kullanılabilir. Ayrıca, BIM veri toplama ve entegrasyon için hayati bir kaynak olarak kabul edilmektedir.

Hibrit genetik algoritmalar, benzetilmiş tavlama algoritmaları, Bayesian ağları, çok katmanlı perceptron yapay sinir ağları, derin öğrenme algoritmaları, destek vektör makineleri, regresyon algoritmaları, makine öğrenimi algoritmaları, model öngörücü kontrol algoritmaları ve diğer AI araçları ve algoritmaları, potansiyel sorunları öngörmek, iş akışlarını geliştirmek ve inşaat sektöründeki DT çerçevelerinde karar verme süreçlerini iyileştirmek için kullanılabilir. VR, AR ve MR dahil olmak üzere XR teknolojileri, fiziksel ve sanal alemleri entegre ederek gerçeklik algısını artırmak için kullanılacaktır.

Tez çalışması, inşaat projelerinin karmaşıklığının DT'nin uygulanmasının önündeki başlıca engeller olarak görüldüğünü göstermiştir. Ayrıca, inşaat sektöründe DT'nin anlaşılmaması, sektörde DT'nin uygulanmasının ertelenmesinde büyük rol oynamaktadır. Aynı zamanda, DT teknolojilerinin yüksek maliyetleri, inşaat şirketlerini bu teknolojiyi projelerinde uygulamaya teşvik etmemektedir.

Ayrıca, makine öğrenimi ve derin öğrenme algoritmalarının kullanımı, paydaşlara proje yaşam döngüsünün tüm aşamalarında tahmin analitiği sunarak inşaat sektöründe DT içinde önemli bir umut vaat etmiştir.

İki ayrı aşamada yürütülen örnek kiriş çalışmasının ikinci bileşeni, bu çalışmada kullanılan algoritmaların tahmin için etkinliğini değerlendirmekti. Yüklemelerin yapıldığı aşama sırasında, aşamanın her haftası ve altı haftalık sürenin tamamı için ayrı ayrı çalıştırılan bazı regresyon modelleri haricinde, algoritmaların çoğu iyi bir verimlilik göstermiştir. Ayrıca, üstel GPR modeli, bu çalışmaya dahil edilen regresyon modelleri arasında en başarılı model olduğunu kanıtlamış ve haftalar boyunca yapılan analizlerde üstün RMSE ve R^2 sonuçları göstermiştir. Ayrıca, sinir ağı, NARX ve NARNN, basamaklı aşama boyunca 0,97'den az olmayan bir R^2 değeri elde ederek olağanüstü performans göstermiştir. Sonuç olarak, bu analiz adımından elde edilen bulgular, modellerin toplam veri setinin yüzde yetmişi üzerinde eğitilmiş olan test veri setinin yüzde otuzu için değerleri verimli bir şekilde tahmin etme kapasitesini göstermiştir.

Örnek kiriş çalışmasındaki yükün sabit kaldığı aşama sırasında, çalışma veri seti genişledikçe performans verimliliğini değerlendirmek için bir haftadan altı aya kadar değişen çeşitli zaman ölçeklerinde yürütülen bazı regresyon modelleri hariç, algoritmaların çoğu iyi verimlilik göstermiştir. Ayrıca, üstel GPR modeli, bu çalışmada kullanılan regresyon modelleri arasında en başarılı model olduğunu kanıtlamış ve çeşitli veri kümelerinde üstün RMSE ve R^2 sonuçları sergilemiştir. Ayrıca, sinir ağı, NARX ve NARNN, 0,99 R^2 değerine ulaşarak yükün sabit kaldığı aşamada olağanüstü performans göstermiştir. Sonuç olarak, bu analiz aşamasının bulguları, genel veri kümesinin yüzde yetmişi üzerinde eğitilen modellerin, test veri kümesinin yüzde otuzu için değerleri verimli bir şekilde tahmin edebildiğini göstermiştir.

Bulguların son bölümünde ise örnek kiriş verileri, bir haftalık, altı haftalık ve üç aylık veri kümeleri kullanılarak bir sonraki hafta için yapılan tahmin sonuçları sunulmuştur. Bulgular, eğitim veri kümesi boyutunun artırılmasıyla tahmin sonuçlarının kesinliğinin arttığını göstermiştir. Üstel GPR doğruluğu, eğitim veri setinin genişletilmesiyle artmıştır. Bununla birlikte, her eğitim dönemi sırasında, birkaç regresyon modeli tutarlı bir mükemmellikten yoksunken olağanüstü performans göstermiştir. Sonuç olarak, üstel GPR'nin sonuçları regresyon modelleri arasında en hassas olanı olarak kabul edilmiştir.

Çeşitli metodolojiler karşılaştırıldığında, üstel GPR, 0,67508'lik bir R^2 ile gösterildiği üzere, sinir ağı, NARX ve NARNN'ın bir sonraki haftanın değerlerini tahmin etmek için bir haftalık veri kümesi üzerinde eğitilmesine göre daha iyi sonuçlar göstermiştir. Eğitmek için altı haftalık bir veri seti kullanan NARX, 0,816135 R^2 değeri elde ederek üstel GPR, sinir ağı ve NARNN modellerine göre geleceği tahmin etmede daha iyi bir iş çıkarmıştır. Ayrıca, sinir ağı ve NARNN, üç aylık bir veri kümesi üzerinde eğitildiğinde, sinir ağı için 0,879067 ve NARNN için 0,880006 R^2 değerleri ile üstel GPR ve NARX'a kıyasla gelecek haftanın değerlerini tahmin etmede daha iyi bir iş çıkarmıştır. Sonuç olarak, eğitim veri setinin artırılması tahmin sonuçlarının doğruluğunu artırabilir. Nihayetinde, elde edilen tahmin sonuçları doğruluk açısından yetersiz kabul edilebilir; bu nedenle, eğitim veri kümesi boyutunun artırılması ve uygulanan yük, sıcaklık ve bağıl nemin ötesinde gerilme değerini etkileyebilecek ek faktörlerin dahil edilmesi sonuç doğruluğunu artırabilir.

Bu tez çalışmasında oluşturulan model, inşaat sektörü alanında daha kapsamlı bir DT modeli oluşturmak için iyi bir başlangıç olabilmektedir. Bu nedenle yazar, inşaat sektöründe DT modelini geliştirmek için sonraki çalışmaları mevcut çalışmada oluşturulan modelden yola çıkmaya teşvik etmektedir. Ayrıca yazar, gelecekteki çalışmalara DT çerçevesini geliştirmeye yardımcı olabilecek diğer makine öğrenimi yöntemlerinin ve algoritmalarının denenmesini önermektedir.

KAYNAKLAR

Agostinelli, S., Cumo, F., Guidi, G. and Tomazzoli, C., 2021, Cyber-physical systems improving building energy management: Digital twin and artificial intelligence, *Energies*, 14(8), 2338. doi: 10.3390/en14082338.

Akanbi, T. and Zhang, J., 2021, Design information extraction from construction specifications to support cost estimation, *Automation in construction*, 131, 103835. doi: https://doi.org/10.1016/j.autcon.2021.103835.

Akanmu, A.A., Anumba, C.J. and Ogunseiju, O.O., 2021, Towards next generation cyber-physical systems and digital twins for construction, *Journal of information technology in construction*, 26, 505-525. doi: 10.36680/j.itcon.2021.027.

Akhtar, A. and Sarmah, A.K. 2018, Construction and demolition waste generation and properties of recycled aggregate concrete: A global perspective, *Journal of cleaner production*, 186, 262-281. doi: https://doi.org/10.1016/j.jclepro.2018.03.085.

AlBalkhy, W., Karmaoui, D., Ducoulombier, L., Lafhaj, Z. and Linner, T., 2024, Digital twins in the built environment: Definition, applications, and challenges, *Automation in construction*, 162, 105368

Alizadehsalehi, S. and Yitmen, I., 2023, Digital twin-based progress monitoring management model through reality capture to extended reality technologies (DRX), *Smart and sustainable built environment*, 12(1), 200-236. doi: 10.1108/SASBE-01-2021-0016.

Alsakka, F., Yu, H., El-Chami, I., Hamzeh, F. and Al-Hussein, M., 2024, Digital twin for production estimation, scheduling and real-time monitoring in offsite construction, *Computers & industrial engineering*, 191, 110173.

Ammar, A., Nassereddine, H., AbdulBaky, N., AbouKansour, A., Tannoury, J., Urban, H. and Schranz, C., 2022, Digital twins in the construction industry: A perspective of practitioners and building authority, *Frontiers in built environment*, 8, 834671.

Anderl, R., Haag, S., Schützer, K. and Zancul, E., 2018, Digital twin technology – An approach for industrie 4.0 vertical and horizontal lifecycle integration, *IT - information technology*, 60(3), 125-132. doi: 10.1515/itit-2017-0038.

Angjeliu, G., Coronelli, D. and Cardani, G., 2020, Development of the simulation model for digital twin applications in historical masonry buildings: The integration between numerical and experimental reality, *Computers & structures*, 238, 106282. doi: 10.1016/j.compstruc.2020.106282.

Antonino, M., Nicola, M., Claudio, D.M., Luciano, B. and Fulvio, R.C., 2019, Office building occupancy monitoring through image recognition sensors, *International journal of safety and security engineering*, 9(3), 371-380. doi: 10.2495/SAFE-V9-N4-371-380.

Arrichiello, V. and Gualeni, P., 2020, Systems engineering and digital twin: A vision for the future of cruise ships design, production and operations, *International journal on interactive design and manufacturing (IJIDeM)*, 14, 115-122.

Attaran, M., 2017, The internet of things: Limitless opportunities for business and society, *Journal of strategic innovation and sustainability*, 12(1), 11.

Attaran, M. and Celik, B.G., 2023, Digital Twin: Benefits, use cases, challenges, and opportunities. *Decision analytics journal*, 6, 100165.

Bacher, U., 2022, Hybrid aerial sensor data as basis for a geospatial digital twin, *The international archives of the photogrammetry, remote sensing and spatial information sciences*, 43, 653-659.

Baker, H., Hallowell, M.R. and Tixier, A.J.-P., 2020, Automatically learning construction injury precursors from text, *Automation in construction*, 118, 103145. doi: 10.1016/j.autcon.2020.103145.

Bakhshi, S., Chenaghlou, M.R., Pour Rahimian, F., Edwards, D.J. and Dawood, N., 2022, Integrated BIM and DfMA parametric and algorithmic design based collaboration for supporting client engagement within offsite construction, *Automation in construction*, 133, 104015. doi: https://doi.org/10.1016/j.autcon.2021.104015.

Bambura, R., Šolc, M., Dado, M. and Kotek, L., 2020, Implementation of digital twin for engine block manufacturing processes, *Applied sciences*, 10(18), 6578. https://www.mdpi.com/2076-3417/10/18/6578.

Bao, Z., Laovisutthichai, V., Tan, T., Wang, Q. and Lu, W., 2022, Design for manufacture and assembly (DfMA) enablers for offsite interior design and construction, *Building research & information*, 50(3), 325-338. doi: 10.1080/09613218.2021.1966734.

Benachio, G.L.F., Freitas, M. do C.D. and Tavares, S.F., 2020, Circular economy in the construction industry: A systematic literature review, *Journal of cleaner production*, 260, 121046. doi: 10.1016/j.jclepro.2020.121046.

Bilberg, A. and Malik, A.A., 2019, Digital twin driven human–robot collaborative assembly, *CIRP annals*, 68(1), 499-502

Blomkvist, Y. and Ullemar Loenbom, L.E.O., 2020, *Improving supply chain visibility within logistics by implementing a digital twin: A case study at scania logistics*, Thesis (Master), KTH Royal Instıtute Of Technology.

Bocullo, V., Martišauskas, L., Gatautis, R., Vonžudaitė, O., Bakas, R., Milčius, D., Venčaitis, R., and Pupeikis, D., 2023, A digital twin approach to city block renovation using RES technologies, *Sustainability*, 15(12), 9307. doi: 10.3390/su15129307.

Boje, C., Guerriero, A., Kubicki, S. and Rezgui, Y., 2020, Towards a semantic construction digital twin: Directions for future research, *Automation in construction*, 114, 103179.

Bolton, A., Butler, L., Dabson, I., Enzer, M., Evans, M., Fenemore, T., Harradence, F., Keaney, E., Kemp, A., Luck, A. and Pawsey, N., 2018, Gemini Principles.

Borth, M., Verriet, J. and Muller, G., 2019, Digital twin strategies for SoS 4 challenges and 4 architecture setups for digital twins of SoS. *14th annual conference system of systems engineering (SoSE)*, 2019 Anchorage, Alaska, USA, IEEE, 164-169.

Bortolini, R., Rodrigues, R., Alavi, H., Vecchia, L.F.D. and Forcada, N., 2022, Digital twins' applications for building energy efficiency: A review, *Energies,* 15(19), 7002. doi: 10.3390/en15197002.

Boschert, S. and Rosen, R., 2016. *Digital twin—the simulation aspect*, Mechatronic futures, In: Hehenberger, P., Bradley, D. (eds.), Springer, Cham, Singapore, 59-74.

Bradley, D. and Hehenberger, P., 2016, *Mechatronic futures*, Mechatronic Futures, In: Hehenberger, P., Bradley, D. (eds.), Springer, Cham, Singapore, 1-15.

Broo, D.G. and Schooling, J., 2023, Digital twins in infrastructure: Definitions, current practices, challenges and strategies, *International journal of construction management,* 23(7), 1254-1263.

Cai, H., Zhang, W. and Zhu, Z., 2019, Quality management and analysis of aircraft final assembly based on digital twin. *11th international conference on intelligent human-machine systems and cybernetics (IHMSC)*, 2019 Hangzhou, China, IEEE, 202-205. https://ieeexplore.ieee.org/document/8941382/.

Cai, H., Zhu, J. and Zhang, W., 2021, Quality deviation control for aircraft using digital twin, *Journal of computing and information science in engineering,* 21(3).

Canedo, A., 2016, Industrial IoT lifecycle via digital twins, *Proceedings of the eleventh IEEE/ACM/IFIP international conference on hardware/software codesign and system synthesis*, October 2016 Pittsburgh, Pennsylvania, USA, Arquimedes Canedo, 1-1.

Carbonera, L.F.B., Pinheiro Bernardon, D., de Castro Karnikowski, D. and Alberto Farret, F., 2021, The nonlinear autoregressive network with exogenous inputs (NARX) neural network to damp power system oscillations, *International transactions on electrical energy systems,* 31(1), e12538-e12538. doi: 10.1002/2050-7038.12538.

Chang, X., Jia, X., Liu, K. and Hu, H., 2021, Knowledge-enabled digital twin for smart designing of aircraft assembly line, *Assembly automation,* 41(4), 441-456.

Chen, X., Zhu, Y., Chen, H., Ouyang, Y., Luo, X. and Wu, X., 2021, BIM-based optimization of camera placement for indoor construction monitoring considering the construction schedule, *Automation in construction,* 130, 103825.

Cheng, C.-W., Sheu, G.-T., Chou, J.-S., Wang, P.-H., Cheng, Y.-C. and Lai, C.-Y., 2021, Fine particulate matter PM2.5 generated by building demolition increases the malignancy of breast cancer MDA-MB-231 cells, *Chemosphere,* 265, 129028.

Chryssolouris, G., Mavrikios, D., Papakostas, N., Mourtzis, D., Michalos, G. and Georgoulias, K., 2009, Digital manufacturing: History, perspectives, and outlook, *Proceedings of the institution of mechanical engineers, Part B: journal of engineering manufacture,* 223(5), 451-462.

Clack, C.D., Bakshi, V.A. and Braine, L., 2016, Smart contract templates: Foundations, design landscape and research directions, *arxiv preprint arxiv:1608.00771*.

Clausen, A., Arendt, K., Johansen, A., Sangogboye, F.C., Kjærgaard, M.B., Veje, C.T. and Jørgensen, B.N., 2021, A digital twin framework for improving energy efficiency and occupant comfort in public and commercial buildings, *Energy informatics*, 4(S2), 40. doi: 10.1186/s42162-021-00153-9.

da Costa Lopes, F., Watanabe, E.H. and Rolim, L.G.B., 2015, A control-oriented model of a PEM fuel cell stack based on NARX and NOE neural networks, *IEEE transactions on industrial electronics*, 62(8), 5155-5163.

Damcı, E., Şekerci, Ç., Samav, S., Pektaş, H., Nur Özbek, funda, Üçüncü, Ş. and Ünlü, A., 2017, Short and long-term measurement of deformations at structural elements with arduino development board and sensors, *2nd International congress on engineering and technology sciences*, 22-25 December 2017 Afyon, Turkey, 15.

Dave, B., Kubler, S., Främling, K. and Koskela, L., 2016, Opportunities for enhanced lean construction management using internet of things standards, *Automation in construction*, 61, 86-97. https://linkinghub.elsevier.com/retrieve/pii/S0926580515002149.

Demartini, M., Galluccio, F., Mattis, P., Abusohyon, I., Lepratti, R. and Tonelli, F., 2019, Closed-loop manufacturing for aerospace ındustry: An integrated PLM-MOM solution to support the wing box assembly process. *IFIP international conference on advances in production management systems (APMS)*, 1-5 September 2019 Austin, TX, United States, Springer International Publishing, 423-430.

Deng, T., Zhang, K. and Shen, Z.-J.M., 2021, A systematic review of a digital twin city: A new pattern of urban governance toward smart cities, *Journal of management science and engineering*, 6(2), 125-134.

Diaconescu, E., 2008, The use of NARX neural networks to predict chaotic time series, *Wseas transactions on computer research*, 3(3), 182-191.

Döllner, J., 2020, Geospatial artificial intelligence: Potentials of machine learning for 3D point clouds and geospatial digital twins, *PFG–journal of photogrammetry, remote sensing and geoinformation science*, 88, 15-24.

ElArwady, Z., Kandil, A., Afiffy, M. and Marzouk, M., 2024, Modeling indoor thermal comfort in buildings using digital twin and machine learning, *Developments in the built environment*, 19, 100480.

Elfarri, E.M., Rasheed, A. and San, O., 2023, Artificial ıntelligence-driven digital twin of a modern house demonstrated in virtual reality, *IEEE access*, 11, 35035-35058. doi: 10.1109/ACCESS.2023.3265191.

Enders, M.R. and Hoßbach, N., 2019, Dimensions of digital twin applications: A literature review, *25th Americas conference on information systems*, 2019 Cancun, AMCIS Proceedings, 20.

Fu, Y., Zhu, G., Zhu, M. and Xuan, F., 2022, Digital twin for integration of design-manufacturing-maintenance: An overview, *Chinese journal of mechanical engineering*, 35(1), 80.

Gabor, T., Belzner, L., Kiermeier, M., Beck, M.T. and Neitz, A., 2016, A simulation-based architecture for smart cyber-physical systems, *IEEE international conference on autonomic computing (ICAC)*, July 2016 Wuerzburg, Germany, IEEE, 374-379.

Gao, X. and Pishdad-Bozorgi, P., 2019, BIM-enabled facilities operation and maintenance: A review, *Advanced engineering informatics*, 39, 227-247. doi: 10.1016/j.aei.2019.01.005.

García de Soto, B., Agustí-Juan, I., Hunhevicz, J., Joss, S., Graser, K., Habert, G. and Adey, B.T., 2018, Productivity of digital fabrication in construction: Cost and time analysis of a robotically built wall, *Automation in construction*, 92, 297-311. doi: https://doi.org/10.1016/j.autcon.2018.04.004.

Ghafourian, K., Ismail, S. and Mohamed, Z., 2018, Construction and demolition waste: Its origins and causes, *Advanced science letters*, 24(6), 4132-4137. doi: 10.1166/asl.2018.11557.

Greif, T., Stein, N. and Flath, C.M., 2020, Peeking into the void: Digital twins for construction site logistics, *Computers in industry*, 121, 103264. doi: 10.1016/j.compind.2020.103264.

Grieves, M., 2014, Digital twin: Manufacturing excellence through virtual factory replication. *White paper* 1, 1-7.

Grieves, M. and Vickers, J., 2016, Origins of the digital twin concept. *Florida Institute of Technology*, *8*, 3-20.

Grieves, M., 2022, Intelligent digital twins and the development and management of complex systems, *Digital twin*, 2(8), 8.

Grieves, M. and Vickers, J, 2017, *Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems*, Transdisciplinary perspectives on complex systems, In: Kahlen, J., Flumerfelt, S., Alves, A. (eds), Springer international publishing, Switzerland, 85-113. doi: 10.1007/978-3-319-38756-7_4.

He, Y., Guo, J. and Zheng, X., 2018, From surveillance to digital twin: Challenges and recent advances of signal processing for industrial internet of things, *IEEE signal processing magazine*, 35(5), 120-129.

Herterich, M.M., Eck, A. and Uebernickel, F., 2016, Exploring how digitized products enable industrial service innovation: An affordance perspective, *ECIS proceedings*, 156.

Hijazi, A.A., Perera, S., Al-Ashwal, A.M. and Neves Calheiros, R., 2019, Enabling a single source of truth through BIM and blockchain integration, *The international conference on innovation, technology, enterprise and entrepreneurship (ICITEE 2019)*, 24-25 November 2019, Kingdom of Bahrain, 385-393.

Hosamo, H.H., Svennevig, P.R., Svidt, K., Han, D. and Nielsen, H.K., 2022, A digital twin predictive maintenance framework of air handling units based on automatic fault

detection and diagnostics, *Energy and buildings*, 261, 111988. doi: https://doi.org/10.1016/j.enbuild.2022.111988.

Hossain, Md.A., Abbott, E.L.S., Chua, D.K.H., Nguyen, T.Q. and Goh, Y.M., 2018, Design for Safety knowledge library for BIM integrated safety risk reviews, *Automation in construction*, 94, 290-302. doi: https://doi.org/10.1016/j.autcon.2018.07.010.

Hou, L., Wu, S., Zhang, G., Tan, Y. and Wang, X., 2020, Literature review of digital twins applications in construction workforce safety, *Applied sciences*, 11(1), 339.

Ilhan, B. and Yaman, H., 2016, Green building assessment tool (GBAT) for integrated BIM-based design decisions, *Automation in construction*, 70, 26-37. doi: https://doi.org/10.1016/j.autcon.2016.05.001.

Islam, R., Nazifa, T.H., Mohammed, S.F., Zishan, M.A., Yusof, Z.M. and Mong, S.G., 2021, Impacts of design deficiencies on maintenance cost of high-rise residential buildings and mitigation measures, *Journal of building engineering*, 39, 102215. doi: https://doi.org/10.1016/j.jobe.2021.102215.

El Jazzar, M., Piskernik, M. and Nassereddine, H., 2020, Digital twin in construction: An empirical analysis. *27th EG-ICE international workshop on intelligent computing in engineering*, 1-4 July 2020 Germany, 501-510.

Jeddoub, I., Nys, G.-A., Hajji, R. and Billen, R., 2023, Digital twins for cities: Analyzing the gap between concepts and current implementations with a specific focus on data integration, *International journal of applied earth observation and geoinformation*, 122, 103440.

Jiang, F., Ma, L., Broyd, T. and Chen, K., 2021, Digital twin and its implementations in the civil engineering sector, *Automation in construction*, 130, 103838. doi: https://doi.org/10.1016/j.autcon.2021.103838.

Jiang, H. and Jiang, A., 2022, Monitoring system for the construction of arch cover method subway station based on DT and IoT. Jerbi, H. Ed, *Journal of sensors*, 2022, 1875196. doi: 10.1155/2022/1875196.

Jiang, Y., 2021, Intelligent building construction management based on BIM digital twin, *Computational intelligence and neuroscience*, 2021 (1), 4979249. doi: 10.1155/2021/4979249.

Jiang, Y., Su, S., Zhao, S., Zhong, R.Y., Qiu, W., Skibniewski, M.J., Brilakis, I. and Huang, G.Q., 2024, Digital twin-enabled synchronized construction management: A roadmap from construction 4.0 towards future prospect, *Developments in the built environment*, 19, 100512. https://linkinghub.elsevier.com/retrieve/pii/S2666165924001935.

Jiang, Y., Li, M., Li, M., Liu, X., Zhong, R.Y., Pan, W. and Huang, G.Q., 2022, Digital twin-enabled real-time synchronization for planning, scheduling, and execution in precast on-site assembly, *Automation in construction*, 141, 104397.

Jiang, Y., Liu, X., Wang, Z., Li, M., Zhong, R.Y. and Huang, G.Q., 2023, Blockchain-enabled digital twin collaboration platform for fit-out operations in modular integrated

construction, *Automation in construction,* 148, 104747. doi: https://doi.org/10.1016/j.autcon.2023.104747.

Jin, J., Hu, J., Li, C., Shi, Z., Lei, P. and Tian, W., 2023, A Digital twin system of reconfigurable tooling for monitoring and evaluating in aerospace assembly, *Journal of manufacturing systems,* 68, 56-71.

Kabirifar, K., Mojtahedi, M., Changxin Wang, C. and Tam, V.W.Y., 2021, Effective construction and demolition waste management assessment through waste management hierarchy: A case of Australian large construction companies, *Journal of cleaner production,* 312, 127790. doi: https://doi.org/10.1016/j.jclepro.2021.127790.

Kaewunruen, S. and Lian, Q., 2019, Digital twin aided sustainability based lifecycle management for railway turnout systems, *Journal of cleaner production,* 228, 1537-1551. doi: 10.1016/j.jclepro.2019.04.156.

Kamari, M. and Ham, Y., 2022, AI-based risk assessment for construction site disaster preparedness through deep learning-based digital twinning, *Automation in construction,* 134, 104091. doi: https://doi.org/10.1016/j.autcon.2021.104091.

Ketzler, B., Naserentin, V., Latino, F., Zangelidis, C., Thuvander, L. and Logg, A., 2020, Digital twins for cities: A state of the art review, *Built environment,* 46(4), 547-573.

Khajavi, S.H., Motlagh, N.H., Jaribion, A., Werner, L.C. and Holmstrom, J., 2019, Digital twin: Vision, benefits, boundaries, and creation for buildings, *IEEE access,* 7, 147406-147419. doi: 10.1109/ACCESS.2019.2946515.

Kim, S.A., Shin, D., Choe, Y., Seibert, T. and Walz, S.P., 2012, Integrated energy monitoring and visualization system for smart green city development: Designing a spatial information integrated energy monitoring model in the context of massive data management on a web based platform, *Automation in construction,* 22, 51-59.

Kineber, A.F., Singh, A.K., Fazeli, A., Mohandes, S.R., Cheung, C., Arashpour, M., Ejohwomu, O. and Zayed, T., 2023, Modelling the relationship between digital twins ımplementation barriers and sustainability pillars: Insights from building and construction sector, *Sustainable cities and society,* 99, 104930.

Kritzinger, W., Karner, M., Traar, G., Henjes, J. and Sihn, W., 2018, Digital twin in manufacturing: a categorical literature review and classification. *16th IFAC symposium on information control problems in manufacturing INCOM,* 2018 Vienna, 51 (11), 1016-1022.

Lederer, J., Gassner, A., Kleemann, F. and Fellner, J., 2020, Potentials for a circular economy of mineral construction materials and demolition waste in urban areas: A case study from Vienna, *Resources, conservation and recycling,* 161, 104942.

Lee, D. and Lee, S., 2021, Digital twin for supply chain coordination in modular construction, *Applied sciences,* 11(13), 5909. doi: 10.3390/app11135909.

Lee, D., Lee, S.H., Masoud, N., Krishnan, M.S. and Li, V.C., 2021, Integrated digital twin and blockchain framework to support accountable information sharing in construction projects, *Automation in construction*, 127, 103688. doi: 10.1016/j.autcon.2021.103688.

Lehner, H. and Dorffner, L., 2020, Digital geotwin Vienna: Towards a digital twin city as Geodata Hub, *PFG*, 88, 63–75. https://doi.org/10.1007/s41064-020-00101-4

Lei, B., Janssen, P., Stoter, J. and Biljecki, F., 2023, Challenges of urban digital twins: A systematic review and a Delphi expert survey, *Automation in construction*, 147, 104716.

Li, H., Lu, M., Chan, G. and Skitmore, M., 2015, Proactive training system for safe and efficient precast installation, *Automation in construction*, 49, 163-174.

Li, J., Greenwood, D. and Kassem, M., 2019, Blockchain in the built environment and construction industry: A systematic review, conceptual models and practical use cases, *Automation in construction*, 102, 288-307. doi: 10.1016/j.autcon.2019.02.005.

Li, M., Lu, Q., Bai, S., Zhang, M., Tian, H. and Qin, L., 2021, Digital twin-driven virtual sensor approach for safe construction operations of trailing suction hopper dredger, *Automation in construction*, 132, 103961. doi: https://doi.org/10.1016/j.autcon.2021.103961.

Li, S., Nie, L. and Liu, B., 2018, The practice of forward prospecting of adverse geology applied to hard rock TBM tunnel construction: The case of the Songhua River water conveyance project in the middle of Jilin Province, *Engineering*, 4(1), 131-137. doi: https://doi.org/10.1016/j.eng.2017.12.010.

Liang, B., Liu, W., Liu, K., Zhou, M., Zhang, Y. and Jia, Z., 2020, A displacement field perception method for component digital twin in aircraft assembly, *Sensors*, 20(18), 5161. https://www.mdpi.com/1424-8220/20/18/5161.

Lin, Y., Chen, L., Ali, A., Nugent, C., Cleland, I., Li, R., Ding, J. and Ning, H., 2024, Human digital twin: A survey, *Journal of cloud computing*, 13(1), 131.

Lin, Y.-C. and Cheung, W.-F., 2020, Developing WSN/BIM-based environmental monitoring management system for parking garages in smart cities, *Journal of management in engineering*, 36(3), 4020012. doi: 10.1061/(ASCE)ME.1943-5479.0000760.

Liu, M., Fang, S., Dong, H. and Xu, C., 2021a, Review of digital twin about concepts, technologies, and industrial applications, *Journal of manufacturing systems*, 58, 346-361. doi: 10.1016/j.jmsy.2020.06.017.

Liu, S., Bao, J., Lu, Y., Li, J., Lu, S. and Sun, X., 2021b, Digital twin modeling method based on biomimicry for machining aerospace components, *Journal of manufacturing systems*, 58, 180-195.

Liu, Y., Feng, J., Lu, J. and Zhou, S., 2024, A review of digital twin capabilities, technologies, and applications based on the maturity model, *Advanced engineering informatics*, 62, 102592.

Liu, Z., Shi, G., Jiao, Z. and Zhao, L., 2021c, Intelligent safety assessment of prestressed steel structures based on digital twins, *Symmetry*, 13(10), 1927. doi: 10.3390/sym13101927.

Liu, Z.-S., Meng, X.-T., Xing, Z.-Z., Cao, C.-F., Jiao, Y.-Y. and Li, A.-X., 2022, Digital twin-based ıntelligent safety risks prediction of prefabricated construction hoisting, *Sustainability*, 14(9), 5179. doi: 10.3390/su14095179.

Long, W., Bao, Z., Chen, K., Thomas Ng, S. and Yahaya Wuni, I., 2024, Developing an integrative framework for digital twin applications in the building construction industry: A systematic literature review, *Advanced engineering informatics*, 59, 102346. https://linkinghub.elsevier.com/retrieve/pii/S1474034623004743.

Loverdos, D. and Sarhosis, V., 2023, Geometrical digital twins of masonry structures for documentation and structural assessment using machine learning, *Engineering structures*, 275, 115256. doi: https://doi.org/10.1016/j.engstruct.2022.115256.

Lu, Q., Chen, L., Li, S. and Pitt, M., 2020a, Semi-automatic geometric digital twinning for existing buildings based on images and CAD drawings, *Automation in construction*, 115, 103183. doi: 10.1016/j.autcon.2020.103183.

Lu, Q., Xie, X., Parlikad, A.K. and Schooling, J.M., 2020b, Digital twin-enabled anomaly detection for built asset monitoring in operation and maintenance, *Automation in construction*, 118, 103277. doi: 10.1016/j.autcon.2020.103277.

Luciano, A., Cutaia, L., Cioffi, F. and Sinibaldi, C., 2021, Demolition and construction recycling unified management: The DECORUM platform for improvement of resource efficiency in the construction sector, *Environmental science and pollution research*, 28(19), 24558-24569. doi: 10.1007/s11356-020-09513-6.

Lv, Z. and Xie, S., 2022, Artificial intelligence in the digital twins: State of the art, challenges, and future research topics, *Digital twin*, 1, 12.

Macchi, M., Roda, I., Negri, E. and Fumagalli, L., 2018, Exploring the role of digital twin for asset lifecycle management, *IFAC-papersonline*, 51(11), 790-795. doi: https://doi.org/10.1016/j.ifacol.2018.08.415.

Madubuike, O.C., Anumba, C.J. and Khallaf, R., 2022, A review of digital twin applications in construction, *Journal of information technology in construction*, 27, 145-172. doi: 10.36680/j.itcon.2022.008.

Marr, B., 2019, *Artificial intelligence in practice: how 50 successful companies used AI and machine learning to solve problems*, John Wiley & Sons, USA, ISBN: 978-1-119-54898-0.

Miskinis, C., 2018, Improving healthcare using medical digital twin technology. *Challenge advisory*.

Modoni, G.E., Sacco, M. and Terkaj, W., 2016, A telemetry-driven approach to simulate data-intensive manufacturing processes, *Procedia CIRP*, 57, 281-285.

Mohseni, S.-R., Zeitouni, M.J., Parvaresh, A., Abrazeh, S., Gheisarnejad, M. and Khooban, M.-H., 2022, FMI real-time co-simulation-based machine deep learning control of HVAC systems in smart buildings: Digital-twins technology, *Transactions of the institute of measurement and control*, 45(4), 661-673. doi: 10.1177/01423312221119635.

Mykoniatis, K. and Harris, G.A., 2021, A digital twin emulator of a modular production system using a data-driven hybrid modeling and simulation approach, *Journal of intelligent manufacturing*, 32(7), 1899-1911.

Negri, E., Fumagalli, L., Cimino, C. and Macchi, M., 2019, FMU-supported simulation for CPS digital twin, *Procedia manufacturing*, 28, 201-206.

Negri, E., Fumagalli, L. and Macchi, M., 2017, A review of the roles of digital twin in CPS-based production systems, *Procedia manufacturing*, 11, 939-948.

Ning, X., Qi, J., Wu, C. and Wang, W., 2019, Reducing noise pollution by planning construction site layout via a multi-objective optimization model, *Journal of cleaner production*, 222, 218-230. doi: https://doi.org/10.1016/j.jclepro.2019.03.018.

Noardo, F., 2022, Multisource spatial data integration for use cases applications, *Transactions in GIS*, 26(7), 2874-2913.

Nyanteh, Y.D., Srivastava, S.K., Edrington, C.S. and Cartes, D.A., 2013, Application of artificial intelligence to stator winding fault diagnosis in permanent magnet synchronous machines, *Electric power systems research*, 103, 201-213.

Opoku, D.-G.J., Perera, S., Osei-Kyei, R. and Rashidi, M., 2021, Digital twin application in the construction industry: A literature review, *Journal of building engineering*, 40, 102726. doi: 10.1016/j.jobe.2021.102726.

Oppermann, L., Shekow, M. and Bicer, D., 2016, Mobile cross-media visualisations made from building information modelling data, *Proceedings of the 18th international conference on human-computer interaction with mobile devices and services adjunct*, 6 September 2016 New York, NY, USA, Association for Computing Machinery, 823-830.

Ospina-Bohórquez, A., López-Rebollo, J., Muñoz-Sánchez, P. and González-Aguilera, D., 2022, A digital twin for monitoring the construction of a wind farm, *Infrastructures*, 8(1) , 3. doi: 10.3390/engproc2022017003.

Oti, A.H., Kurul, E., Cheung, F. and Tah, J.H.M., 2016, A framework for the utilization of building management system data in building information models for building design and operation, *Automation in construction*, 72, 195-210.

Ozturk, G.B. and Yitmen, I., 2019, Conceptual model of building information modelling usage for knowledge management in construction projects, *IOP conference series: materials science and engineering*, 18-22 June 2018 Prague, IOP Publishing, 022043.

Pan, Y. and Zhang, L., 2021, A BIM-data mining integrated digital twin framework for advanced project management, *Automation in construction*, 124, 103564. doi: 10.1016/j.autcon.2021.103564.

Pantoja-Rosero, B.G., Achanta, R. and Beyer, K., 2023, Damage-augmented digital twins towards the automated inspection of buildings, *Automation in construction*, 150, 104842. doi: https://doi.org/10.1016/j.autcon.2023.104842.

Perno, M., Hvam, L. and Haug, A., 2022, Implementation of digital twins in the process industry: A systematic literature review of enablers and barriers, *Computers in industry,* 134, 103558. doi: https://doi.org/10.1016/j.compind.2021.103558.

Pogarskaia, T., Churilova, M., Petukhova, M. and Petukhov, E., 2019, Simulation and optimization of aircraft assembly process using supercomputer technologies, *Supercomputing,* 17-22 November Denver, Springer international publishing, 367-378. http://link.springer.com/10.1007/978-3-030-05807-4_31.

Qazi, A.M., Mahmood, S.H., Haleem, A., Bahl, S., Javaid, M. and Gopal, K., 2022, The impact of smart materials, digital twins (DTs) and internet of things (IoT) in an industry 4.0 integrated automation industry, *Materials today: proceedings,* 62, 18-25. doi: https://doi.org/10.1016/j.matpr.2022.01.387.

Qi, Q., Tao, F., Hu, T., Anwer, N., Liu, A., Wei, Y., Wang, L. and Nee, A.Y., 2021, Enabling technologies and tools for digital twin, *Journal of manufacturing systems,* 58, 3-21.

Qi, Q. and Tao, F., 2018, Digital twin and big data towards smart manufacturing and ındustry 4.0: 360 degree comparison, *IEEE access,* 6, 3585-3593.

Qiuchen, L. Parlikad, A.K., Woodall, P., Don Ranasinghe, G., Xie, X., Liang, Z., Konstantinou, E., Heaton, J. and Schooling, J., 2020, Developing a digital twin at building and city levels: Case study of West Cambridge Campus, *Journal of management in engineering,* 36(3), 5020004. doi: 10.1061/(ASCE)ME.1943-5479.0000763.

Rafsanjani, H.N. and Nabizadeh, A.H., 2023, Towards digital architecture, engineering, and construction (AEC) industry through virtual design and construction (VDC) and digital twin, *Energy and built environment,* 4(2), 169-178. doi: https://doi.org/10.1016/j.enbenv.2021.10.004.

Rashidi, M., Mohammadi, M., Sadeghlou Kivi, S., Abdolvand, M.M., Truong-Hong, L. and Samali, B., 2020, A decade of modern bridge monitoring using terrestrial laser scanning: Review and future directions, *Remote sensing,* 12(22), 3796.

Rashidi, M. and Samali, B., 2021, Health monitoring of bridges using RPAs, *16th East Asian-Pacific conference on structural engineering and construction*, 3-6 December 2019 Brisbane, Australia, Springer, ISBN: 978-981-15-8078-9, 209-218.

Ross, D., 2016, Digital twinning [virtual reality avatars], *Engineering & technology,* 11(4), 44-45.

Rumelhart, D.E. and McClelland, J.L., 1987. *Learning internal representations by error propagation*, Parallel distributed processing: Explorations in the microstructure of cognition: Foundations, In: Rumelhart, D.E., McClelland, J.L. and PDP research group (eds.), MIT Press, California, USA, ISBN: 9780262291408, 318-362.

Sacks, R., Brilakis, I., Pikas, E., Xie, H.S. and Girolami, M., 2020, Construction with digital twin information systems, *Data-centric engineering,* 1, 14. doi: 10.1017/dce.2020.16.

Schleich, B., Anwer, N., Mathieu, L. and Wartzack, S., 2017, Shaping the digital twin for design and production engineering, *CIRP annals,* 66(1), 141-144. https://linkinghub.elsevier.com/retrieve/pii/S0007850617300409.

Schluse, M. and Rossmann, J., 2016, From simulation to experimentable digital twins: Simulation-based development and operation of complex technical systems, *2016 IEEE international symposium on systems engineering (ISSE)*, 3-5 October 2016 Edinburgh, UK, IEEE, 1-6.

Schroeder, G.N., Steinmetz, C., Pereira, C.E. and Espindola, D.B., 2016, Digital twin data modeling with automationml and a communication methodology for data Exchange, *IFAC-papersonline,* 49(30), 12-17.

Shafto, M., Conroy, M., Doyle, R., Glaessgen, E., Kemp, C., LeMoigne, J. and Wang, L., 2012, Modeling, simulation, information technology & processing roadmap, *National aeronautics and space administration,* 32(2012), 1-38.

Shahat, E., Hyun, C.T. and Yeom, C., 2021, City digital twin potentials: A review and research agenda, *Sustainability,* 13(6), 3386.

Shao, F. and Wang, Y., 2022, Intelligent overall planning model of underground space based on digital twin, *Computers and electrical engineering,* 104, 108393. doi: https://doi.org/10.1016/j.compeleceng.2022.108393.

Shao, G. and Helu, M., 2020, Framework for a digital twin in manufacturing: Scope and requirements, *Manufacturing letters,* 24, 105-107.

Shu, Z., Wan, J., Zhang, D. and Li, D., 2016, Cloud-integrated cyber-physical systems for complex industrial applications, *Mobile networks and applications,* 21, 865-878.

Singh, M., Srivastava, R., Fuenmayor, E., Kuts, V., Qiao, Y., Murray, N. and Devine, D., 2022, Applications of digital twin across industries: A review, *Applied sciences,* 12(11), 5727. https://www.mdpi.com/2076-3417/12/11/5727.

Son, H., Kim, C., Kim, H., Han, S.H. and Kim, M.K., 2010, Trend analysis of research and development on automation and robotics technology in the construction industry, *KSCE journal of civil engineering,* 14(2), 131-139. doi: 10.1007/s12205-010-0131-7.

Su, S., Zhong, R.Y., Jiang, Y., Song, J., Fu, Y. and Cao, H., 2023, Digital twin and its potential applications in construction industry: State-of-art review and a conceptual framework, *Advanced engineering informatics*, 57, 102030.

Su, Y., Si, H., Chen, J. and Wu, G., 2020, Promoting the sustainable development of the recycling market of construction and demolition waste: A stakeholder game perspective, *Journal of cleaner production,* 277, 122281. doi: https://doi.org/10.1016/j.jclepro.2020.122281.

Subramanian, K., 2020, Digital twin for drug discovery and development—The virtual liver, *Journal of the Indian Institute of Science,* 100(4), 653-662. https://link.springer.com/10.1007/s41745-020-00185-2.

Sun, H. and Liu, Z., 2022, Research on intelligent dispatching system management platform for construction projects based on digital twin and BIM technology, *Advances in civil engineering,* 2022, 1-9. doi: 10.1155/2022/8273451.

Sun, X., Bao, J., Li, J., Zhang, Y., Liu, S. and Zhou, B., 2020, A digital twin-driven approach for the assembly-commissioning of high precision products, *Robotics and computer-integrated manufacturing,* 61, 101839.

Sun, Z., Li, H., Bao, Y., Meng, X. and Zhang, D., 2023, Intelligent risk prognosis and control of foundation pit excavation based on digital twin, *Buildings,* 13(1), 247. doi: 10.3390/buildings13010247.

Van Tam, N., Linh, L.D. and Toan, N.Q., 2021, An analysis of value chain in the Vietnam construction industry, *International journal of sustainable construction engineering and technology,* 12(3), 12-23. doi: 10.30880/ijscet.2021.12.03.002.

Tao, F., Sui, F., Liu, A., Qi, Q., Zhang, M., Song, B., Guo, Z., Lu, S.C.Y. and Nee, A.Y., 2019a, Digital twin-driven product design framework, *International journal of production research,* 57(12), 3935-3953. doi: 10.1080/00207543.2018.1443229.

Tao, F., Zhang, M. and Nee, A.Y.C., 2019b, Five-dimension digital twin modeling and its key technologies, *Digital twin driven smart manufacturing,* 63-81.

Tao, S., Wu, C., Hu, S. and Xu, F., 2020, Construction project scheduling under workspace interference, *Computer-aided civil and infrastructure engineering,* 35(9), 923-946. doi: 10.1111/mice.12547.

Tariq, R., Torres-Aguilar, C.E., Sheikh, N.A., Ahmad, T., Xamán, J. and Bassam, A., 2022a, Data engineering for digital twining and optimization of naturally ventilated solar façade with phase changing material under global projection scenarios, *Renewable energy,* 187, 1184-1203. doi: https://doi.org/10.1016/j.renene.2022.01.044.

Tariq, R., Torres-Aguilar, C.E., Xamán, J., Zavala-Guillén, I., Bassam, A., Ricalde, L.J. and Carvente, O., 2022b, Digital twin models for optimization and global projection of building-integrated solar chimney, *Building and environment,* 213, 108807. doi: https://doi.org/10.1016/j.buildenv.2022.108807.

Teicholz, P., 2013, *BIM for facility managers*. John Wiley & Sons, New Jersey, ISBN: 978-1-118-38281-3.

Tekinerdogan, B. and Verdouw, C., 2020, Systems architecture design pattern catalog for developing digital twins, *Sensors,* 20(18), 5103. https://www.mdpi.com/1424-8220/20/18/5103.

Tran, H., Nguyen, T.N., Christopher, P., Bui, D.-K., Khoshelham, K. and Ngo, T.D., 2021, A digital twin approach for geometric quality assessment of as-built prefabricated façades, *Journal of building engineering,* 41, 102377. doi: https://doi.org/10.1016/j.jobe.2021.102377.

VanDerHorn, E. and Mahadevan, S., 2021, Digital twin: Generalization, characterization and implementation, *Decision support systems,* 145, 113524.

Vapnik, V.N., 2000, *The nature of statistical learning theory*, Springer, New York, NY. http://link.springer.com/10.1007/978-1-4757-3264-1.

Vijayakumar, K., Dhanasekaran, C., Pugazhenthi, R. and Sivaganesan, S., 2019, Digital twin for factory system simulation, *International journal of recent technology and engineering*, 8(1), 63-68.

Wang, W., Guo, H., Li, X., Tang, S., Li, Y., Xie, L. and Lv, Z., 2022, BIM information integration based VR modeling in digital twins in industry 5.0., *Journal of industrial information integration*, 28, 100351. doi: https://doi.org/10.1016/j.jii.2022.100351.

Wang, X., Liang, C.-J., Menassa, C.C. and Kamat, V.R., 2021, Interactive and immersive process-level digital twin for collaborative human–robot construction work, *Journal of computing in civil engineering*, 35(6), 4021023. doi: 10.1061/(ASCE)CP.1943-5487.0000988.

Wang, X.V. and Wang, L., 2019, Digital twin-based WEEE recycling, recovery and remanufacturing in the background of industry 4.0., *International journal of production research*, 57(12), 3892-3902.

Winfield, M., 2018, The winfield rock report: Overcoming the legal and contractual barriers of BIM, *Proc. Winfield rock report overcoming the legal and contractual barriers BIM*, 1-60.

Xiang, F., Zhang, Z., Zuo, Y. and Tao, F., 2019, Digital twin driven green material optimal-selection towards sustainable manufacturing, *Procedia CIRP*, 81, 1290-1294. https://linkinghub.elsevier.com/retrieve/pii/S2212827119306298.

Xie, X., Merino, J., Moretti, N., Pauwels, P., Chang, J.Y. and Parlikad, A., 2023, Digital twin enabled fault detection and diagnosis process for building HVAC systems, *Automation in construction*, 146, 104695. doi: https://doi.org/10.1016/j.autcon.2022.104695.

Xiong, M. and Wang, H., 2022, Digital twin applications in aviation industry: A review, *The international journal of advanced manufacturing technology*, 121(9-10), 5677-5692. https://link.springer.com/10.1007/s00170-022-09717-9.

Xiong, M., Wang, H., Fu, Q. and Xu, Y., 2021, Digital twin driven aero-engine intelligent predictive maintenance, *The international journal of advanced manufacturing technology*, 114(11-12), 3751-3761. https://link.springer.com/10.1007/s00170-021-06976-w.

Xu, Y., Sun, Y., Liu, X. and Zheng, Y., 2019, A Digital twin assisted fault diagnosis using deep transfer learning, *IEEE access*, 7, 19990-19999.

Ye, Y., Yang, Q., Yang, F., Huo, Y. and Meng, S., 2020, Digital twin for the structural health management of reusable spacecraft: A case study, *Engineering fracture mechanics*, 234, 107076. https://linkinghub.elsevier.com/retrieve/pii/S0013794419315759.

Yıldırım, M. and Giran, O., 2023, *Digital twin in construction*, Digital twin driven intelligent systems and emerging metaverse, In: Karaarslan, E., Aydin, Ö., Cali, Ü., Challenger, M. (eds.), Springer, Singapore, 249-267. https://doi.org/10.1007/978-981-99-0252-1_12

Yin, X., Liu, H., Chen, Y. and Al-Hussein, M., 2019, Building information modelling for off-site construction: Review and future directions, *Automation in construction*, 101, 72-91. doi: 10.1016/j.autcon.2019.01.010.

Yoon, S., 2023, Building digital twinning: Data, information, and models, *Journal of building engineering*, 76, 107021.

Zhang, H., Zhou, Y., Zhu, H., Sumarac, D. and Cao, M., 2021, Digital twin-driven intelligent construction: Features and trends, *Structural durability & health monitoring*, 15(3), 183-206. doi: 10.32604/sdhm.2021.018247.

Zhang, K., Chen, H., Dai, H.-N., Liu, H. and Lin, Z., 2022a, Spovis: Decision support system for site selection of sports facilities in digital twinning cities, *IEEE transactions on industrial informatics*, 18(2), 1424-1434. https://ieeexplore.ieee.org/document/9456031/.

Zhang, Q., Shen, S., Li, H., Cao, W., Tang, W., Jiang, J., Deng, M., Zhang, Y., Gu, B., Wu, K. and Zhang, K., 2022b, Digital twin-driven intelligent production line for automotive MEMS pressure sensors, *Advanced engineering informatics*, 54, 101779. https://linkinghub.elsevier.com/retrieve/pii/S1474034622002373.

Zhao, Y., Cao, C. and Liu, Z., 2022, A framework for prefabricated component hoisting management systems based on digital twin technology, *Buildings*, 12(3), 276. doi: 10.3390/buildings12030276.

Zheng, H., Moosavi, V. and Akbarzadeh, M., 2020, Machine learning assisted evaluations in structural design and construction, *Automation in construction*, 119, 103346. doi: https://doi.org/10.1016/j.autcon.2020.103346.

Zheng, Z., Liao, W., Lin, J., Zhou, Y., Zhang, C. and Lu, X., 2022, Digital twin-based investigation of a building collapse accident, *Advances in civil engineering*, 2022, 1-13. doi: 10.1155/2022/9568967.

Zhuang, C., Gong, J. and Liu, J., 2021, Digital twin-based assembly data management and process traceability for complex products, *Journal of manufacturing systems*, 58, 118-131. https://linkinghub.elsevier.com/retrieve/pii/S0278612520300753.

Züst, S., Züst, R., Züst, V., West, S., Stoll, O. and Minonne, C., 2021, A graph based Monte Carlo simulation supporting a digital twin for the curatorial management of excavation and demolition material flows, *Journal of cleaner production*, 310, 127453. https://www.sciencedirect.com/science/article/pii/S0959652621016723.

EKLER

Ek1: Anket soruları

İlk bölümün soruları

Sektördeki Rolü (örn. Mimar, Mühendis, Müteahhit, ...)

Akademideki rol (örn. Araştırmacı, Öğretim Görevlisi, ...)

İkinci bölüm soruları

Yaşam döngüsündeki DT modelin soruları

Sorular	Hiç katılmıyorum	Katılmıyorum	Tarafsız	Katılıyorum	Tamamen Katılıyorum
Dijital İkiz model aşamaları net ve anlaşılması kolay					
Dijital İkiz model aşamaları gerçek ve temsilidir					
Model, Dijital İkiz teknolojisinin anlaşılmasını kolaylaştırır					
Modelde kullanılan tekniklerin sıralaması optimum kullanımla tutarlıdır					

Lütfen ek yazılı geri bildirim veya önerilerinizi iletin

…….

Üçüncü bölüm soruları

Yaşam döngüsünde DT Modellerindeki paydaş etkileşimi

Sorular	Hiç katılmıyorum	Katılmıyorum	Tarafsız	Katılıyorum	Tamamen Katılıyorum
Model net ve anlaşılması kolay					
Model doğru ve temsilidir					
Model, paydaşların nasıl hareket ettiğini ve Dijital İkiz teknolojisinden nasıl faydalandığını anlamayı kolaylaştırır					

Lütfen ek yazılı geri bildirim veya önerilerinizi iletin

……..

İNTİHAL RAPORU İLK SAYFASI

4802180152-Muhammet YILDIRIM

ORİJİNALLİK RAPORU

%2	%2	%1	%1
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%1
2	acikbilim.yok.gov.tr İnternet Kaynağı	<%1
3	dergipark.org.tr İnternet Kaynağı	<%1
4	spaceweather.astron.nl İnternet Kaynağı	<%1
5	www.duvaryayinlari.com İnternet Kaynağı	<%1
6	www.mastergbi.fr İnternet Kaynağı	<%1
7	Submitted to The London College UCK Öğrenci Ödevi	<%1
8	Kasule, Abdal. "Hibrit Algoritma Kullanarak Elektrik Enerji Tüketim Modelinin Oluşturulması ve Kestirimi: Uganda Örneği", Sakarya Universitesi (Turkey), 2022 Yayın	<%1

ETİK KURUL İZİN YAZISI

Uyarı: Canlı denekler üzerinde yapılan tüm araştırmalar için Etik Kurul Belgesi alınması zorunludur.

☐ **Etik Kurul izni gerekmektedir.**

☒ **Etik Kurul izni gerekmemektedir.**

Muhammet YILDIRIM
(İmza)

KURUM İZNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

☐ **Kurum izni gerekmektedir.**

☒ **Kurum izni gerekmemektedir.**

Muhammet YILDIRIM
(İmza)