

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM

MEKANSAL-ZAMANSAL MAKİNE ÖĞRENİMİ MODELİ İLE RİSK
BİLGİLİ İNŞAAT İLERLEME TAHMİNİ

DOKTORA TEZİ

Fatemeh MOSTOFI

EKİM 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**MEKANSAL-ZAMANSAL MAKİNE ÖĞRENİMİ MODELİ İLE RİSK
BİLGİLİ İNŞAAT İLERLEME TAHMİNİ**

Fatemeh MOSTOFI

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (İNŞAAT MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 18/ 09 / 2024

Tezin Savunma Tarihi : 08/ 10 / 2024

Tez Danışmanı : Prof. Dr. Vedat TOĞAN

İkinci Danışmanı : Doç. Dr. Onur Behzat TOKDEMİR

Trabzon 2024

ÖNSÖZ

Öncelikle, tez sürecinde bana verilen nimetler ve güç için Allah’a şükrediyorum.

Bilim ve araştırmanın temellerini öğrenme fırsatını en başından beri yanımda olan Prof. Dr. Vedat Toğan’ın rehberliğinde elde ettiğim için çok şanslıyım. Ayrıca, inşaat yönetimi alanındaki derin uzmanlığı ile araştırmamın kalitesini büyük ölçüde artıran ikinci danışmanım Doç. Dr. Onur Behzat Tokdemir ile de çalışma fırsatına sahip olduğum için kendimi daha da şanslı hissediyorum. Beni Yapım Yönetimi programına yönlendiren Prof. Dr. Şakir Erdoğan’ya, tez sürecimde bana değerli geri bildirimlerini sunan jüri üyelerim Doç. Dr. Hasan Basri Başağa ve Doç. Dr. Hüseyin Avni Es’e de teşekkürlerimi sunarım.

Uzun zamandır yakın arkadaşlarım olan Matin Keshmiri, Maryam Mirkhah, Sepideh Ale Taha ve Minoo Nasiri’ye en içten teşekkürlerimi iletmek isterim. Yapım Yönetimi ekibindeki arkadaşlarım Ediz Boz, Ümit Bahadır, Mohammad Azim Eirgash ve Raja Abuelaish’e de teşekkür ederim. KTÜ’deki arkadaşlarım Ridwan Adebayo Bello, Negin Khojaste, Sebahat Şimşek, Yunus Emrahan Akbulut, Olgahan Şevket Karahasan, Neman Izadi, Ebru ve Fatih Okur, Ayhan Üstün, Filiz Toğan, Meltem Bahadır, Esin Ertürk, İpek Naz Semercioğlu, Tuğba Sağlam ve Ömer Özbey’e benimle olan entelektüel dostluklarından dolayı minnettarım. Ayrıca Heriot-Watt Üniversitesi ve Sharjah Amerikan Üniversitesi’nden (AUS) arkadaşlarıma da teşekkür ederim.

En derin şükranlarımı sevgileri, destekleri, tavsiyeleri ve sürekli teşvikleri için annem ve babam Mahindokht ve Nasrollah’a sunarım. Onlar sayesinde öğrenme her zaman neşeli, heyecan verici, eğlenceli ve maceralı oldu. Bilime olan tutkumun kıvılcımını onlar ateşledi ve öğrenmenin değerine olan inançları bana daima ilham verdi. Kız kardeşlerim Sara ve Laya tez sürecimde kahve, mizah ve gerekli dikkat dağıtıcı unsurlarla her zaman yanımda yer alarak benim en büyük destekçilerim oldular. Kuzenlerim Kosar ve Fatima’ya da pozitif enerjileri ve varlıklarıyla hayatıma kattıkları neşe için teşekkür ederim. Ailemden aldığım sevgi ve destek benim en büyük güç ve ilham kaynağım oldu. Bu başarıyı onlara ithaf ediyorum.

Fatemeh MOSTOFI

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Mekansal-zamansal Makine Öğrenimi Modeli ile Risk Bilgili İnşaat İlerleme Tahmini” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. VEDAT TOĞAN’ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 08/10/2024

Fatemeh MOSTOFI

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XV
SEMBOLLER VE KISALTMALAR DİZİNİ	XVI
1. GENEL BİLGİLER	1
1.1. İnşaat Projelerinde İlerleme Yönetimine Giriş.....	1
1.2. İnşaat İlerlemesi Yönetimi Yöntemleri Üzerine Araştırmalar	3
1.2.1. Geleneksel Ağ Tabanlı Modeller	3
1.2.2. Yapı Bilgi Modellemesi (BIM).....	5
1.2.3. Makine Öğrenimi Teknikleri	6
1.2.4. Görsel Makine Öğrenimi Teknikleri.....	7
1.2.5. Görsel Olmayan Makine Öğrenimi Teknikleri	8
1.3. Problem Tanımı ve Araştırma Boşluğu.....	9
1.4. Önerilen Çözüm ve Araştırma Amacı	12
1.5. Teknik Arka Plan.....	15
1.5.1. Makine Öğrenimi Modelleri	15
1.5.2. Grafik Sinir Ağlar (GNN) Modelleri	17
1.5.3. Mesaj Geçişli Sinir Ağlar Modeli (MPNN)	21
1.5.4. Grafik Evrişimli Ağlar (GCN)	23
1.5.5. Grafik Dikkat Ağlar (GAT)	24
1.5.6. Geçitli Grafik Evrişim Ağlar (GatedGNN).....	26
1.5.7. Artık Geçitli Grafik Evrişim Ağlar (ResGatedGNN)	27
1.5.8. Tekrarlayan Sinir Ağlar (RNN)	28
1.5.9. Uzun Kısa Süreli Bellek (LSTM)	28
1.5.10. Geçitli Tekrarlayan Birimler (GRU).....	29
1.5.11. Mekansal-zamansal Modeller	29

2. YAPILAN ÇALIŞMALAR.....	33
2.1. Yöntem Özeti	33
2.2. Mekansal-Zamansal Modeller İçin Girdi Verileri.....	40
2.2.1. Veri Toplama ve Hazırlık	40
2.2.2. Veri Tanımlaması.....	49
2.3. Mekansal-Zamansal Modellerin Girdi Ağlar	71
2.4. Mekansal-Zamansal Modellerin Yapılandırılması.....	74
2.4.1. GCN Modelinin Yapılandırılması.....	74
2.4.2. GAT Modelinin Yapılandırılması.....	76
2.4.3. GatedGNN Modellerinin Yapılandırılması.....	77
2.4.4. ResGatedGNN Modellerinin Yapılandırılması.....	79
2.4.5. GCRNN Modellerinin (RNN-GCN, GCN-RNN, Bi-RNN-GCN ve GCN-Bi-RNN)Yapılandırılması	80
2.4.6. AttGCRNN Modellerinin (RNN-GAT, GAT-RNN, Bi-RNN- GAT ve GAT-Bi-RNN) Yapılandırılması	83
2.4.7. GCNLSTM Modellerinin (LSTM-GCN, GCN-LSTM, Bi-LSTM- GCN ve GCN-Bi-LSTM) Yapılandırılması.....	85
2.4.8. AttGCNLSTM Modellerinin (LSTM-GAT, GAT-LSTM, Bi- LSTM-GAT ve GAT-Bi-LSTM) Yapılandırılması	87
2.4.9. GCNGRU Modellerinin (GRU-GCN, GCN-GRU, Bi-GRU-GCN ve GCN-Bi-GRU) Yapılandırılması	89
2.4.10. AttGCNGRU Modellerinin Yapılandırılması (GRU-GAT, GAT- GRU, Bi-GRU-GAT ve GAT-Bi-GRU).....	91
2.4.11. GatedGRNN Modellerinin (RNN-GatedGNN, GatedGNN-RNN) Yapılandırılması.....	92
2.4.12. AttGatedGRNN Modellerinin (RNN-GatedGAT, GatedGAT- RNN) Yapılandırılması	94
2.4.13. GatedGNNLSTM Modellerinin (LSTM-GatedGNN, GatedGNN- LSTM) Yapılandırılması.....	95
2.4.14. AttGatedGNNLSTM Modellerinin (LSTM-GatedGAT, GatedGAT-LSTM) Yapılandırılması.....	97
2.4.15. GatedGNNGRU Modellerinin Yapılandırılması (GRU- GatedGNN, GatedGNN-GRU)	98
2.4.16. AttGatedGNNGRU Modellerinin Yapılandırılması (GRU- GatedGAT, GatedGAT-GRU).....	99
2.5. Performans Metriklerinin Entegrasyonu ve Değerlendirilmesi.....	101
2.5.1. Doğruluk Değerlendirme Metrikleri	101
2.5.2. Siber Saldırı Değerlendirme Metrikleri	104

2.6. Mekansal-Zamansal Modellerin Eğitimi, Değerlendirilmesi ve Seçimi	109
2.6.1. Parametre Başlatma ve Model Eğitimi	109
2.6.2. Mekansal-Zamansal Modellerin Değerlendirilmesi.....	111
2.6.3. Mekansal-Zamansal Modellerin Seçimi	135
2.7. Üretici Modellerle Hibrit Veri Setleri Oluşturma	142
3. MODEL DEĞERLENDİRMESİ BULGULAR VE TARTIŞMA	144
4. SONUÇLAR.....	181
4.1. Katkılar.....	183
4.2. Araştırma Önerileri.....	187
5. KAYNAKLAR	189
6. EKLER.....	205
ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

MEKANSAL-ZAMANSAL MAKİNE ÖĞRENİMİ MODELİ İLE RİSK BİLGİLİ İNŞAAT İLERLEME TAHMİNİ

Fatemeh MOSTOFI

Karadeniz Teknik Üniversitesi

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Vedat TOĞAN

İkinci Danışman: Doç. Dr. Onur Behzat TOKDEMİR

2024, 219 Sayfa

Bu çalışma inşaat ilerleme tahmini için mekansal-zamansal makine öğrenimi (ML) modellerinin ilk uygulaması olup planlamada kullanılan ağ tabanlı yöntemlerin ML modellerinde yansıtılamayan boşluklarını ele almaktadır. Mevcut zamansal ML modelleri kısa dizilimli yüksek frekanslı inşaat aktivitelerinde zorlanmakta bu da tahmin doğruluğunu sınırlamaktadır. Bu zorlukları aşmak için çalışmada 40 adet mekansal-zamansal model değerlendirilmiş bunlardan GatedGNN tabanlı 14 model en doğru ve dayanıklı olarak belirlendi. Çalışmada 175 haftalık inşaat ilerleme raporlarından elde edilen 2 milyondan fazla kayıttan oluşan bir veri kümesi kullanıldı. GatedGNN, GatedGNN-RNN ve GatedGNN-GRU modelleri diğerlerinden daha iyi performans göstererek maliyet ve takvim performans göstergelerinde %80 ile %95 arasında doğruluk elde etmiştir. Çalışmada veri kalitesi sorunları veri zehirlenmesi, etiket değiştirme ve özellik manipülasyonu gibi saldırılar olarak modellenerek modellerin dayanıklılıkları da test edildi. GatedGNN modelleri bu saldırılar altında doğruluklarını %80'in üzerinde korumuştur ancak küçük veri kümelerinde FGSM saldırısı doğruluğu düşürmüştür. Öne çıkan modeller proje yöneticilerinin sonuçları daha iyi tahmin etmelerine ve stratejik kararlar almalarına yardımcı olabilmektedir.

Anahtar Kelimeler: İnşaat ilerleme yönetimi, maliyet ve takvim performansı tahmini, mekansal-zamansal makine öğrenimi modeli, geçitli mekanizma, grafik sınır ağlar (GNN), geçitli tekrarlayan birim (GRU)

PhD. Thesis

SUMMARY

RISK-INFORMED CONSTRUCTION PROGRESS FORECASTING WITH SPATIO- TEMPORAL MACHINE LEARNING MODEL

Fatemeh MOSTOFI

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Civil Engineering Graduate Program
Supervisor: Prof. Dr. Vedat TOĞAN
Co-Supervisor: Assoc. Dr. Onur Behzat TOKDEMİR
2024, 219 Pages

This study represents the first application of spatio-temporal machine learning (ML) models for construction progress prediction, addressing gaps where network-based methods used in planning cannot be reflected in ML models. Existing temporal ML models struggle with short-sequence, high-frequency construction activities. To overcome these challenges, 40 spatio-temporal models were evaluated, and among them, 14 GatedGNN-based models were identified as the most accurate and robust. The study utilized a dataset comprising over 2 million records obtained from 175 weeks of construction progress reports. The GatedGNN, GatedGNN-RNN, and GatedGNN-GRU models outperformed others, achieving accuracies between 80% and 95% in cost and schedule performance indicators. Data quality issues were modeled like data poisoning, label flipping, feature manipulation, and FGSM attacks. The GatedGNN models-maintained accuracy above 80% under these attacks; however, in small datasets, FGSM attacks reduced accuracy. The prominent models can assist project managers in better predicting outcomes and making strategic decisions.

Key Words: Construction progress management, cost and schedule performance prediction, spatio-temporal machine learning model, gated mechanism, graph neural network (GNN), Recurrent neural network (RNN), Gated recurrent unit (GRU)

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Bir haftalık inşaat ilerleme raporunun yapısı, mekansal ve zamansal unsurların WBS görevleri ile entegrasyonu ve bunun proje zamanlaması ve bütçe kararlarına olan etkileri.	10
Şekil 2. Veri toplama ve mekansal-zamansal model yapılandırma süreci akış şeması.	13
Şekil 3. İnşaat proje yönetiminde karar destek araçları olarak ML modelleri.	16
Şekil 4. Öklidyen ve Öklidyen olmayan veri kümeleri.	18
Şekil 5. CPI ve SPI'yi tahmin etmek için yapılandırılan MPNN modelinin mimarisi.	22
Şekil 6. GAT modelinde dikkat mekanizması prosedürü.	24
Şekil 7. Mekansal ve mekansal-zamansal mesaj iletme işlemi.	30
Şekil 8. Araştırmada takip edilen araştırma yöntemi akış diyagramı.	34
Şekil 9. Farklı veri hazırlama aşamalarında tekrarlanan adım detayları.	41
Şekil 10. Haftalık ilerleme raporlarındaki Özet sayfasının ekran görüntüsü.	43
Şekil 11. Haftalık ilerleme raporlarındaki Verimlilik ve İlerleme sayfasının ekran görüntüsü.	44
Şekil 12. Haftalık ilerleme raporlarındaki Gantt şeması sayfasının ekran görüntüsü.	45
Şekil 13. Kullanılan büyük veri panosunun ekran görüntüsü.	47
Şekil 14. (a) Z-skoru ve (b) İzolasyon Ormanı yaklaşımları kullanılarak tespit edilen anomalilerin sonuçları.	49
Şekil 15. Projelerdeki aktivitelerin tamamlanma tarihlerinin dağılımları.	51
Şekil 16. Projelerin haftalar boyunca inşaat ilerleme kayıtlarının sıklığı.	52
Şekil 17. Seçilen özelliklerin ve CPI tahmininin Pearson korelasyonu.	54
Şekil 18. Seçilen özelliklerin ve SPI tahmininin Pearson korelasyonu.	55
Şekil 19. Adana, Bursa, Elazığ ve Yozgat veri setlerindeki WBS grubu 2 sütunlarındaki kategorilerin sıklığı.	59
Şekil 20. Adana, Bursa, Elazığ ve Yozgat projelerinde CPI tahmin veri setlerindeki inşaat Aktivite gruplarının sıklığı: (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat.	61
Şekil 21. Adana, Bursa, Elazığ ve Yozgat projelerinde SPI tahmin veri setlerindeki inşaat Aktivite gruplarının sıklığı: (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat.	62

Şekil 22.	Farklı veri setlerinde CPI ve SPI tahmin sütunlarındaki tahmin etiketlerinin sayısı.	64
Şekil 23.	Adana, Bursa, Elazığ ve Yozgat veri setlerinde CPI ve SPI sütunlarındaki kategorilerin sıklığı.	66
Şekil 24.	Farklı ilerleme haftaları boyunca (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat projelerindeki eğitim, test ve doğrulama kayıtlarının dağılımı.	69
Şekil 25.	Projelere ait veri setini saklayan mekansal-zamansal CPI ve SPI tahmin modellerine ait 100 örnek düğümün görselleştirilmesi.	72
Şekil 26.	İnşaat ilerleme raporlarına dayanan girdi ağının yapılandırılması.	73
Şekil 27.	CPI ve SPI tahmini için yapılandırılmış GCN modelinin mimarisi.	75
Şekil 28.	CPI ve SPI tahmini için yapılandırılmış GAT modelinin mimarisi.	76
Şekil 29.	Çalışmada kullanılan GatedGNN mimarisi.	78
Şekil 30.	Çalışmada kullanılan ResGatedGNN mimarisi.	79
Şekil 31.	CPI ve SPI tahmininde yapılandırılan (a) RNN-GCN ve (b) GCN-RNN modellerinin mimarisi.	82
Şekil 32.	CPI ve SPI tahmini için yapılandırılmış (a) RNN-GAT ve (b) GAT-RNN modellerinin mimarisi.	84
Şekil 33.	CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GCN ve (b) GCN-LSTM modellerinin mimarisi.	86
Şekil 34.	CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GAT ve (b) GAT-LSTM modellerinin mimarisi.	88
Şekil 35.	CPI ve SPI tahmini için yapılandırılmış (a) GRU-GCN ve (b) GCN-GRU modellerinin mimarisi.	90
Şekil 36.	CPI ve SPI tahmini için yapılandırılmış (a) GRU-GAT ve (b) GAT-GRU modellerinin mimarisi.	92
Şekil 37.	CPI ve SPI tahmini için yapılandırılmış (a) RNN-GatedGNN ve (b) GatedGNN-RNN modellerinin mimarisi.	93
Şekil 38.	CPI ve SPI tahmini için yapılandırılmış (a) RNN-GatedGAT ve (b) GatedGAT-RNN modellerinin mimarisi.	95
Şekil 39.	CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GatedGNN ve (b) GatedGNN-LSTM modellerinin mimarisi.	96
Şekil 40.	CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GatedGAT ve (b) GatedGAT-LSTM modellerinin mimarisi.	97
Şekil 41.	CPI ve SPI tahmininde yapılandırılmış (a) GRU-GatedGNN ve (b) GatedGNN-GRU modellerinin mimarisi.	98
Şekil 42.	CPI ve SPI tahmininde yapılandırılmış (a) GRU-GatedGAT ve (b) GatedGAT-GRU modellerinin mimarisi.	100
Şekil 43.	Adana veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.	112

Şekil 44.	Adana veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları.	114
Şekil 45.	Bursa veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.	115
Şekil 46.	Bursa veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları.	116
Şekil 47.	Elazığ veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.	117
Şekil 48.	Elazığ veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları	118
Şekil 49.	Yozgat veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları	119
Şekil 50.	Yozgat veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları	120
Şekil 51.	Mekansal-zamansal modellerin proje veri setinin farklı pencereleri içinde çeşitli performans metriklerine göre CPI tahminine yönelik performansları.....	121
Şekil 52.	Mekansal-zamansal modellerin proje veri setinin farklı pencereleri içinde çeşitli performans metriklerine göre SPI tahminine yönelik performansları.....	123
Şekil 53.	Mekansal-zamansal CPI tahmin modellerinde dikkat ve geçit mekanizmaları arasındaki F1 skoru performans karşılaştırması.	126
Şekil 54.	Mekansal-zamansal SPI tahmin modellerinde dikkat ve geçit mekanizmaları arasındaki F1 skoru performans karşılaştırması.	127
Şekil 55.	Geçit mekanizmasına sahip mekansal-zamansal inşaat ilerleme CPI tahmin modellerinin F1 skoru performans karşılaştırması.	128
Şekil 56.	Geçit mekanizmasına sahip mekansal-zamansal inşaat ilerleme SPI tahmin modellerinin F1 skoru performans karşılaştırması.	129
Şekil 57.	Mekansal-zamansal CPI tahmin modellerinde RNN, LSTM ve GRU mekanizmaları arasındaki F1 skoru performans karşılaştırması.	130
Şekil 58.	Mekansal-zamansal SPI tahmin modellerinde RNN, LSTM ve GRU mekanizmaları arasındaki F1 skoru performans karşılaştırması.	131
Şekil 59.	Tek yönlü ve çift yönlü mekansal-zamansal CPI ilerleme tahmin modelleri arasında F1 skoru performans karşılaştırması.	133
Şekil 60.	Tek yönlü ve çift yönlü mekansal-zamansal SPI ilerleme tahmin modelleri arasında F1 skoru performans karşılaştırması.	134
Şekil 61.	En yüksek doğruluk ve F1 skoruna sahip en iyi performans gösteren model sıklığı.	136
Şekil 62.	Geçitli mekanizmalara sahip mekansal-zamansal modeller ile bu mekanizmalara sahip olmayan modellerin farklı pencerelerde CPI tahmin performansları karşılaştırması.	138

Şekil 63.	Geçitli mekanizmalara sahip mekansal-zamansal modeller ile bu mekanizmalara sahip olmayan modellerin farklı pencerelerde SPI tahmin performansları karşılaştırması.	139
Şekil 64.	Statik ve dinamik mekansal-zamansal modellerin CPI tahmininde F1 skoru performansları karşılaştırması.	140
Şekil 65.	Statik ve dinamik mekansal-zamansal modellerin SPI tahmininde F1 skoru performansları karşılaştırması.	141
Şekil 66.	Farklı veri setlerinde CPI ve SPI tahmin modellerinin farklı pencerelerde doğruluk performansı.	145
Şekil 67.	Farklı veri setlerinde ele alınan pencereler boyunca CPI ve SPI tahmin modellerinin en yüksek doğruluk performansı.	147
Şekil 68.	Adana veri setinin ilk penceresinde eğitilen GatedGNN mekanizmasına sahip mekansal-zamansal modellerin ROC performansları.	149
Şekil 69.	Adana veri setinin ilk penceresinde eğitilen GatedGNN mekanizmasına sahip mekansal-zamansal modellerin doğruluk performansları.	150
Şekil 70.	Farklı veri setlerinde çeşitli pencereler boyunca CPI ve SPI tahmin modellerinin F1 skoru performansları.	152
Şekil 71.	Farklı veri setlerinde CPI ve SPI tahmin modellerinin sergiledikleri en yüksek F1 skoru performansları.	153
Şekil 72.	Adana projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.	155
Şekil 73.	Adana projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.	158
Şekil 74.	Bursa projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.	161
Şekil 75.	Bursa projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.	164
Şekil 76.	Elazığ projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.	166
Şekil 77.	Elazığ projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.	168
Şekil 78.	Yozgat projesinin iki farklı penceresinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.	170
Şekil 79.	Yozgat projesinin iki farklı penceresinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.	171
Şekil 80.	Adana veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.	174
Şekil 81.	Bursa veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.	176

Şekil 82.	Elazığ veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.	178
Şekil 83.	Yozgat veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.	180
Şekil 84.	Bu çalışmada mevcut literatüre yapılan katkılar ve gelecekteki çalışmalar için ele alınabilecek araştırma boşlukları.	185
Ek Şekil 1.	GatedGNN modeli için kullanılan Python kodu detayları.	205
Ek Şekil 2.	GatedGNN-RNN modeli için kullanılan Python kodu detayları.	206
Ek Şekil 3.	GatedGNN-GRU modeli için kullanılan Python kodu detayları.	207
Ek Şekil 4.	RNN-GatedGNN modeli için kullanılan Python kodu detayları.	208
Ek Şekil 5.	GRU-GatedGNN modeli için kullanılan Python kodu detayları.	209

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Ağ tabanlı yaklaşımlar kullanılarak inşaat ilerleme izlemesi üzerine gerçekleştirilen çalışmalar.	4
Tablo 2. Bu Araştırmada Geliştirilen Mekansal-Zamansal ML Modelleri.....	36
Tablo 3. Mekansal-zamansal ML modellerinde kullanılan kodlanmış veri setinin istatistiksel detayları.	56
Tablo 4. Yapılandırılmış mekansal-zamansal modellerin eğitim parametreleri.	110
Ek Tablo 1. Farklı pencerelerde CPI tahmininde kullanılan mekansal-zamansal modellerin performansı.....	210
Ek Tablo 2. Farklı pencerelerde SPI tahmininde kullanılan mekansal-zamansal modellerin performansı.....	214

SEMBOLLER VE KISALTMALAR DİZİNİ

AC	: Gerçek Maliyet (Actual Cost)
AI	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağlar (Artificial Neural Networks)
AUC-ROC	: Alıcı İşletim Karakteristiği Eğrisi Altındaki Alan (Area Under The Receiver Operating Curve)
BIM	: Bina Bilgi Modellemesi (Building Information Modeling)
CAD	: Bilgisayar Destekli Tasarım (Computer-Aided Design)
CNN	: Evrişimsel Sinir Ağlar (Convolutional Neural Networks)
CPI	: Maliyet Performans Göstergeleri (Cost Performance Index)
CPM	: Kritik Yol Yöntemi (Critical Path Method)
DNN	: Derin Sinir Ağlar (Deep Neural Networks)
EDA	: Keşifsel Veri Analizi (Exploratory Data Analysis)
ELU	: Üstel Doğrusal Birim (Exponential Linear Unit)
FedAVG	: Federasyon Ortalaması (Federated Averaging)
EVM	: Kazanılmış Değer Yönetimi (Earned Value Management)
EV	: Kazanılmış Değer (Earned Value)
FGSM	: Hızlı Gradyan İşareti Yöntemi (Fast Gradient Sign Method)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
GAN	: Üretici Çekişmeli Ağlar (Generative Adversarial Networks)
GAT	: Grafik Dikkat Ağlar (Graph Attention Networks)
GatedGAT	: Geçitli Grafik Dikkat Ağları (Gated Graph Attention Network)
GatedGNN	: Geçitli Grafik Sinir Ağları (Gated Graph Neural Network)
GCN	: Grafik Evrişimli Ağlar (Graph Convolutional Networks)
GNN	: Grafik Sinir Ağlar (Graph Neural Networks)
GRU	: Geçitli Tekrarlayan Birim (Gated Recurrent Units)
ICT	: Bilgi ve İletişim Teknolojisi (Information And Communication Technology)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ML	: Makine Öğrenimi (Machine Learning)
MLP	: Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron)

NaN	: Sayı Deęil (Not a Number)
NLP	: Doęal Dil İřleme (Natural Language Processing)
PERT	: Program Deęerlendirme İnceleme Teknięi (Program Evaluation Review Technique)
PV	: Planlanmış Deęer (Planned Value)
ResGatedGNN-	Artık Geçitli Grafik Sinir Aęları (Residual Gated Graph Neural Network)
ReLU	: Düzeltilmiş Doğrusal Birim (Rectified Linear Unit)
RNN	: Tekrarlayan Sinir Aęlar (Recurrent Neural Networks)
SPI	: Zamanlama (Takvim) Performans Göstergeleri (Schedule Performance Index)
TCN	: Zamansal Konvolüsyonel Aęlar (Temporal Convolutional Network)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
VAE	: Varyasyonel Otomatik Kodlayıcı (Variational Autoencoder)
VR	: Sanal Gerçeklik (Virtual Reality)
WBS	: İş Kırılım Yapıları (Work Breakdown Structures)

1. GENEL BİLGİLER

1.1. İnşaat Projelerinde İlerleme Yönetimine Giriş

İnşaat projeleri, beklenen sonuçlara ulaşmada özellikle maliyet, süre ve kalite açısından zorluklarla sıkça karşılaşmaktadır. Bu üç unsur, inşaat projelerinin başarısını destekleyen temel üçlü olarak kabul edilmekte olup, başarısızlıkları itibar kaybına, tedarik zincirlerinde aksamalara ve devlet gelirlerinde azalmaya neden olarak ulusal ve küresel ekonomiyi olumsuz etkilemektedir (Biswas vd., 2021). Süre ve maliyet proje başarısının üç unsuru arasından en yaygın iki performans metriğini(göstergesini) oluşturmakta (Project Management Institute, 2021) ve bu nedenle bu araştırmanın temel odak noktasını teşkil etmektedir.

Proje yöneticilerinin iyimser öz-değerlendirmelerine rağmen, araştırmalar projelerin sadece %5'inin bütçe ve süre hedeflerini başarıyla karşıladığını belirtmiştir (Orgut vd., 2016). İnşaat proje yönetiminde maliyet ve süre birbirine sıkı sıkıya bağlı iki performans metriği olup, bunlardan birinde meydana gelen başarısızlık, genellikle projenin genelinde önemli etkilere neden olmaktadır. İnşaat belirsizlikleri orijinal planlardan önemli sapmalara ve aylarca sürebilen gecikmelere neden olarak maliyetlerin %80'e kadar artmasına yol açabilir (X. Yan vd., 2022). Ayrıca, bu durumlar yüklenicilerin süre uzatımı için yüksek mali cezalar ödemelerine sebep olmaktadır (Guo vd., 2017; X. Yan vd., 2022). Maliyet ve süre arasındaki ilişki döngüseldir ve yönetilmesi son derece karmaşık olabilmektedir. Bu ilişki, projenin çeşitli yönleri arasında zincirleme etkiler yaratmaktadır. Gecikmeler, proje takvimini geri çekerken maliyet aşımalarına da neden olmuştur (Eirgash & Toğan, 2023; Selcuk vd., 2024). Geciken takvim, proje maliyetlerine ek yük getirirken, bütçe aşımaları ilerlemeyi yavaşlatmaktadır. Örneğin, takvim gecikmelerini telafi etmek için yapılacak hızlandırma, fazla mesai, hızlandırılmış malzeme sevkiyatları veya ek kaynak kullanımı maliyetleri artırmaktadır. Tersine, daha ucuz malzemelerin istenen kaliteyi sağlamaması nedeniyle yeniden ele alınmaları veya azalan iş gücünün ilerlemeyi yavaşlatması gibi maliyet azaltma önlemleri gecikmelere neden olmaktadır. Bu döngüsel ilişki, yatırımcılardan yüklenicilere kadar tüm paydaşları ciddi şekilde etkilemektedir (Flyvbjerg vd., 2018; Guo vd., 2017).

İnşaat projelerin yönetilmesi, maliyet ve süre planlamaları da dahil olmak üzere, karar verme süreçlerinin belirsiz, karmaşık ve muğlak bir ortamda gerçekleşmesi nedeniyle zorlayıcıdır (K. Feng vd., 2023; Love, 2024; Ochieng vd., 2013; Santos & Jungles, 2016). Her proje, iş gücü verimliliği (Nurhendi vd., 2022), belgeler (Mohammed vd., 2021), lojistik süreçler (Gholami, 2023), teknoloji ve ileri düzey yapı malzemeleri ile ekipmanların kullanımı (AlMunifi & Almutairi, 2021), hava durumu ve düzenleyici konular gibi birçok değişkeni içermekte ve inşaat projelerinin başarılı bir şekilde teslim edilmesi, bu değişkenlerin etkili bir şekilde yönetilmesine kritik derecede bağlı olmaktadır. Bu zorluk, karar verme süreçlerini yönlendiren bilgi seviyesinin ve öngörülebilirliğin tutarsız olmasıyla daha da karmaşılaşmaktadır (Love, 2024). Bu durum, kazanılmış değer yönetimi (EVM) gibi entegre maliyet ve süre kontrolünün önemini vurgulamaktadır. 1980'lerin sonlarında tanıtılan bu yöntem, kapsam, zaman ve maliyeti entegre ederek proje ilerlemesini izlemeyi ve başarının sağlanmasını amaçlamaktadır (Abo Mhady vd., 2024).

Mou (2019), EVM'yi inşaat ilerlemesinin ölçümünde temel yöntemlerden biri olarak tanımlamıştır. EVM yöntemleri, maliyet ve zamanlama verilerinin bütünleştirilmesi ile öne çıkmakta ve proje performansını daha kapsamlı bir biçimde değerlendirmeye olanak tanımaktadır. Bu yöntem, maliyet verimliliği ile zamanlama uyumunu ölçmek amacıyla maliyet performans göstergesi (Cost Performance Index, CPI) ve zamanlama performans göstergesi (Schedule Performance Index, SPI) gibi metriklerden yararlanmaktadır.

CPI, maliyet verimliliğinin bir göstergesi olarak, kazanılmış değer (Earned Value, EV) ile gerçek maliyet (Actual Cost, AC) arasındaki oranın hesaplanmasıyla Denklem (1)'de ifade edildiği gibi elde edilir (Project Management Institute, 2021).

$$CPI = \frac{EV}{AC} \quad (1)$$

Denklem (1)'e göre, CPI değerinin 1 olması, gerçekleştirilen işin gerçek maliyetinin planlanan bütçe ile uyumlu olduğunu, yani projenin bütçe dahilinde yürütüldüğünü gösterir. $CPI > 1$ olduğunda, maliyet verimliliğinin sağlandığını ve projenin bütçe altında tamamlandığını; gerçek maliyetlerin planlanan harcamaların altında kaldığını işaret eder. Diğer yandan, $CPI < 1$ ise, projenin bütçeyi aştığını belirtir; bir diğer deyişle işin tamamlanma maliyeti planlanan bütçeyi aşmıştır. Aynı şekilde, SPI, bir projenin zamanlama verimliliğini değerlendirir ve EV ile planlanmış değer (Planned Value, PV) arasındaki oranın

hesaplanmasıyla Denklem (2)'de belirtildiği gibi tespit edilir (Project Management Institute, 2021).

$$SPI = \frac{EV}{PV} \quad (2)$$

Denklem (2)'ye göre $SPI = 1$ ise projenin gerçek ilerlemesinin planlanan takvime uygun olduğunu, yani projenin zamanında ilerlediğini gösterir. $SPI > 1$ ise projenin takvimin ötesinde ilerlediğini gösterir. Bu da belirli bir zamana kadar planlanandan daha fazla işin tamamlandığı anlamına gelmektedir. $SPI < 1$ olduğunda ise projenin geride olduğunu ve gerçekleştirilen işin planlanandan az olduğunu göstermektedir.

1.2. İnşaat İlerlemesi Yönetimi Yöntemleri Üzerine Araştırmalar

Planlama ve izleme süreçlerinin kesişimi hem geçmiş verileri hem de gerçek zamanlı güncellemeleri kullanan verimlilik tahmin modellerine odaklanan çalışmalara yol açmıştır. Proje izlemeyi iyileştirecek ve tüm paydaşlar arasında etkili iletişimi kolaylaştıracak bir karar destek sistemine ihtiyaç duyulmaktadır (Pour Rahimian vd., 2020). Süre gecikmelerini ve maliyet aşımalarını etkili bir şekilde önlemek için, planlanan ve gerçekleşen ilerleme arasındaki herhangi bir uyumsuzluğun anında tespit edilmesini, işlenmesini ve iletilmesini sağlayan inşaat ilerleme, planlama ve izleme mekanizmalarının kullanılması hayati önem taşımaktadır (Mani vd., 2009). Bu, planlanan ve gerçekleşen sonuçlar arasındaki farklılıkları azaltmaya yardımcı olarak genel proje teslimatının beklenen amaçlar doğrultusunda gerçekleştirilmesine ön ayak olmaktadır. Proje harcamalarının ayrıntılı tahminlerini sağlayan maliyet planları ve proje takvimini belirleyen süre planları, bu yaklaşımın kritik bileşenleridir. İnşaat ilerleme izleme modelleri, görsel ve görsel olmayan farklı kategorilerde geliştirilen ve ağırlıklı olarak ağ tabanlı yaklaşımlarla izlemeye odaklananlar ve tahmine dayalı analitiğe yönelik olanlar olmak üzere iki ana sınıfa ayrılan modellerdir.

1.2.1. Geleneksel Ağ Tabanlı Modeller

İnşaat yönetimi çalışmaları geleneksel olarak, kritik yol yöntemi (Critical Path Method, CPM) ve program değerlendirme inceleme tekniği (Program Evaluation Review Technique, PERT) gibi ağ tabanlı yaklaşımlara dayanmaktadır. 1950'lerden bu yana proje

takvimlendirme ve izleme, CPM ve PERT gibi ağ tabanlı tekniklerle yürütülmüştür (Ahuja & Thiruvengadam, 2004). CPM bağımlı görevlerin en uzun dizisini belirleyen ve minimum proje süresini belirleyen ağ tabanlı bir takvimlendirme yöntemidir. CPM proje faaliyetleri arasından kritik olanlarının zamanında tamamlanmasını sağlamak için önceliklendirir ve böylece proje yöneticilerinin kaynakları ve çabalarını bunlara yönelterek projenin genel zaman çizelgesindeki gecikmelerinin önüne geçebilirler. Tablo 1 inşaat ilerlemesini izlemek için çeşitli metodolojilerin ağ tabanlı yaklaşımlarla nasıl entegre edildiğini göstermektedir.

Tablo 1. Ağ tabanlı yaklaşımlar kullanılarak inşaat ilerleme izlemesi üzerine gerçekleştirilen çalışmalar.

Metot	Kaynak
CPM ile denge çizgisi tekniği (Line-of-balance Technique (LOB)) entegrasyonu	(Suhail & Neale, 1994)
CPM ile bulanık sistem entegrasyonu	(Nasution, 1994)
CPM ile PERT entegrasyonu	(Peña-Mora & Li, 2001)
Karar destek araçları olarak proje gecikme analizi	(Francis & Miresco, 2002)
Gecikme hesaplama için matematiksel modeller	(Sacks vd., 2003; Shi vd., 2001)
Verimlilik performans kontrolü	(Navon & Goldschmidt, 2003)
CPM tabanlı izleme	(Sacks vd., 2003)
Kaynak yönetimi	(H. J. Wang vd., 2004)
Zaman ve maliyet optimizasyonu	(Chassiakos & Sakellariopoulos, 2005)
CPM tabanlı iletişim	(Navon, 2007; Ying & Pheng, 2014)

Tablo 1'de gösterildiği gibi ağ tabanlı yöntemler, gecikmelerin kritik yolunu ve genel proje zaman çizelgesini nasıl etkilediğini daha iyi anlamak amacıyla, CPM gibi tekniklerle sıklıkla entegre edilmektedir. Önceki çalışmalar, geleneksel CPM yaklaşımını farklı tekniklerle entegre etmeye odaklanmıştır. Örneğin, bazı çalışmalar PERT'i CPM ile birleştirerek hem deterministik hem de olasılıksal planlama yaklaşımlarının güçlü yönlerinden faydalanarak karmaşık projeleri yönetmek için daha kapsamlı bir araç sunmuştur (Peña-Mora & Li, 2001). PERT, inşaat proje yönetimi literatüründe ikinci en popüler ağ tabanlı tekniktir ve proje aktivitelerinin olasılıksal zaman tahminlerine vurgu yaparak, görev sürelerindeki belirsizlik ve değişkenliklerin daha iyi yönetilmesini sağlar. PERT, bir ağ diyagramı kullanarak proje aktivitelerinin sırasını modellemekte ve beklenen proje zaman çizelgelerini hesaplamak için iyimser, kötümser ve en olası gibi birden fazla zaman tahminini içermektedir.

CPM tekrar eden projeler için özellikle etkili bir yöntem olan denge çizgisi tekniği (Line of Balance, LOB) ile de entegre edilmiştir. LOB, özellikle yüksek katlı binalar veya otoyol inşaatları gibi tekrarlayıcı projeler için etkili olan grafik tabanlı bir takvimlendirme yöntemidir. Bu yöntem, görevlerin sürekli bir iş akışını sağlamak ve kaynak darboğazlarını önlemek için tamamlanması gereken sıralama ve hızları görsel olarak temsil eder (Suhail & Neale, 1994).

Diğer çalışmalar CPM'in proje zaman çizelgelerinin sürekli izlenmesi (Sacks vd., 2003), iletişim (Navon, 2007; Ying & Pheng, 2014) ve maliyet kontrolü (Navon, 2007) için kullanılmasına odaklanmıştır. Bu entegrasyonlar belirsiz veya kesin olmayan verilerin ağ modeline dahil edilmesine olanak tanıyan bulanık mantık ile CPM'in birleştirilmesini de içermektedir. Örneğin, Nasution (1994) bu birleştirme ile planlama sürecine esneklik kazandırarak zaman çizelgesi performansının bütçe takibi ile doğrudan bağlantılarını ve proje zaman çizelgesindeki gecikmeler veya hızlanmaların finansal yönetimi nasıl etkileyebileceğini göstermiştir.

Bu sürekli izleme proje yöneticilerinin potansiyel gecikmeleri erken tespit etmelerine ve bunlar büyümeden önce düzeltici önlemler almalarına olanak tanıdığı için kritik öneme sahiptir. Bununla birlikte, geleneksel ilerleme izleme yöntemlerinin (örneğin, CPM ve EVM) deterministik doğası, belirsizlikleri hesaba katamamakta ve bu nedenle proje performansını tahmin edememektedir (Byung Cheol Kim, 2007). Bu nedenle, CPM'in yeteneklerini artırmak için karar destek teknikleri geliştirilmiştir (Patel vd., 2021).

1.2.2. Yapı Bilgi Modellemesi (BIM)

Yapı bilgi modellemesi (Building Information Modeling, BIM) görselleştirme ve otomasyon tekniklerinin CPM'in performansını artırma amacıyla uygulanması 2007 ve 2020 yılları arasında önemli araştırma konusu olarak ilgi çekmiştir (Patel vd., 2021). BIM ortamında kullanılan en geleneksel yöntem şantiyedeki durumun planlanmış olanla karşılaştıran fiziksel ilerleme yönetimi için kullanılan 2D CAD çizimleridir (W. Yan & Escamilla, 2019). Ancak, 2D çizimler, raporlar, takvimler ve fotoğraf günlükleri gibi seyrek ve hata eğilimli geleneksel yöntemleri kullanmak süreci karmaşık ve verimsiz hale getirmektedir (Pour Rahimian vd., 2020; X. Zhang vd., 2009). BIM, ayrıca bir yapının ayrıntılı 3D modelini oluşturan dijital bir araç olarak yaygın şekilde kullanılmaktadır ve bu yapısal tasarım ve inşaat süreçlerini kolaylaştırmaktadır (Yavan, 2023). Bu durum proje

yöneticilerinin inşaat sırasını ve takvimini zaman içinde görselleştirmesini sağlayarak potansiyel çakışmaları tespit etmeyi, iş akışlarını optimize etmeyi ve genel proje koordinasyonunu iyileştirmeyi kolaylaştırmaktadır. BIM, CPM ile entegre edildiğinde modele bir zaman boyutu eklenebilir (4D BIM olarak adlandırılır) ve böylelikle proje yöneticileri inşaat sırasını zaman içinde görselleştirerek simüle edebilirler.

BIM'in inşaat gecikmelerinin modellenmesi ve proje izleme üzerindeki kullanımının geleneksel yöntemlerle ilişkilendirilen zorlukları azaltmadaki etkinliğini vurgulayan birçok çalışmada bulunmaktadır. Örneğin, C.-W. Feng & Chen (2008), bilgisayar destekli tasarım (Computer-Aided Design, CAD) modelini kullanarak hibrit bir yaklaşım içinde inşaat projeleri için entegre bir süre planlaması geliştirmiştir. Hashemi Golpayegani & Emamizadeh (2007), CAD BIM modelini CPM ile entegre ederek inşaat ilerlemesinin dinamik olarak görselleştirilmesini ve fiziksel ile planlanmış ilerlemenin daha iyi uyum sağlamasını mümkün kılmıştır. Ancak, inşaat projelerinde saha izleme için planlanan ile gerçekleşen karşılaştırmasının manuel olarak yapılması yüksek maliyetli ve zaman alıcı olmaktadır (W. Yan & Escamilla, 2019). Çalışma ilerlemesinin sürekli izlenmesi ve plarlardan sapmaların belirlenmesi daha verimli ve güvenli bir çalışma ortamı oluşturmak için önemlidir (Garcia vd., 2022). Sonuç olarak, araştırmacılar ve uygulayıcılar gecikmelerin nedenlerini ve etkilerini belirlemek için proje takvimlerinin sistematik incelemesini yapmaya yönelik çeşitli otomatik yaklaşımlar kullanmışlardır.

1.2.3. Makine Öğrenimi Teknikleri

Yapay zeka (Artificial Intelligence, AI) ve makine öğrenimi (Machine Learning, ML) tekniklerinin tanıtılması, insan hatası ve önyargı olmaksızın tahmin modelleri oluşturulmasına olanak tanıyarak, büyük miktarda bilginin kısa sürede işlenmesine yol açmıştır. ML yaklaşımları, deneyimlerden otomatik olarak öğrenme ve geliştirme yeteneğine sahip karmaşık tahmin modellerini kullanabilmek için güvenilir bilgiler içeren büyük veri setlerine ihtiyaç duymaktadır (García Rodríguez vd., 2022). İnşaat mühendisliği alanındaki ML tabanlı araştırmalar, yangın tehlikesi tahmininden (S. Mostofi & Altunişik, 2024a, 2024b) bina hasar değerlendirmesine kadar çeşitli alanları kapsamaktadır (Alpaslan vd., 2024; Bahadır vd., 2022; Hacıfendioğlu vd., 2022). Benzer şekilde inşaat yönetiminde ML, fiyat bazlı kararları optimize etmek (Mostofi vd., 2021; Mostofi, Toğan, vd., 2022; Rafiei & Adeli, 2016; Selim, 2009) ve risk değerlendirmesi gerçekleştirmek (Koc vd., 2023; Mostofi

& Toğan, 2023c; Sakhakarmi vd., 2019; S. Tang & Golparvar-Fard, 2021) için uygulanmıştır. İnşaat mühendisliği ve proje yönetimi alanındaki ML tabanlı araştırmalara olan ilgi 2015 ile 2021 yılları arasında üç katına çıkmıştır (Y. Pan & Zhang, 2021).

1.2.4. Görsel Makine Öğrenimi Teknikleri

Bilgisayarla görme, bilgisayarların görsel dünyayı yorumlayıp anlamasını sağlayan bir ML alanıdır. Bu teknikler, şantiye görsel verilerini analiz ederek inşaat ilerlemesini otomatik olarak izlemeyi mümkün kılarak proje yönetimine katkı sağlamaktadır (X. Zhang vd., 2009). Görüntü işleme ve BIM'in hibrit kullanımı, “planlandığı gibi” modellerin talep üzerine güncellenmesini ve inşaat ilerlemesinin daha etkin bir şekilde izlenmesini hedeflemektedir (Pour Rahimian vd., 2020). İnşaat yönetimi literatürü, gelişmiş görsel ML tekniklerinin BIM ile birleştirilerek şantiyelerden doğrudan veri yakalama ve analiz etme konusunda geniş çapta kullanıldığını göstermektedir. Örneğin, Mou (2019) çalışmasında, bilgisayarla görme ve anlamsal bölütleme tekniklerinin görselleri segmentlere ayırarak şantiye yapıları ile BIM modellerini karşılaştırmayı ve tamamlanma oranlarını tahmin etmeyi mümkün kılan süreçleri ele almıştır. Bu yönde yapılan diğer çalışmalarda da çeşitli tahmin modelleri aynı amaçla geliştirilmiştir (E. Z. Berglund vd., 2020; J. Kim & Chi, 2020; Vick & Brilakis, 2018). Başka bir çalışmada, ML ile BIM'in entegrasyonunun inşaat ilerlemesinin görselleştirilmesini ve izlenmesini nasıl iyileştirdiği vurgulanmakta ve proje yöneticilerinin bu yolla projedeki sapmaları daha etkili bir şekilde tespit etmeleri sağlanmaktadır (X. Zhang & Zhang, 2023).

Ek olarak, bilgi ve iletişim teknolojilerinin (Information and Communication Technology, ICT) proje yönetimiyle entegrasyonu proje iletişimi, koordinasyonu, planlaması ve izlenmesini geliştirmeyi amaçlayan gelişmiş ilerleme izleme teknolojilerinin ortaya çıkmasına neden olmuştur (Pour Rahimian vd., 2020). Pour Rahimian vd. (2020) tarafından geliştirilen kavramsal çerçeve, şantiyeler ile BIM arasında bilgi akışının iki yönlü koordinasyonunu artırmayı amaçlayan bir prototip içermektedir. Sanal gerçeklik (Virtual Reality, VR) ortamı, kullanıcıların ilerleme değerlendirmelerine aktif olarak katılmalarını, tutarsızlıkları vurgulamalarını ve raporlamalarını sağlamaktadır (Pour Rahimian vd., 2020). Bu çerçeve, şantiye fotoğraflarını planlanan BIM modelleriyle hizalamak için bilgisayarla görme ve ML metodolojilerini kullanarak, Unity gibi VR oyun motorları aracılığıyla birlikte çalışabilirliği ve entegrasyonu artırmayı hedeflemektedir (Pour Rahimian vd., 2020).

Bilgisayarla görme yaklaşımları ilerleme ölçümünü otomatikleştirebilse de bu yöntemler inşaatın belirli aşamalarıyla sınırlı kalmaktadır (X. Zhang vd., 2009). Gerçek zamanlı içgörülerin sağladığı faydalara rağmen bu yaklaşım genellikle geleneksel planlama ve zamanlama metodolojilerine kıyasla daha az öngörü sunmakta ve daha çok mevcut proje durumu ve kısa vadeli düzenlemelere odaklanmaktadır.

1.2.5. Görsel Olmayan Makine Öğrenimi Teknikleri

ML'in inşaat yönetimindeki en önemli uygulamalarından biri, olası gecikmelerin proje üzerinde olumsuz etki yapmadan önce tahmin etmek ve hafifletmek amacıyla planlama ve zamanlama metodolojilerini iyileştirmektir. Buna paralel olarak, çeşitli çalışmalar, inşaat ilerlemesini izlemeyi kolaylaştırmak için görsel olmayan ML modellerinin bu amaç doğrultusunda uygulanabilirliğini araştırmıştır (Bottaccioli vd., 2017; Han vd., 2015; Teizer, 2015; Patel vd., 2021). Bu çalışmalar, planlanan ve gerçekleşen sonuçlar arasındaki farklılıkları azaltmaya yardımcı olacak modeller geliştirerek proje teslimatının iyileştirilmesini amaçlamaktadırlar.

B.-C. Kim & Kim (2014) tarafından yürütülen çalışmada, proje maliyetini ve süresini tahmin etmek için basit ve ileri düzey ML yaklaşımlarını kullanmıştır. Soibelman vd. (2002) ve Asiedu vd. (2016) sırasıyla karar ağaçları ve çoklu doğrusal regresyon gibi daha basit ML tekniklerini kullanarak proje gecikmelerini ve zaman aşımı tahminlerini gerçekleştirmişlerdir. Özellikle, yapay sinir ağları (Artificial Neural Networks, ANN) inşaat senaryolarında tipik olan karmaşık doğrusal olmayan ilişkileri ele almak için yaygın olarak kullanılmaktadır (Ezeldin & Sharara, 2006; Heravi & Eslamdoost, 2015).

Bu alandaki araştırmalar, aynı zamanda gecikmeleri etkileyen faktörlerin erken tespitine odaklanarak proje zamanlaması tahminlerinin doğruluğunu artırmaya ve proaktif proje kontrolünü sağlamaya yöneliktir. Örneğin, Leon vd. (2018), ML'i SPI modelleriyle entegre ederek potansiyel gecikmeler için erken uyarılar sağlamış ve proje ekiplerinin proaktif yönetim yeteneklerini artırmıştır. Gündüz vd. (2013; 2015), gecikme faktörlerinin proje yaşam döngüsünün erken aşamalarında tanınmasının zamanında teslimatı sağlama açısından önemini vurgulamıştır. İnşaat verimliliğini projenin başarısında anahtar bir belirleyici olarak tanıyan araştırmacılar, sahadaki verimliliği etkileyen faktörleri belirlemek ve performans göstergelerini tahmin etmek için ML'i geniş ölçüde kullanmışlardır (Al Jassmi

vd., 2019; Alaloul vd., 2018; Ebrahimi vd., 2021; Florez-Perez vd., 2022; Golnaraghi vd., 2019; Momade vd., 2020).


Bu gelişmelere paralel olarak, Amer vd. (2023) proje aktiviteleri arasındaki bağımlılıkları analiz etmek için doğal dil işleme (Natural Language Processing, NLP) yöntemini kullanmıştır. NLP, bilgisayarların insan dilini anlamasına, yorumlamasına ve manipüle etmesine yardımcı olan bir AI dalıdır. NLP bu sayede proje zamanlamalarını daha etkili bir şekilde anlamak ve yönetmek için kullanılabilecek yeni bir yaklaşım sunmaktadır. Araştırmalar, daha yüksek tahmin doğruluğu elde etmek için çeşitli ML tekniklerini geleneksel istatistiksel modellerle birleştiren hibrit modeller geliştirmeye odaklanmıştır. Yaseen vd. (2020) rastgele orman yöntemi ile genetik algoritma optimizasyonunu birleştiren bir hibrit model sunarak geleneksel gecikme tahmin yöntemlerinin sınırlarını zorlamıştır. L. Chen vd. (2023) tahmin modellerini iyileştirmek için Monte Carlo simülasyonunun ML ile birleştirilmesini incelemiştir.

Ancak, geliştirilen ML modelleri ilerleme tahmin modellerinin zamansal bileşenini ihmal etmiştir. Buna karşılık, araştırmalar görev sıralamasını ve gecikme tahminini iyileştirmek amacıyla zaman serisi ML yaklaşımlarını kullanmıştır. Örneğin, Amer & Golparvar-Fard (2019) gelişmiş sıralama ve zamanlama tahminleri için uzun kısa süreli bellek (Long Short-Term Memory, LSTM) ile birlikte tekrarlayan sinir ağlar (Recurrent Neural Networks, RNN) (LSTM-RNN) uygularken Alikhani vd. (2023) ise tek başına LSTM modellerini kullanmıştır. Ek olarak, Cheng vd. (2011) ve Chao & Chien (2009), S-eğrisi tahminlerinin güvenilirliğini artırmak için sinir ağları ve kısa aralıklı dinamik tahmin tekniklerini uygulamışlardır. Geliştirilen zaman serisi ML yöntemleri, dinamik olay dizilerini modelleyerek, basit ML yöntemlerinin gözden kaçırabileceği zamansal bağımlılıkları ve desenleri yakalayabilir. Ancak, bu yöntemler inşaat görevlerinin ağ yapısını (mekansal) ve ilerlemesini (zamansal) aynı anda entegre edememektedirler.

1.3. Problem Tanımı ve Araştırma Boşluğu

İnşaat ilerleme verileri doğası gereği hem mekansal hem de zamansal dinamikleri içermektedir. Öte yandan bu veriler bu iki boyut arasında süre gelen akışı da barındırmaktadır. Bu durum aktivitelerin birbirine bağlı olan doğası gereği bir görevdeki gecikmelerin veya bütçe sorunlarının zincirleme etkiler yaratarak projenin sonraki aktivitelerini etkileyebileceği anlamına gelir. Şekil 1’de mekansal ve zamansal unsurların bir

haftalık ilerleme raporundaki iş kırılım yapısı (Work Breakdown Structure, WBS) ile entegrasyonunu göstererek bu mekansal-zamansal doğanın karmaşıklığını gösterilmektedir.



Şekil 1. Bir haftalık inşaat ilerleme raporunun yapısı, mekansal ve zamansal unsurların WBS görevleri ile entegrasyonu ve bunun proje zamanlaması ve bütçe kararlarına olan etkileri.

Bu karmaşık ilişkileri yöneten modellerin geliştirilmesindeki zorluk, ilerleme verilerini zamanlama bilgisiyle etkili bir şekilde birleştirmekte yatmaktadır. Bu tür modellerin, hem bir WBS aracılığıyla mekansal organizasyonu hem de proje süresi boyunca zamansal takibi ele alması gerekmektedir (X. Zhang vd., 2009). Kısa dizili inşaat aktivite ilerleme kayıtlarını yönetmek ve yorumlamak zorlayıcıdır, özellikle birçok görev yeterince uzun sürmediğinde anlamlı diziler oluşturmak için gerekli olan verilerin azlığı, bu tür veri kümelerinden etkili bir şekilde öğrenebilecek modellerin yapılandırılmasını zorlaştırmaktadır.

Aktiviteler arasındaki karmaşık bağımlılıkları dikkate alarak inşaat ilerlemesini doğru bir şekilde tahmin edebilen mekansal-zamansal ML modelleri geliştirmede önemli bir

araştırma boşluğu bulunmaktadır. Mekansal ve zamansal ML modelleri, inşaat projelerinin planlanması ve izlenmesi için temel sağlamaktadır. Ancak bu modeller dinamik maliyet ve zamanlama performans verilerini içeren birleşik bir mekansal-zamansal yaklaşımın potansiyelini tam anlamıyla kullanmamaktadırlar. Bu yöndeki çalışmalarda görülen bazı yenilikçi sinir ağı yapılandırmaları ile LSTM birimlerini içeren uygulamalarla ilerleme kaydedilmiş olsa da (Alikhani vd., 2023; Amer & Golparvar-Fard, 2019), uzun sıralı verilerin nadirliği birleşik bir mekansal-zamansal yaklaşımın geliştirilmesinde önemli engeller oluşturmaktadır. Bu yönde geliştirilecek olan mekansal-zamansal modellerin avantajları trafik tahmini gibi uygulamalar da dahil olmak üzere ortaya koyulmuştur (Roy vd., 2021; Yu vd., 2018).


Ayrıca, mevcut inşaat yönetimi literatüründeki modeller genellikle model performansını doğruluk ve F1 skoru gibi performans metriklerine göre değerlendirmektedir. Ancak, H. Zhang vd. (2024) ve NIST (2022) 'de vurgulandığı üzere özellikle büyük inşaat şirketleri için siber saldırılara karşı dayanıklı modeller geliştirmek kritik önem taşımaktadır. Y. Chen vd. (2023) tarafından gerçekleştirilen düşman saldırı analizi, maliyet açısından hassas dönemlerdeki küçük değişikliklerin sistem işletme maliyetlerini artırdığını göstermiştir. Bu durum, geliştirilecek ML modellerinin değerlendirilmesinde, veri zehirlenmesi(manipülasyonu) gibi çeşitli ataklar altında modelin güvenilir performansını sürdürebilme gerekliliğini ortaya koymaktadır. İnşaat projelerinin birbirine bağlı yapısı ve rekabetçi sektör ortamı, projenin zamanında ve güvenli bir şekilde tamamlanmasını sağlamak için doğru tahminlerin yapılmasını zorunlu kılmaktadır. Veri bütünlüğündeki herhangi bir ihlal, proje gecikmeleri, maliyet aşımaları ve güvenlik tehlikeleri gibi ciddi sonuçlara yol açabilmektedir.

Bu araştırma boşluklarını gidermek için mekansal ve zamansal verileri etkili bir şekilde birleştirerek olası aksamalara karşı yüksek veri bütünlüğü ve dayanıklılığı sağlayan modellerin geliştirilmesine ihtiyaç duyulmaktadır. Bu yönde geliştirilecek olan doğru ve temsil edici bir ilerleme tahmin modeli, inşaat alanında ortaya çıkabilecek çeşitli sorunlara karşı dayanıklı olmalıdır. Bu sorunlar arasında doğruluk hataları, düşmanca manipülasyonlar, hatalar, eksik değerler, farklı paydaşlar tarafından tutulan kayıtlardaki önyargılar vd. sorunlar bulunmaktadır. Bu tür modellerde kullanılan verilerin bütünlüğü kritik öneme sahiptir. Aksi durumda bozulan veri kalitesi modelin tahmin performansını önemli ölçüde etkileyebilmektedir.

1.4. Önerilen Çözüm ve Araştırma Amacı

Mekansal-zamansal veriler, inşaat aktivitelerinin daha ayrıntılı ve dinamik bir temsilini sunarak görevlerin zamansal ilerlemesini ve mekansal dağılımını yansıtmaktadır. Bu çift yönlü yetenek, görevlerin birbiriyle bağlantılı olduğu ve zaman içerisinde ilerleyen inşaat projelerinin yönetiminde özellikle faydalıdır. Bu çalışma, inşaat proje yönetiminde projelerin maliyet ve süre performans göstergeleri olan CPI ve SPI tahmininde mekansal-zamansal verileri sistematik olarak araştırarak, etkinliklerini kapsamlı bir şekilde değerlendiren model çerçevesi önerisi temeli üzerine gerçekleştirilmiştir. Şekil 2, bu çalışmada geliştirilen mekansal-zamansal CPI ve SPI tahmin modellerinin yapılandırılması sürecini özetlemektedir.

Şekil 2'de gösterildiği gibi, model kurulumunun ilk aşaması proje yaşam döngüsü boyunca inşaat ilerleme verilerinin sistematik olarak toplanmasıyla başlamaktadır. Bu aşama, planlanan maliyet ve zamanlamadan sapmaları değerlendirmek için kritik olan “inşa edildiği gibi” ve “planlandığı gibi” verilerin toplanmasını içerir. Verilerin toplanmasından sonraki kritik adım, bu ilerleme kayıtlarını yapılandırılmış Excel dosyalarından ilişkisel grafik yapılı veri formatlarına dönüştürmektir. Bu dönüşüm, inşaat kayıtlarının düğümler olarak saklandığı ağların oluşturulmasına olanak tanımaktadır. Düğümler arasındaki bağlantı WBS ve ilerleme raporlarına dayanılarak kurulmuştur. Bunun arkasındaki neden, WBS'in ne yapılması gerektiğini düzenleyen hiyerarşik yapısı ile ilerleme raporlarının görevleri belirli zamanlara bağlayan zamansal bakış açısını bir araya getirmektir. Üçüncü aşamada, mekansal-zamansal tahmin modelleri yapılandırılmış, değerlendirilmiş ve en güvenilir mimariler olası proje bütçe aşımı ve süre gecikmelerini tahmin etmek için seçilmiştir. Bu çalışma bu yönü ile inşaat sektöründe mekansal-zamansal ML modellerini detaylı inşaat ilerleme planlamasına yönelik seçme ve doğrulama konusunda kapsamlı bir çerçeve sunarak öncülük etmektedir. Bu amaçla bu tez çalışmasında başlangıçta WBS tabanlı ilerleme kayıtları ile en gelişmiş mekansal-zamansal modelleri eğitilmiş ve bu modeller SPI ve CPI göstergelerini kullanarak sınıflandırılmıştır. Ardından, RNN, LSTM, geçitli tekrarlayan birimler (Gated Recurrent Units, GRU), grafik evrişimli ağlar (Graph Convolutional Networks, GCN), grafik dikkat ağları (Graph Attention Networks, GAT) ve geçitli mekanizmalar gibi çeşitli kombinasyonlar kullanılarak gelecek ayın CPI ve SPI göstergelerini tahmin edecek en uygun mekansal-zamansal ilerleme tahmin modelleri seçilmiştir.



Şekil 2. Veri toplama ve mekansal-zamansal model yapılandırma süreci akış şeması.

Bu modeller, önceki aşamalarda sağlanan dinamik ve karmaşık veri yapısını ele alabilecek kapasitede olup daha zengin içerikli inşaat ilerleme kayıtlarından da öğrenebilme yeteneğine sahip olmaktadır. Geliştirilen modellerin tahminlerinden elde edilen bilgiler, bütçe ve zamanlamaya proaktif ayarlamalar yapılmasını kolaylaştırarak, riskleri en aza indirme ve inşaat projesinin yönetimini iyileştirme amaçlı kullanım potansiyeline sahiptirler. Model tahminlerinin yönetsel karar alma süreçlerine entegrasyonu, inşaat projelerinde

doğuştan var olan belirsizliklerin yönetilmesini iyileştirmektedir. Yapılandırılmış model, her inşaat aktivitesinin mevcut ilerleme performansına dayalı olarak yaklaşan ilerleme beklentilerinin doğruluğunu değerlendirmek amacıyla inşaatın erken aşamalarındaki ilerleme kayıtları üzerinde eğitilmiştir. Böylelikle inşaat projesinin her aşamasının izlenerek gerçek ilerlemenin stratejik hedeflerle etkili bir şekilde uyumlu hale getirilmesi hedeflenmiştir.

Sonrasında, mevcut performans tahmin metriklerinin ötesine geçilerek, iki ek performans değerlendirmesi çalışması gerçekleştirilmiştir. İlk olarak, modelin farklı gerçek inşaat projelerinden elde edilen mekansal-zamansal veri setleri üzerinde sağlamlılık ve uygulanabilirlik testi yapılmıştır. İkinci olarak, geliştirilen mekansal-zamansal modellerin güvenilirliğini artırmak için modeller veri hataları ve saldırıları altında (veri zehirlenmesi, etiket değiştirme ve hızlı gradyan işaret yöntemi (Fast Gradient Sign Method, FGSM) dahil olmak üzere) doğruluk, F1 skoru ve AUC açısından titizlikle test edilmiştir.

Bu yaklaşımın inşaat ilerleme tahminlerinin doğruluğunu artırmanın ötesine geçerek inşaat profesyonellerine proje risklerini yönetmek ve genel proje performansını iyileştirmek için güvenilir bir araç sunması beklenmektedir. Bu tez çalışmasının inşaat mühendisliği ve inşaat proje yönetimine sağlayacağı katkılar şu şekilde özetlene bilmektedir:

- Veri Seti: Önerilen mekansal-zamansal modelin etkinliği, bu araştırma tarafından farklı lokasyonlarda ve farklı zaman dilimlerinde gerçekleştirilen projelerden toplanan kapsamlı bir veri setleri üzerinde gösterilmiştir. 175 haftadan fazla inşaat ilerleme kaydı içeren 2 milyon veri kaydı çıkarılmış ve 1000'den fazla inşaat aktivitesini içeren veri seti oluşturulmuştur. Bu veri seti, 40'tan fazla farklı dinamik ve statik mekansal-zamansal modelin kapsamlı bir şekilde değerlendirilmesini sağlamıştır.
- Mekansal-Zamansal Girdi Ağlar: WBS ve aktivitelerin ilerleme raporlarına dayanan hem zaman hem de mekansal bağımlılığı içeren bir girdi ağı ilk kez geliştirilmiştir. Bu girdi ağı, inşaat ilerleme performansı kayıtlarının mekansal ve zamansal dinamik yönlerini öğrenmek için daha temsil edici bir araç sağlamaktadır.
- Mekansal-Zamansal Modeller: İnşaat proje performansını tahmin etmek için mekansal ve mekansal-zamansal ML modelleri ilk kez yapılandırılmıştır. Bu yaklaşım, aktivitelerin iş kırılım yapısına dayalı olarak hem mekansal hem de zamansal bağımlılıkları kapsayan benzersiz bir girdi ağından yararlanmaktadır. Önceki çalışmalar, mühendislik alanında mekansal-zamansal modeller uygulamış ancak inşaat

aktivitelerinin mekansal bağımlılıklarını veya kayıtlar içindeki eşzamanlı zamansal bağımlılıkları ele almamıştır.

- Performans Değerlendirme Metrikleri: Bu çalışma, ML modellerinin etkinliği için kullanılan geleneksel doğruluk metriklerinin ötesine geçerek, modellere saldırılara karşı dayanıklılık, yorumlanabilirlik ve açıklanabilirlik önlemlerini entegre eden ilk çalışmadır. Bu özellikler, uygulayıcılar için daha güvenilir bir model oluşturmaya katkıda bulunmaktadır.
- Hibrit Veri Seti: Bu tez çalışmasında üretici çekişmeli ağlar (Generative Adversarial Networks, GAN) ve varyasyonel otomatik kodlayıcılar (Variational Autoencoders, VAE) gibi üretici modelleri incelenerek, GAN ve VAE gibi üretici modeller aracılığıyla hibrit mekansal-zamansal inşaat ilerleme performansı tahmin modelleri geliştirilmiştir. Bu, mekansal-zamansal tahmin modellerinde sınıf dengesizliği gibi sorunları çözmek ve modellerin veri zehirlenmesi ve düşmanca saldırılara karşı dayanıklılığını artırmak için yapılan bir incelemedir.


Genel olarak, bu tez çalışması yalnızca inşaat ilerleme tahminlerinin doğruluğunu artırmayı amaçlamakla kalmayıp, aynı zamanda inşaat profesyonellerine proje risklerini yönetmek ve genel proje performansını değerlendirerek iyileştirmek için güvenilir bir model sunmaktadır.

1.5. Teknik Arka Plan

1.5.1. Makine Öğrenimi Modelleri

Son yıllarda, inşaat sektörü ve akademik literatür özelleştirilmiş AI çözümleri ve ML modellerinde önemli bir artışla karşı karşıya kalmıştır. Artan hesaplama gücü ve bunun sonucunda ortaya çıkan daha gelişmiş ML teknikleri, karar vermeyi iyileştirerek daha sürdürülebilir ve verimli bir sektörün oluşmasına olanak tanımıştır (Garcia vd., 2022). ML inşaat sektöründe dönüştürücü bir potansiyele sahiptir (Datta vd., 2024) ve karmaşık zorluklarla başa çıkmada etkili bir araçtır (Garcia vd., 2022). Şekil 3'te inşaat proje yönetiminde karar destek araçları olarak kullanılan ML modellerinin gösterimi yer almaktadır. İnşaat mühendisliği (Alpaslan vd., 2024; Hacıfendioğlu vd., 2022; S. Mostofi & Altunişik, 2024a) ve inşaat yönetimi (Avci, 2024; Candaş & Tokdemir, 2022a, 2022b; F. Mostofi vd., 2023, 2024; F. Mostofi & Toğan, 2023d; Zhong vd., 2019) alanında

karşılaşılabilen karmaşık zorlukların üstesinden gelmek için ML yaklaşımları karar destek aracı olarak kullanılmıştır.



Şekil 3. İnşaat proje yönetiminde karar destek araçları olarak ML modelleri.

ML teknikleri ilk olarak 1990'ların başlarında bina enerji sektöründe uygulanmış olsa da inşaat izleme alanındaki kullanımı nispeten yenidir ve tam potansiyeli henüz tam anlamıyla keşfedilmemiştir (Pour Rahimian vd., 2020). Garcia vd. (2022) inşaat yönetiminde ML'in kullanım alanlarına odaklanmış ve proje yönetimi, kontrol ve teslimatının ML'in kullanılabileceği kritik alanlar olarak tanımlamıştır (Garcia vd., 2022). Q. Hui Liu & Cao (2024) maliyet kontrolünü inşaat öncesi, inşaat süreci ve inşaat sonrası olarak üçe ayırarak inşaat sürecindeki maliyet kontrolünü en hayati olarak değerlendirmiştir.

İnşaat ilerlemesini tahmin etmek için kullanılan bir ML prosedürü maliyet kayıtlarının toplanması ve ön işlenmesiyle başlamaktadır. Bu kayıtlar tablosal bir formatta her kayıt bir satır, her özellik bir sütun olarak yapılandırılır. Veri seti eğitim ve test setlerine ayrılır. Test seti için bu tablonun bir kısmı, çıktı vektörü $\mathbf{Y}$ 'yi tahmin etmek amacıyla giriş matrisi $\mathbf{X}$ olarak kullanılır ve bu durum Denklem (3) ile formüle edilir.

$$\mathbf{X} = \begin{bmatrix} x_{11} & \cdots & x_{1d} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nd} \end{bmatrix}, \mathbf{Y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \quad (3)$$


$$x_{ij} \in R^{n \times d}, \forall i = 1, 2, \dots, n, \forall j = 1, 2, \dots, d, y_i \in R^n, \forall i = 1, 2, \dots, n$$

$\mathbf{X}$ ($n \times d$) boyutlarında bir giriş matrisi ve $\mathbf{Y}$ (n) boyutlarında bir çıktı vektörüdür. Burada n ve d , inşaat ilerleme kayıtlarının sayısını temsil eder. ML modeli, çeşitli optimizasyon ve aktivasyon fonksiyonları aracılığıyla geri bildirim almak ve iyileşmek için bir kayıp fonksiyonu kullanır.

1.5.2. Grafik Sinir Ağlar (GNN) Modelleri

Bu çalışmada kullanılan ML tekniklerinin seçimi ve tahmin modelinin formülasyonu mevcut literatürdeki bulgularla desteklenmiştir. ML tekniklerindeki son gelişmeler, grafik sinir ağlar (Graph Neural Networks, GNN) yaklaşımlarını kullanarak ilişkisel modellemeyi kolaylaştırmıştır. GNN'ler özellikle grafik tabanlı görevler için tasarlanmış derin öğrenme yaklaşımlarıdır. GNN'ler grafik yapıları aracılığıyla bilgi toplayarak verilerin yüksek seviyeli temsillerini oluştururlar (Xa vd., 2022). Mesaj geçiş mekanizmasıyla grafik yapıları verilerden öğrenme yeteneği olan GNN'ler, çeşitli alanlarda en son gelişmeleri ileriye taşımakta ve güçlü, gelişmiş sinir modelleri olarak öne çıkmaktadır (Corso vd., 2024; J. Zhou vd., 2020).

GNN'ler grafik verileri için özel olarak optimize edilmiş, evrimsel sinir ağlarının (Convolutional Neural Networks, CNN) veya derin sinir ağlarının (Deep Neural Networks, DNN) gelişmiş bir varyantı olarak düşünülebilir (Tang vd., 2020). GNN'ler grafik biçiminde temsil edilen verilerden yüksek seviyeli soyutlamaları öğrenme yeteneğini kullanarak, derin öğrenmenin gücünden yararlanır. Mekansal-zamansal modeller, mekansal ve zamansal verilerin birbirine bağımlı olduğu karmaşık sistemlerin davranışını tanımlamak ve tahmin etmek için tasarlanmış sistemlerdir (Mercieca & Kadirkamanathan, 2016). Şekil 4 CNN'lerin Öklidyen veri kümeleri (ör. görüntüler) ile GNN modellerindeki Öklidyen olmayan veri kümeleri (ör. ağ) arasındaki farkları görselleştirmektedir.



Şekil 4. Öklidyen ve Öklidyen olmayan veri kümeleri.

Şekil 4'te görüldüğü gibi, GNN'lerin benzersiz mimarisi hem DNN'lerin hem de grafik teorisinin ilkelerini içermektedir. DNN'ler geleneksel ML modellerine kıyasla üstün performans sergilerken, GNN'ler, nesneler arasındaki ilişkilerin doğru tahminler için kritik olduğu görevlerde DNN modellerine tercih edilmektedir (Vatter vd., 2024). Denklemler (4)-(6) ile her ağdaki düğüm (V) bir proje içindeki belirli bir inşaat görevini temsil ederken, kenarlar (E) bu görevler arasındaki ilişkileri paylaşılan WBS ve ilerleme raporlarına dayalı olarak temsil eder.

$$V = \begin{bmatrix} V_{11} & V_{1n} \\ \vdots & \vdots \\ \vdots & \dots & \vdots \\ V_{1m} & V_{mn} \end{bmatrix}, \quad V = \text{Düğüm veri kümesi} \quad (4)$$

$$E = \begin{bmatrix} E_{11} & E_{1p} \\ \dots & \dots \\ E_{21} & E_{2p} \end{bmatrix}, \quad E = \text{Kodlanmış kenar veri kümesi} \quad (5)$$

$$\text{Girdi ağı} = f(V, E) \quad (6)$$

Her düğümün başlangıç temsili komşu düğümlerle olan etkileşimler yoluyla güncellenmektedir. Model, inşaat görev düğümlerini (Denklem 4) ve bağlantılarını (Denklem 5) işleyerek, inşaat ilerlemesindeki tutarsızlıkları tahmin ederken, bir görevdeki değişikliklerin diğer bağlı görevleri nasıl etkileyebileceğini göz önünde bulundurmaktadır.

Ağ yapısına sahip verilerin derin temsil öğrenmedeki üstün yeteneği nedeniyle GNN geniş çapta araştırma ilgisi görmüş (Q. Hu vd., 2022; Y. Zhang, 2020) ve daha zengin ve

daha alakalı özellik temsillerinin çıkarılmasını sağlamıştır (F. Mostofi vd., 2023; F. Mostofi & Toğan, 2023b). GNN'nin kullanımı node2vec (Avci, 2024; F. Mostofi & Toğan, 2022a, 2023a), GAT (F. Mostofi & Toğan, 2023b; Y. Pan vd., 2022), mekansal-zamansal GCN'ler (Gao vd., 2023) ve GRU (H.-B. Liu, 2020) ile ilişkilendirilerek önemli ilerlemeler kaydetmiştir. Bu tür tekniklerin kullanımı GNN'in karmaşık Öklidyen olmayan veri kümelerini işleme kapasitesinde önemli iyileştirmeler göstermiştir (J. Zhou vd., 2020). Bu ağlar içindeki evrişim mekanizmalarının GNN ile entegrasyonu, grafik yapısındaki verilerle çalışan modellerin tahmin yeteneklerini artırmıştır (F. Mostofi vd., 2024; F. Mostofi & Toğan, 2023d). Mühendislik ve inşaat yönetimi araştırmaları GNN'lerin inşaat yönetimi ve iş güvenliği alanındaki çok yönlü zorlukları ele alma konusundaki uyarlanabilirliğini vurgulamıştır (Gao vd., 2023; J. Liu vd., 2022; F. Mostofi vd., 2023, 2024; F. Mostofi, Toğan, vd., 2022a; F. Mostofi & Toğan, 2023d; X. Yan vd., 2019).

GNN'ler veriler içindeki karmaşık ilişkileri yakalamada ve karmaşık sistemleri temsil etmede oldukça yeteneklidir (Mostofi & Toğan, 2022a; H. Zhang vd., 2024). GNN modelleri verilerin yorumlanabilirliğini ve temsil edilebilirliğini artıran daha iyi görselleştirme yetenekleri sunarlar (Xia vd., 2022). Bu yetenekler değişkenler arasındaki ilişkilerin karmaşık ve birbirine bağımlı olduğu mekansal-zamansal modelleme için özellikle uygundur. Grafik veya ağ inşaat görev bilgilerini, görev tanımı, türü ve kategorisi gibi proje özelliklerini düğümlerinde, farklı inşaat görevleri arasındaki ilişkiler hakkında bağlantı bilgilerini de kenarlarda saklarlar. Grafik temsili öğrenmenin sunduğu zengin bilgi, zaman ve maliyet ilerleme tahmin modellerinin daha yüksek doğrulukla geliştirilmesine olanak tanımıştır (Hamilton, 2020).

GNN'ler grafik biçiminde verileri temsil etme ve bu veriler üzerinde akıl yürütme konusundaki doğal yetenekleri nedeniyle geniş bir uygulama alanında faydalı olduklarını kanıtlamıştır. GNN'ler grafik verilerinin bağlantıları ve özelliklerinden öğrenme yeteneği sayesinde karmaşık ağları da ele alabilirler (Veličković, 2023). Önceki çalışmalar GNN'lerin özellikle mekansal bilgiyi kullanmayı gerektiren karmaşık görevlerde rastgele orman (Random Forest), Naïve Bayes ve çok katmanlı algılayıcılar gibi yaygın olarak benimsenmiş ML modellerini geride bıraktığını göstermiştir (T. Chen, 2023). Ağ yapısı projeleri ve bunların stratejik hedeflerle olan ilişkilerini belirgin bir şekilde gösterirken bir portföy içindeki projeler arasındaki karmaşık etkileşimleri kapsayan bütünsel bir görselleştirme aracı sağlarlar. GNN'lerin gerçek hayatta mühendislik verilerinde yaygın olan Öklidyen olmayan

verileri (BIM ve taranmış nokta bulutları gibi) yönetmedeki çok yönlülüğü ortaya konulmuştur (Jia vd., 2023; Yao vd., 2019).

GCN ve GAT en yaygın kullanılan GNN modelleri arasında öne çıkmaktadır (Khemani vd., 2024). GCN, CNN'in evrişim katmanlarını genelleştirerek bilgi bağımlılıklarını öğrenebilir ve son yıllarda çeşitli mühendislik ve inşaat yönetimi uygulamalarında incelenmiştir (F. Mostofi vd., 2023; F. Mostofi, Toğan, vd., 2022a; X. Pan vd., 2022; Tian vd., 2022). GCN farklı tahmin görevleri için Öklidyen olmayan veri yapısına sahip grafik yapıları veri kümelerini öğrenme yeteneğine sahiptir (Zhou vd., 2020). GAT'ler ise GCN'lere göre iyileştirme sağlayarak komşu düğümlerin özelliklerine farklı ağırlıklar atayan bir dikkat mekanizması uygular (Jing vd., 2021). Bu dikkat mekanizması sayesinde GAT'ler ağ yapıları verileri işlemek için daha esnek ve güçlü bir yaklaşım sunar (Mostofi & Toğan, 2023b). GAT modelleri düğümlere farklı önem seviyeleri tahsis edebilir, bu da daha bağlamsal ve hassas düğüm temsillerinin öğrenilmesine olanak tanır ve daha doğru tahminler sağlar (Veličković vd., 2018; Mostofi & Toğan, 2023b). Son araştırmalar, GCN'lerin yeniden işleme maliyet sonuçlarını tahmin etmekte nasıl kullanıldığını göstermiştir (F. Mostofi vd., 2023).

GNN'lerin karmaşık veri yapılarını çözmedeki faydaları, GCN modellerinin bina desen tanıma doğruluklarını artırma yetenekleriyle kanıtlanmıştır (Yao vd., 2019; X. Yan vd., 2019). Benzer şekilde, Yao vd. GNN'in üstünlüğünü göstererek TextGCN modelinin kelime ortak görünürlüğü ve belge kelime ilişkilerini kullanarak etkili metin sınıflandırması sağladığını vurgulamıştır (Yao vd., 2019). Öte yandan, Z. Wang vd. (2022) GraphSAGE'in gelişmiş bir versiyonu olan SAGE-E algoritmasını geliştirerek GNN'lerin etkinliğini göstermiştir. Bu algoritma, BIM modellerinin anlamsal zenginleştirilmesiyle daha yüksek doğruluk ve hesaplama verimliliği sağlamıştır. GNN'yi tahmin modeli olarak seçme mantığı, H. Kim ve Kim (2020) tarafından yapılan karşılaştırmalı çalışmalarla daha da güçlendirilmiştir. Bu çalışma, dinamik bir GCN'in köprü bileşenleri için doğruluk sunduğunu ve dikkat mekanizmasının, düğüm durumlarına dayalı olarak adaptif kenar ağırlığı tahsis etmesine olanak tanıdığını ortaya koymuştur.

Ayrıca, grafik yapıları veri kümesine zamansal ilerleme bilgilerinin eklenmesi, geleneksel tablo veri kümelerinden çok daha zengin içeriklere sahip bir inşaat görevi ağı oluşturur. Zamansal ilerleme bilgilerinin eklenmesi RNN ve Bi-RNN gibi sıralı verileri öğrenen derin öğrenme mekanizmalarıyla popüler olan zaman serisi ML modelleri aracılığıyla yapılabilmektedir. RNN önceki zaman adımlarını yakalayarak gizli durumu koruyan bir


zaman serisi modeli (Graves, Mohamed vd., 2013) iken Bi-RNN her biri için ayrı gizli katmanlar kullanarak zaman serisi verilerini hem ileri hem de geri yönlerde işleyebilen (Graves, Jaitly vd., 2013) bir zaman serisi modelidir.

1.5.3. Mesaj Geçiş Sinir Ağlar Modeli (MPNN)

Gelişen ilk GNN modellerinden biri mesaj geçiş sinir ağı modeli (MPNN) olmuştur (Gilmer vd., 2017). MPNN, çeşitli GNN'ler için mesaj geçiş şeması aracılığıyla geliştirilmiş bir yaklaşım sunmuştur. MPNN'ler inşaat aktivite düğümlerinin komşuluğundan bilgi toplamak ve bu düğümün özelliklerini öğrenmek için mesaj geçiş paradigmasını kullanırken, farklı grafik veri türlerine ve görevlere uyarlanabilen özelleştirilebilir bir toplama fonksiyonu kullanmıştır. MPNN'ler farklı alanlarda iyi tahmin performansı sergilemiştir. Örneğin, Gilmer vd. (2017) pahalı 3D yapısal bilgilere ihtiyaç duymadan moleküler özellikleri tahmin etmek için MPNN'yi yoğun bir sinir ağı modeli ile birleştirerek geniş 2D bileşik kütüphanelerinin hızlı sanal taramasını mümkün kılmıştır. Son vd. (2021) MPNN'yi kablolu köprülerde kablo durumlarını değerlendirmek, hasarlı kabloları tespit etmek ve kesit alanındaki azalmayı tahmin etmek için kullanmıştır.

H. He vd. (2024) ise 5G ve gelecekteki 6G ağları için hibrit bir MPNN yapılandırmış ve MPNN'lerin kablosuz iletişim sistemlerinin fiziksel katmanında kullanılan algoritmaların verimliliğini ve uyarlanabilirliğini artırma potansiyeli olduğunu vurgulamıştır. Geleneksel modeller olan XGBoost ve çok katmanlı algılayıcılar (Multi-layer Perceptron, MLP) gibi modelleri geride bırakmalarına rağmen (Son vd., 2021), MPNN'ler henüz inşaat yönetimi çalışmalarında kullanılmamıştır. Bunun nedeni, inşaat yönetimi verilerinin moleküler yapılar veya sosyal ağlardaki gibi fiziksel ve açık grafik formatında olmamasıdır.

Bu çalışmada yapılandırılan model, geliştirilmiş mesaj geçiş şemasının bir uygulamasıdır. Şekil 5 MPNN katmanlarının ve ilgili dönüşüm adımlarının ayrıntılı yapısını göstermektedir.



Şekil 5. CPI ve SPI'yi tahmin etmek için yapılandırılan MPNN modelinin mimarisi.

Şekil 5'te gösterildiği gibi, MPNN bu çalışmada yapılandırılan mekansal-zamansal modeller arasında en basit GNN mimarilerinden birine sahiptir. Model, mesaj geçişi katmanı ile başlar; burada inşaat aktivite düğümlerinin özelliklerinde saklanan bilgiler, aynı hafta içinde teslim edilen ve aynı WBS grubuna ait olan bağlantılı aktivite düğümlerine (komşu düğümler olarak kabul edilir) iletilir. MPNN, bu mesaj geçişi sürecini nispeten parametresiz bir işlemle gerçekleştirir ve tamamen her haftada aktivite düğümlerinin nasıl bağlandığına dayanır. Düğümler, özelliklerini bitişik düğümlere iletir ve bu düğümler toplama işlemiyle birleştirilir. Toplanan mesajlar, düğüm özelliklerine lineer bir dönüşüm uygulayan lineer dönüşüm katmanına girdi olarak hizmet eder ve bu işlem sırasında özellik boyutları ağırlıklarla değiştirilir. Bu katman öğrenilen ağırlıklar kullanılarak verilerin lineer olarak dönüştürüldüğü tam bağlantılı basit bir sinir ağı katmanıdır. Genellikle bu katmana öğrenme sürecinde daha karmaşık desenlerin yakalanmasına yardımcı olan düzeltilmiş doğrusal birim (Rectified Linear Unit, ReLU) (Agarap, 2018) gibi bir doğrusal olmayan aktivasyon fonksiyonu eklenir. Bu dönüşümün ardından aşırı öğrenmeyi önlemek amacıyla bazı girdilerin rastgele sıfırlandığı bir Dropout katmanı gelir. Son adımda, her aktivite

düğümünün gömme (Embedding) vektörleri toplanarak güncellenir ve düğüm gömme vektörleri oluşturulur.

1.5.4. Grafik Evrişimli Ağlar (GCN)

Grafik yapıları öğrenmek için ölçeklenebilir yarı denetimli bir model olarak tanıtılmış olan GCN (Kipf & Welling, 2016) hem en güçlü (Cui vd., 2024) hem de popüler GNN modellerinden biri olarak kabul edilmektedir. Bu model son dönemde mühendislik ve inşaat yönetimi (F. Mostofi vd., 2023; F. Mostofi, Toğan, vd., 2022a; F. Mostofi & Toğan, 2023d; Ogoke vd., 2020; Yao vd., 2019), inşaat güvenliği tehlikelerini tahmin etme (F. Mostofi, Toğan, vd., 2022a; F. Mostofi & Toğan, 2023d) ve güvenlik metinlerini sınıflandırma (Pan vd., 2022; Tian vd., 2022) gibi alanlarda kullanılmıştır. GCN grafik yapıları veri setlerini işleyerek ilişkisel kayıtlara sahip gerçek yaşam verilerini daha iyi temsil eder ve böylece daha yorumlanabilir bir tahmin modeli sağlar (F. Mostofi vd., 2023). GCN sosyal öneriler (L. Wu vd., 2018), makale atfı (Abu-El-Haija vd., 2019; Liao vd., 2019), kimya (Liao vd., 2019), sosyal ağlar (L. Chen vd., 2020), inşaat kalitesi kusurunun maliyete etkisini tahmin etme (F. Mostofi vd., 2024), karar verme süreçlerine yardımcı olma (F. Mostofi vd., 2023) ve inşaat güvenliği tahmini (F. Mostofi vd., 2022a; F. Mostofi & Toğan, 2022b; X. Pan vd., 2022) gibi geniş bir uygulama alanında başarı göstermiştir.


Yüksek seviye temsili çıkarmak amacıyla GCN birden fazla grafik evrişim katmanı boyunca komşu bilgilerin yinelemeli olarak toplanmasını gerçekleştirir (H. Chen vd., 2021). Bu GCN'nin hem düğüm hem de komşu özelliklerini öğrenmesine ve ardından grafik yapıları verilerde temsiller oluşturmaya olanak tanır. Her evrişim işleminde düğümlerde depolanan inşaat ilerleme özellik bilgileri ile bağlantı kenarlarının indeksleri aktarılır ve ağ boyunca bilgi yayılır. GCN katmanındaki evrişim işlemi, Denklem (7)'de verildiği şekli ile matematiksel olarak gösterilebilir (Kipf & Welling, 2016).

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (7)$$

Denklem (7)'de her bir katman l 'nin çıktısı, önceki katmandan aktivasyon matrisini alarak, ağı normalleştirilmiş kenar matrisi $\tilde{A}$ 'ya uygulayarak ve ardından mevcut katmanın ağırlık matrisi $W^{(l)}$ ile çarparak hesaplanır. Burada, D derece matrisi ve $H^{(l)}$ önceki katmandan gelen aktivasyon matrisidir.

1.5.5. Grafik Dikkat Ağlar (GAT)

GAT'ler (Veličković vd., 2018) grafik içindeki düğümlerin önemini bağlamsal olarak ağırlıklandıran bir dikkat mekanizmasından yararlanan bir GNN türüdür. GAT'deki dikkat mekanizması, modelin bu kritik bağımlılıklara dinamik olarak odaklanmasını ve onları vurgulamasını sağlar. Bu, GAT modelini farklı görevler arasındaki bağımlılıkların zamanla değişebileceği ve eşit derecede önemli olmayabileceği senaryolar için özellikle uygun hale getirir. Örneğin, projenin erken aşamalarında temel görevler daha fazla ağırlık taşıyabilir ve bu görevlerdeki gecikmeler projenin genel zaman çizelgesi ve maliyetini orantısız şekilde etkileyebilir. Şekil 6'da GAT modelinin mesaj toplama işlemi sırasında kullanılan dikkat mekanizması özetlenmektedir.



Şekil 6. GAT modelinde dikkat mekanizması prosedürü.

GAT modelinin ilk adımı, düğüm ve bağlantı bilgilerini kullanan girdi ağının işlenmesidir. Bu adım, hangi düğümlerin diğerleriyle bağlantılı olduğunu tanımlayarak graf

veri setini düzenler ve verileri sonraki katmanlara hazırlar. İlk işleme aşamasının ardından girdi katmanı yapılandırılır. Bu aşama, girdi verisinin yapısını tanımlamayı, her düğümün belirli veri özelliklerini atamayı ve düğümler arasındaki ilişkileri belirleyen kriterleri oluşturmayı içerir. Ardından, dikkat mekanizması kurulmaya başlanır; bu, daha sonra eğitim sürecinde optimize edilecek parametreler olan ağırlıkların başlatılmasıyla başlar. Her düğüm için dikkat puanları tanımlanır ve bu puanlar, düğüm özelliklerinin birbirine göre önemini belirler. Bu puanlar, modelin eğitim sürecinde her düğümün özelliklerine ne kadar odaklanacağını etkilediği için normalleştirilir. Literatürdeki GAT modelleri genellikle çok başlı dikkat katmanları kullanır; bu katmanlar, farklı konumlarda birçok temsil alt alanından bilgiyi eşzamanlı olarak keşfetmelerini sağlar. Bu paralel yapılandırma, girdi verisinin çeşitli yönlerini yakalamaya yardımcı olur. Birden fazla dikkat mekanizmasının çıktıları birleştirildikten sonra, bir özellik dönüşüm aşaması gelir. Bu aşama, ReLU gibi fonksiyonlar aracılığıyla doğrusal olmayanlık uygulanmasını içerir ve modelin, özellikler arasındaki doğrusal olmayan ilişkileri yakalamasına yardımcı olur. Ek olarak, hesaplama karmaşıklığını azaltmak ve modelin verimliliğini artırmak amacıyla en ilgili özelliklere odaklanmak için boyut azaltma işlemi gerçekleştirilir. Bir sonraki adımda, farklı dikkat başlıklarından elde edilen çıktılar birleştirilir. Bu, çıktıların ağırlıklandırma ve toplama işlemi yoluyla yapılır ve böylelikle her başlığın yakaladığı çeşitli perspektifler tek bir bütünsel çıktı haline getirilir. Bu adım, düğüm özelliklerinin tek bir temsilini üretmek için her dikkat başlığının katkılarını dengelediği için kritik öneme sahiptir. Model, son olarak çıktı katmanını tasarımıyla sonuçlanır. Bu katmanda toplanan özellikler daha fazla işlenerek nihai çıktı üretilir. Bir GAT katmanındaki temel işlem, Denklem (8)'de matematiksel olarak gösterilmiştir.

$$h_i' = \sigma \left(\sum_{j \in N_i} \alpha_{ij} \mathbf{W} h_{ij} \right) \quad (8)$$

Eşitlik (8)'de, σ aktivasyon fonksiyonunu temsil eder. h_i' düğüm i 'nin yeni özellik temsidir. α_{ij} düğüm i ile komşuları j arasındaki hesaplanan dikkat katsayılarını temsil eder. $\mathbf{W}$ her komşunun özelliklerine h_{ij} uygulanan ağırlık matrisidir. N_i ağdaki düğüm i 'nin komşu kümesini belirtir. (Veličković vd., 2018) dikkat mekanizmasını a olarak tanımlamıştır ve bu, aktivasyon fonksiyonu σ 'yı LeakyReLU olarak ayarlayarak doğrusal olmayanlık uygulayan ileri beslemeli bir katmanlı sinir ağı modelidir (Xu vd., 2015). GAT

her düğüm çifti i ve j için dikkat katsayılarını α_{ij} hesaplar. Bir GAT katmanındaki temel işlem, Denklem (9)'da matematiksel olarak gösterilmektedir.

$$e_{ij} = \sigma(a^T (Wh_i \parallel Wh_j)) \quad (9)$$

Burada, i ve j düğüm numaralarını, α_{ij} bu düğümler arasındaki dikkat skorunu, h_i ve h_j düğüm özelliklerini, ve T ve $\parallel$ transpozisyon ve birleştirme işlemlerini ifade etmektedir. Denklem (9)'da aktivasyon fonksiyonu, σ , olarak LeakyReLU aktivasyonunun (Agarap, 2018) alınması durumunda Denklem (9) Denklem (10)'da gösterilen eşitlik ile temsil edilir.

$$e_{ij} = \text{LeakyReLU}(a^T [Wh_i \parallel Wh_j]) \quad (10)$$

Bu denklemde Wh_i ve Wh_j 'nin birleştirilmesi ağın her bağlı düğüm çifti için benzersiz bir dikkat puanı öğrenmesine olanak tanır ve LeakyReLU aktivasyonu (Agarap, 2018) başlangıç katsayıları küçük olan düğümler için bile gradyan akışının sağlanmasına yardımcı olur.

1.5.6. Geçitli Grafik Evrişim Ağlar (GatedGNN)

Dinamik özelliklere sahip grafik yapıları verilerin etkin bir şekilde işlenmesi için geçitli mekanizmaların kullanılmasını tanıtan erken dönem GNN araştırmalarından biri Czakon vd. (2015) tarafından yapılan çalışmadır. Bu çalışma, Scarselli vd. (2009) tarafından tanıtılan ilk GNN modelini temel alarak bunları GRU ve modern optimizasyon teknikleriyle geliştirmiştir. Czakon vd. (2015) grafik yapıları sorunları için bu avantajlı önyargıların ve geçitli mekanizmaların kullanılmasını önermiştir. Entegre edilen GRU'lar, ağ boyunca bilginin akışını yönetmeye yardımcı olmuş ve önemli bilgilerin birden çok yayılma adımı boyunca korunmasını sağlamıştır. Geçitli varyant, RNN veya LSTM gibi tamamen sıralı modellere kıyasla daha avantajlı bir önyargı sunar. Bu durum, geçitli mekanizmanın daha yeni bir GCN modeliyle (Kipf & Welling, 2016) birleştirilmesiyle elde edilen modelin çoklu sensör sinyali birleşimi ve kalan ömür tahmini gibi görevlerdeki başarısından da görülmektedir (L. Wang vd., 2022). GatedGNN modeli ağırlık öneminin komşu düğümler arasında nasıl dağıtıldığını ele alarak, görüntüler arasındaki ilişkileri analiz ederken en önemli bilgilere odaklanmayı sağlar (Yang vd., 2021). Buradan hareketle, Yang vd. (2021)

GCN'nin göğüs röntgeni görüntülerinde en önemli bölgelere daha fazla dikkat etmesini sağlayarak modelin hastalıkları tanımlamadaki performansını artırmışlardır.

1.5.7. Artık Geçitli Grafik Evrişim Ağlar (ResGatedGNN)

ResGatedGNN modeli, GCN modellerinin düğümler arasındaki bilgi akışını kontrol etme yeteneklerini geliştirerek, derin ağların eğitiminde karşılaşılan kaybolan gradyan (Vanishing Gradient) sorununu aşmalarını sağlar. Kaybolan gradyan sorunu, derin katmanlı mimarilerde özellikle sorunlu hale gelen, öğrenmeyi ve yakınsamayı zorlaştıran bir problemdir. Bu sorun, kayıp fonksiyonunun gradyanlarının eğitim sırasında ağ boyunca geri yayılım yaparken üstel olarak sifıra düşmesiyle ortaya çıkar (Roodschild vd., 2020), bu da geri yayılım mekanizmasıyla çok katmanlı sinir ağlarını eğitmeyi zorlaştırır (Ravikumar & Sriraman, 2023). Kaybolan gradyan sorunu hem küçük hem de büyük veri kümelerinde belirgin olsa da daha karmaşık desenleri yakalamak için daha fazla katmanın gerektiği büyük veri kümelerinde etkisi daha da belirgin olabilmektedir. Bu çalışmada, inşaat ilerleme veri setlerinin genellikle birkaç hafta süren ancak her hafta için binlerce kayıt içeren yapıları, inşaat ilerlemesini doğru tahmin etmek için derin mimarileri işleyebilen modeller gerektirir. Bu çalışmada Bresson & Laurent (2017) tarafından önerilen ResGatedGNN modeli incelenmiştir. Bu model, derin ağlarda etkin gradyan akışını sürdürmek için kalıntı bağlantılarını ve geçitli mekanizmaları entegre ederek kaybolan gradyan sorununu aşmayı amaçlamaktadır.

ResGatedGNN modeli, önceki GNN'lerin temel ilkeleri üzerine inşa edilmiştir; bunlar arasında Sukhbaatar vd. (2016) tarafından tanıtılan temel grafik ConvNet'ler ve Marcheggiani & Titov (2017) tarafından geliştirilen kenar geçit mekanizması yer alır. ResGatedGNN modeli, kalıntı bağlantılarını entegre ederek bu mimarileri derin ağ yapıları için optimize eder. GCN'ler, komşu düğümlerden gelen bilgilerin toplanmasına odaklanırken, ResGatedGNN modeli bu süreci bilgi akışını kontrol eden geçitli mekanizmalar ve öğrenme sinyali daha derin katmanlar boyunca koruyan kalıntı bağlantılarla güçlendirir. Bresson & Laurent (2017)'ın bulgularına göre altıdan fazla kalıntı bağlantı katmanı eklenilmesinin performansta %10'luk bir artış sağlamıştır. Bu durum, kaybolan gradyan sorununu aşmada hayati öneme sahiptir.

1.5.8. Tekrarlayan Sinir Ağlar (RNN)

Statik grafiklerle çalışmak daha kolaydır, ancak dinamik grafikler zaman içinde değişen ilişkileri daha doğru bir şekilde modelleyebilir. Ancak bu durumda, veri yapılarının ve algoritmalarının karmaşıklığından dolayı dinamik bir grafiğin geliştirilmesi ve incelenmesi daha zor hale gelmektedir (Scherer, 2024). Zaman serisi ML modelleri, geçmiş değerlerin gelecekteki tahminleri etkilediği sıralı verilerden öğrenmek için tasarlanmıştır. ML modelleri, iki boyutlu tablo verileri, üç boyutlu görüntü verileri ve sıralı veriler (metin ve zaman serisi gibi) gibi farklı veri türlerini öğrenmek üzere evrim geçirmiştir. Zaman serisi verileri üzerinde ML yaklaşımlarını eğitmek, gelecekteki bir değeri tahmin etmek için geçmişteki olaylardan öğrenme ve tahmin yapma imkanı sağlar (Garg vd., 2022). Bu modeller, zamansal bağımlılıkları ele almak ve zaman içindeki desenleri yakalamak için yaygın olarak kullanılır.

RNN'ler, ilk olarak 1980'lerde geliştirilmiş ve o zamandan bu yana özellikle paralel işleme birimlerindeki (GPU gibi) gelişmeler sayesinde yaygın bir şekilde uygulanmıştır (Eskandari vd., 2021). RNN önceki girdiler hakkında bilgi yakalamak için iç durumunu (belleğini) kullanır. RNN modelleri, elektrik yükü tahmini (M. Berglund vd., 2015) gibi farklı denetimli ve denetimsiz zaman serisi uygulamalarında mükemmel performans sergilemiştir (Zheng vd., 2024). Sıralı RNN modeli (Elman, 1991) ile Kipf & Welling (2016) tarafından önerilen daha yeni GCN modelinin kombinasyonu hem sıralı hem de grafik tabanlı veri kümelerini içeren mekansal-zamansal modellerin ortaya çıkmasını sağlamış ve bu model son zamanlarda büyük ilgi görmüştür (Capanema vd., 2023). Örneğin, Elbasani vd. (2021) RNN-GCN'yi bileşikler ve protein dizisi vektörlemesi için modellemede önermiştir. Ek olarak, Bi-RNN olasılıksal yorumlamadaki zorluklarına rağmen, zaman serisi verilerinin hem pozitif hem de negatif yönlerini anlayabilir (M. Berglund vd., 2015).

1.5.9. Uzun Kısa Süreli Bellek (LSTM)

RNN modellerinin bilgiyi her zaman yeniden yazma prosedürünün aksine LSTM bir kapı mekanizması aracılığıyla mevcut bellek durumunun (M. Berglund vd., 2015) korunup korunmayacağına ya da unutulup unutulmayacağına karar verir (Eskandari vd., 2021). RNN modellerinde uzun vadeli bağımlılıkları öğrenme sırasında karşılaşılan kaybolan gradyan sorununu aşmak için bir tür RNN olan LSTM modeli tanıtılmıştır. LSTM, bellek hücreleri

ve bilgi akışını düzenleyen kapı mekanizmalarıyla kaybolan gradyan sorununu ele alır (Eskandari vd., 2021) ve uzun vadeli bağımlılıkları öğrenebilir (Manessi vd., 2020). LSTM birimi, hücre durumu ve gizli durum üzerinden bilgi akışını düzenlemek için üç giriş, unutma ve çıkış kapısından oluşur. Giriş kapısı, önceki zaman adımındaki bilgiyi işler ve bunu unutma ve çıkış kapılarına gönderir (Xing vd., 2023).



1.5.10. Geçitli Tekrarlayan Birimler (GRU)

GRU (Chung vd., 2014), RNN mimarisine sahip olup zamansal bağımlılıkları yakalarken RNN'nin kaybolan gradyan sorununu iyileştirir ve onları daha uzun diziler üzerinde öğrenmeye uygun hale getirir. GRU unutma ve giriş kapılarını tek bir “güncelleme kapısı” ile birleştirirken hücre durumu ile gizli durumu birleştirerek LSTM modelini basitleştirir; bu da daha verimli bir hesaplama modeli ortaya çıkarır. GRU, LSTM mimarisini daha az kapı kullanarak basitleştirir (Eskandari vd., 2021), ancak yine de zaman dizilerini etkili bir şekilde modelleme kapasitesini korur. GCN ile entegre edildiğinde, mekansal ilişkileri modelleyen bu kombinasyon, inşaat ilerleme verilerinden öğrenme konusunda güçlü hale gelir çünkü görevler birbirine bağımlıdır ve görevler gerçekleştirilme sırasından etkilenir.

1.5.11. Mekansal-zamansal Modeller

Mekansal-zamansal modeller geniş anlamda iki türe ayrılabilir: jeoistatistiksel modeller ve dinamik modeller (Mercieca & Kadirkamanathan, 2016). Jeostatistiksel modeller istatistiksel betimlemeler kullanırken, dinamik modeller sistem davranışıyla doğrudan ilişkili fiziksel anlamları olan parametrelerle, zamansal veya mekansal-zamansal evrimi açıkça tanımlamak için fark veya diferansiyel denklemleri kullanır ve bu durum, mekaniksel bir yaklaşım sunar (Mercieca & Kadirkamanathan, 2016). 2018'den bu yana, zamansal konvolüsyonel ağlar (Temporal Convolutional Networks, TCNs) gibi mekansal-zamansal modeller, CNN'lerin paralel işlem gücünü, RNN'nin sıralı veri işleme yetenekleriyle birleştirmiştir. Zamanla değişen girdi özelliklerine sahip grafik yapısı dinamik grafikler olarak kabul edilir (Zhou vd., 2020). Dinamik modeller, parametre tahmininde hesaplama verimliliği ile bilinir ve özellikle kontrol ve mühendislik uygulamaları için uygundur (Mercieca & Kadirkamanathan, 2016; Zhou vd., 2020). Şekil 7 bu çalışmada

yapılandırılan mekansal-zamansal ML modelinin mesaj iletme işleminin basitleştirilmiş bir şemasını sunmaktadır.



Şekil 7. Mekansal ve mekansal-zamansal mesaj iletme işlemi.

Mekansal-zamansal ML modellerinde odak mekansal bileşenin yanı sıra modelin zaman içindeki değişiklikleri nasıl entegre ettiğine kaymaktadır. Bu zamansal boyut modelin düğümlerin ilişkilerinin ve özelliklerinin nasıl evrildiğini anlamasını sağlar. Model, ağı

düğümlemleri ve aralarındaki bağlantıları sırasıyla temsil eden köşeler (V) ve kenarlarla (E) tanımlanan bir başlangıç durumu ile başlar. Düğümler, komşu düğümlerden bilgi toplar ve bu süreç grafikteki yerel yapıların anlaşılmasında kritik bir rol oynar. Model, mekansal mesaj iletmeyi zamansal dinamikleri de içerecek şekilde genişletir. Bu, modelin yalnızca düğümlerin mekansal yapılandırmasını değil aynı zamanda bu yapıların zaman içinde nasıl etkileştiğini de göz önünde bulundurmasına olanak tanır. Başka bir deyişle, model yalnızca mevcut komşu düğümlerden bilgi işlemekle kalmaz aynı zamanda gelecekteki durumları tahmin etmek için geçmiş verileri de entegre eder. Her zaman adımındaki düğümler geçmiş durumlarından gelen verileri işler ve güncellenmiş durumlarını bir sonraki zaman adımına ileterek ağ içinde bir zaman serisi analizi oluşturur.

Modelin mekansal bileşeni evrişim ve dikkat mekanizması gibi GNN teknikleri kullanılarak uygulanır ve modelin verilerdeki yapısal bağımlılıkları anlama ve temsil etme yeteneğini artırır. Öte yandan, zamansal bileşen RNN, LSTM ve GRU gibi zaman serisi modelleriyle ele alınır ve zaman içindeki dizilim dinamiklerini yakalar. Bu bileşenleri entegre ederek modeller hem mekansal hem de zamansal bağımlılıkların önemli olduğu karmaşık veri kümelerine yanıt verebilir. Bu kombinasyon daha kapsamlı ve doğru modelleme yapılmasını sağlayarak derinlemesine içgörüler sunar ve tahmin performansını iyileştirir.

Son araştırmalar, farklı mekansal-zamansal ML modellerinin keşfine yönelik motivasyon sağlamaktadır. Bu modeller, enerji (Gong vd., 2023), yol trafiği (Yu vd., 2018; W. Zhang vd., 2019) ve metro yolcu akışı tahmini (Mulerikkal vd., 2022) gibi çeşitli alanlarda giderek daha fazla uygulanmaktadır. Örneğin, J. Chen vd. (2024) trafik akış matrisi, GCN ve dikkat mekanizmalarını içeren bir trafik tahmin modeli geliştirmiştir. J. Zhang vd. (2018) gelecekteki kentsel trafik akışlarını tahmin etmek için mekansal-zamansal derin rezidüel ağ (ST-ResNet) önererek, şehirdeki herhangi iki bölge arasındaki yakın ve uzak mekansal bağımlılıkları öğrenmiştir. R. He vd. (2024) yol ve bölge seviyelerinde trafik akışını tahmin etmek için 3D CNN kullanarak mekansal-zamansal 3D çok ölçekli genişletilmiş yoğun ağ (ST-3DMDDN) geliştirmiştir. Model, erken füzyon mekanizması ile önem örnekleme, mekansal korelasyonları yakalamak için çok ölçekli genişletilmiş evrişim ve özellik çıkarımı için yoğun bağlı bir ağ kullanır. Heidari & Iosifidis (2021) iskelete dayalı insan hareketi tanıma için mekansal-zamansal iki doğrusal ağ (ST-BLN) geliştirmiştir. Mekansal dikkat mekanizması GCN katmanlarında kullanılarak insan hareketleri tanınmıştır. Heidari & Iosifidis (2021) ayrıca, GCN-LSTM modelini kullanarak, mega


kentlerde iki haftalık kısa dönem güç yük tahmini doğruluğunu artırmak için mekansal otokorelasyon istatistiklerini birleştirmiştir. Ayrık dalgacık dönüşümünü kullanarak 81 trafo merkezinden 42 ay boyunca 1 saat aralıklarla toplanan zaman serilerini alt sinyallere ayırarak tahmin etmiştir.

Bu yöntem, özellikle mekansal otokorelasyonun önemli olduğu senaryolarda üstün tahmin doğruluğu göstermiş, destek vektör makineleri, LSTM, GCN-LSTM, GCN-GRU, düzlemsel akış tabanlı VAE ve federasyon ortalaması (Federated Averaging, FedAVG) yöntemlerinden daha iyi performans sergilemiştir. Eskandari vd. (2021) güç yük tahmininde mekansal-zamansal bağımlılıkları simüle etmek için GCN-LSTM ve GCN-GRU modellerini CNN ve RNN kombinasyonu olarak keşfetmiştir. N. Kim vd. (2022) kısa dönem yük tahmini için zamansal ve boyutsal ilişkileri yakalamak amacıyla etiketleme ve gömme prosedürlerini içeren bir model geliştirmiştir.

2. YAPILAN ÇALIŞMALAR

2.1. Yöntem Özeti

Bu çalışma, risk bilgili mekansal-zamansal inşaat ilerleme tahmin modellerinin yapılandırılması, değerlendirilmesi ve seçiminin iyileştirilmesine odaklanmıştır. Araştırma hem mekansal hem de zamansal dinamikleri kapsayan bir mekansal-zamansal modelleme çerçevesi tasarlamıştır. Bu araştırmanın birincil amacı, görev ve zaman bağımlılıklarını dikkate alan daha güvenilir bir inşaat ilerleme tahmin modeli geliştirmektir. Bu hedefe ulaşmak, bu bağımlılıklardan kaynaklanan değişken veri kalitesi sorunlarına dayanabilen modellerin geliştirilmesine bağlıdır. Bu nedenle, burada tespit edilen araştırma boşluğu çok yönlüdür; yalnızca gelişmiş mekansal-zamansal modellere olan ihtiyacı değil, aynı zamanda sağlam değerlendirme metrikleri oluşturma gerekliliğini de içermektedir. Bu metrikler, inşaat yönetimi uygulamalarına tamamen entegre edilebilecek daha güvenilir tahmin modellerinin geliştirilmesini kolaylaştıracak ve bu alanın kritik bir ihtiyacını karşılayacaktır. Bu nedenle geliştirilen modellerin yalnızca tahmin edici değil, aynı zamanda bu veri kalitesi sorunlarına karşı dayanıklı olması gerekmektedir. Bunun için, yalnızca doğru değil, aynı zamanda temsili, sağlam ve risk bilgili olan ML modellerinin geliştirilmesini sağlamak amacıyla çeşitli değerlendirme kriterlerini içeren kapsamlı bir çerçeve geliştirilerek daha güvenilir olması sağlanmış olacaktır. Araştırmanın yöntemi Şekil 8'de özetlenmiştir.



Şekil 8. Araştırmada takip edilen araştırma yöntemi akış diyagramı.

Bu araştırma mekansal-zamansal modellerin ayrıntılı bir şekilde araştırılmasını ve doğrulanmasını sağlamak için birbirini sistematik olarak tamamlayan Şekil 8’de gösterildiği gibi altı ayrı aşamada ilerlemektedir:

- Aşama 1: Mekansal-zamansal Modeller için Girdi Verileri: Sonraki ML modellerinin geliştirilmesi ve doğrulanması için çok önemli olan bu ilk aşama, verilerin toplanması ve hazırlanmasına odaklanmaktadır. Veriler, dört farklı mega inşaat projesinden elde edilen 170'ten fazla haftalık inşaat dokümanı ve iki milyondan fazla veri setinden derlenmiştir. Bu projelerin büyük ölçekli, karmaşık ve önemli toplumsal ve ekonomik etkilere sahip olmaları, genellikle inşaat ilerlemesini tutarlı sürdürme zorlukları yaşamalarına neden olmuştur. CPI ve SPI'nın doğru bir şekilde tahmin edilmesi, inşaat planlarındaki tutarsızlıkları ve sapmaları belirleyerek proje yönetiminin ve sonuçlarının iyileştirilmesine olanak tanır. Toplanan verilerin ML modellemesi için güvenilirliğini artırmak amacıyla veri seti titiz bir temizlik ve ön işleme aşamasından geçirilmiştir. Hazırlanan bu veri kümesi, 36 statik ve dinamik mekansal-zamansal modelin kapsamlı bir şekilde değerlendirilmesinin temelini oluşturmuştur.
- Aşama 2: Mekansal-zamansal Modellerin Girdi Ağlar: Bu aşamada, inşaat ilerleme performans ağları hem zaman hem de maliyet boyutlarında oluşturulmuştur. Faaliyet kayıtlarının paylaşılan WBS grubu ve teslimat haftasına dayalı olarak çift modlu kenar ağları oluşturulmuştur. Böylelikle, düğümlerde görev bilgilerini ve ilgili riskleri bütünleştiren, kenarlarda ise WBS bağlantı bilgilerini içeren kapsamlı ağların geliştirilmesi amaçlamaktadır.
- Aşama 3: Mekansal-Zamansal Modellerin Yapılandırılması: Yöntemin temel bileşeni, GCN, GAT ve geçitli mekanizmalar gibi mekansal modellerin, RNN, LSTM ve GRU gibi zamansal modellerle kombinasyonlarını içeren geniş bir yelpazede mekansal-zamansal ML modellerinin değerlendirilmesidir. Bu modeller, inşaat yönetimi literatüründe ilk kez mekansal ve zamansal derin öğrenme modellerinin inşaat ilerleme tahmini için kullanılmasını sağlamaktadır.

Yapı yönetimi literatüründe mekansal modellerle ilgili sınırlı araştırmalar bulunmaktadır. Bu çalışma, maliyet ve zaman ilerlemesini tahmin etmek amacıyla, statik olarak sınıflandırılan mekansal-zamansal modellerin potansiyelini araştırmıştır. GCN'ler, inşaat faaliyet düğümleri arasındaki mekansal bağımlılıkları tespit ederek, ilerleme kayıtlarındaki bilgileri toplar. Çok başlıklı GAT'ler, farklı dikkat mekanizmalarını kullanarak, aynı hafta içinde ve aynı WBS grubuna ait teslim edilen

inşaat faaliyet düğümlerini öğrenir. Bu yöntem, projenin ağlarındaki kritik düğümlere olan duyarlılığı artırır. Ayrıca, geçitli GNN modellerinde kullanılan mekanizmalar, zaman içerisinde ilgili bilgilerin korunmasını sağlar. ResGatedGNN modelleri ise, derin ağ yapılarında kaybolan gradyan sorununu önleyen Residual bağlantılarla donatılmıştır, bu da onları karmaşık inşaat projeleri için daha uygun hale getirir.

Tablo 2 bu tezde değerlendirilen mekansal-zamansal modelleri listelemektedir.

Tablo 2. Bu Araştırmada Geliştirilen Mekansal-Zamansal ML Modelleri.

Model	Açıklama	Kullanılan mekanizma					
		Evrim	Tekrarlayan	Dikkat	Geçitli	Yönlü	Çift yönlü
GCN	Komşu düğümlerden bilgi toplamak için graf üzerinde evrimsel işlemler uygular.	●				●	
Multi-head GAT	Birden fazla dikkat başlığı kullanarak düğüm ilişkilerinin farklı yönlerini yakalar.	●		●		●	
GatedGNN	Komşu düğümlerden gelen özelliklerin toplanmasını iyileştirmek için geçitli bir mekanizma ekler.	●			●	●	
ResGated GNN	Derin ağlarda öğrenmeyi geliştirmek için kalıntı bağlantılarını kullanır.	●			●	●	
RNN-GCN	GCN ile mekansal özellik toplamanın ardından zamansal işlem için RNN kullanır.	●	●			●	
GCN-RNN	İlk olarak mekansal özellik çıkarımı için GCN kullanır, ardından RNN ile zamansal bağımlılık öğrenir.	●	●			●	
Bi-RNN-GCN	Çift yönlü RNN'ler ile ileri ve geri zaman yönlerindeki bağımlılıkları yakalayarak GCN ile mekansal toplayıcıyı birleştirir.	●	●				●
GCN-Bi-RNN	GCN ile mekansal özellik çıkarımı yapar, ardından çift yönlü RNN ile zamansal bağımlılık öğrenir.	●	●				●
RNN-GAT	RNN ile mekansal özellik toplama için dikkat mekanizmalarını kullanır.	●	●	●		●	
GAT-RNN	İlk olarak mekansal özellik çıkarımı için GAT kullanır, ardından RNN ile zamansal işlem yapar.	●	●	●		●	
Bi-RNN-GAT	Çift yönlü RNN'ler ile GAT'ı entegre ederek zamansal ve mekansal bağımlılık öğrenimini iyileştirir.	●	●	●			●

Tablo 2'nin devamı

GAT-Bi-RNN	GAT ile mekansal özellik çıkarımı yapar, ardından çift yönlü RNN kullanır.						
LSTM-GCN	LSTM ile uzun vadeli zamansal bağımlılıkları ve mekansal özellikleri yakalar.						
GCN-LSTM	İlk olarak GCN ile mekansal özellik çıkarımı yapar, ardından LSTM ile uzun vadeli zamansal bağımlılık öğrenir.						
Bi-LSTM-GCN	Çift yönlü LSTM ile GCN'i birleştirerek zamansal ve mekansal öğrenimi iyileştirir.						
GCN-Bi-LSTM	GCN ile mekansal özellik çıkarımı yapar, ardından çift yönlü LSTM kullanır.						
LSTM-GAT	LSTM ile uzun vadeli zamansal ve mekansal bağımlılık öğrenimini birleştirir.						
GAT-LSTM	GAT ile mekansal özellik çıkarımı yapar, ardından LSTM ile işlem yapar.						
Bi-LSTM-GAT	Çift yönlü LSTM ile GAT'ı entegre ederek zamansal ve mekansal öğrenimi iyileştirir.						
GAT-Bi-LSTM	GAT ile mekansal özellik çıkarımı yapar, ardından çift yönlü LSTM kullanır.						
GRU-GCN	GRU ile zamansal ve mekansal bağımlılıkları yakalamak için GCN ile birleştirir.						
GCN-GRU	GCN ile mekansal özellik çıkarımı yapar, ardından GRU kullanır.						
Bi-GRU-GCN	Çift yönlü GRU ile GCN'i bütünleştirerek kapsamlı bağımlılık öğrenimi sağlar.						
GCN-Bi-GRU	GCN ile mekansal özellik çıkarımı yapar, ardından çift yönlü GRU kullanır.						
GRU-GAT	GRU ile mekansal ve zamansal bağımlılık öğrenimi için GAT ile birleştirir.						
GAT-GRU	GAT ile mekansal özellik çıkarımı yapar, ardından GRU kullanır.						
Bi-GRU-GAT	Çift yönlü GRU ile GAT'ı entegre ederek kapsamlı bağımlılık öğrenimini geliştirir.						
GAT-Bi-GRU	GAT ile mekansal özellik çıkarımı yapar, ardından çift yönlü GRU kullanır.						
RNN-GatedGNN	RNN ile Geçitli GNN'i birleştirerek zamansal ve mekansal özellik öğrenimini geliştirir.						
GatedGNN-RNN	Geçitli GNN ile mekansal özellik çıkarımı yapar, ardından RNN kullanır.						
RNN-GatedGAT	RNN ile Geçitli GAT'i birleştirerek zamansal ve mekansal bağımlılık öğrenimi sağlar.						
GatedGAT-RNN	Geçitli GAT ile mekansal özellik çıkarımı yapar, ardından RNN kullanır.						
LSTM-GatedGNN	LSTM ile Geçitli GNN'i birleştirerek uzun vadeli zamansal ve mekansal bağımlılık öğrenimi sağlar.						

Tablo 2'nin devamı

GatedGNN-LSTM	Geçitli GNN ile mekansal özellik çıkarımı yapar, ardından LSTM kullanır.	●	●		●	●	
LSTM-GatedGAT	LSTM ile Geçitli GAT'i birleştirerek uzun vadeli bağımlılık öğrenimi sağlar.	●	●	●	●	●	
GatedGAT-LSTM	Geçitli GAT ile mekansal özellik çıkarımı yapar, ardından LSTM kullanır.	●	●	●	●	●	
GRU-GatedGNN	GRU ile Geçitli GNN'i birleştirerek zamansal ve mekansal bağımlılık öğrenimi sağlar.	●	●		●	●	
GatedGNN-GRU	Geçitli GNN ile mekansal özellik çıkarımı yapar, ardından GRU kullanır.	●	●		●	●	
GRU-GatedGAT	GRU ile Geçitli GAT'i birleştirerek zamansal ve mekansal bağımlılık öğrenimi sağlar.	●	●	●	●	●	
GatedGAT-GRU	Geçitli GAT ile mekansal özellik çıkarımı yapar, ardından GRU kullanır.	●	●	●	●	●	
● Evrişim, yönlü ● Tekrarlayan, ● Dikkat, ● Geçitli, ● Yönlü, ● Çift							

Statik mekansal-zamansal modellerin yanı sıra, dinamik mekansal-zamansal modeller de değerlendirilmiş ve RNN gibi ilgili mekanizmalar entegre edilmiştir. RNN-GCN modelleri, RNN'in zamansal işleme yetenekleriyle GCN'in mekansal toplama becerilerini birleştirerek, inşaat aşamalarının zaman serisi gibi ardışık veriler için uygun olduğu belirlenmiştir. Bu araştırma ayrıca, zamansal ve mekansal yöntemlerin önceliklen dirilmesini incelemiş, GCN-RNN ve RNN-GCN gibi modelleri değerlendirmiş ve bu modellerin çift yönlü versiyonları olan Bi-RNN-GCN ve GCN-Bi-RNN'yi ele almıştır. Bu çift yönlü modeller hem geçmiş hem de gelecek bağlamını yakalayarak proje zaman çizelgelerine kapsamlı bir bakış sunmuştur.

Ayrıca, GCN ile GAT'den elde edilen ilk sonuçlar, dikkat mekanizmalarının, komşuluk içindeki inşaat aktivite düğümlerinin anlamını ve önemini anlama ve öğrenme potansiyelini artırdığını göstermiştir. Bu durum hem dikkat hem de dinamik yetenekleri entegre eden modellerin araştırılmasına yol açmıştır. Bu modeller, zamansal dinamikler ve dikkat tabanlı mekansal içgörülerden faydalananarak, çeşitli proje aşamaları için tahminleri optimize etmektedir. Literatürde, uzun menzilli bağımlılıkları daha iyi yöneten ve RNN'lere göre ilerleme sağlayan zamansal modeller olarak LSTM ve GRU geliştirilmiştir. Bu nedenle, tezde dikkat mekanizmalarına sahip veya sahip olmayan sekiz LSTM tabanlı modelin (LSTM-GCN, GCN-LSTM, Bi-LSTM-GCN, GCN-Bi-LSTM, LSTM-GAT, GAT-LSTM, Bi-LSTM-GAT ve GAT-Bi-LSTM) tahmin

potansiyeli de incelenmiştir. Benzer şekilde, sekiz GRU tabanlı model de değerlendirilmiştir (GRU-GCN, GCN-GRU, Bi-GRU-GCN, GCN-Bi-GRU, GRU-GAT, GAT-GRU, Bi-GRU-GAT ve GAT-Bi-GRU). Ayrıca, geçitli mekanizmalar ile dikkat ve dinamik özellikleri birleştiren modeller de araştırılmıştır. Bu modeller arasında RNN-GatedGNN, GatedGNN-RNN, RNN-GatedGAT, GatedGAT-RNN, LSTM-GatedGNN, GatedGNN-LSTM, LSTM-GatedGAT, GatedGAT-LSTM, GRU-GatedGNN, GatedGNN-GRU, GRU-GatedGAT ve GatedGAT-GRU yer almaktadır.

- **Aşama 4: Performans Metriklerinin Entegrasyonu ve Değerlendirilmesi:** Bu tezde takip edilen metodolojinin diğer bir bileşeni doğruluk ve sağlamlık gibi performans metriklerinin incelenmesini içermektedir. Bu tezde, geleneksel doğruluk metriklerinin yanı sıra siber saldırılara karşı sağlamlık kriterlerini de içeren ML modellerinin değerlendirilmesi de yapılmıştır. Bu kapsamlı performans metrikleri seti, inşaat mühendisliği ve inşaat yönetimi araştırmalarında önemli bir ilerleme sağlayarak, sektör uzmanları için daha güvenilir bir model oluşturmayı amaçlamaktadır.
- **Aşama 5: Mekansal-Zamansal Modellerin Eğitimi, Değerlendirilmesi ve Seçimi:** Bu bölüm, çeşitli mekansal-zamansal modellerin sağlamlık, doğruluk ve güvenilirlik açısından sistematik olarak değerlendirilmesi için kullanılan yaklaşımı ayrıntılı olarak açıklamakta ve inşaat yönetimi uygulamaları için en iyi performans gösteren modellerin seçimini kolaylaştırmaktadır. Model başlatma ve yapılandırma, farklı mimarileri birleştiren bir dizi mekansal-zamansal ML modelinin başlatılmasını ve çeşitli hiperparametrelerle yeniden başlatılmasını içerir. Modeller, geçmiş projelerden haftalık CPI ve SPI kayıtlarını içeren toplanmış ve işlenmiş inşaat ilerleme verileri kullanılarak eğitilmiştir. Her modelin değerlendirilmesi, çoklu performans metrikleri üzerinden gerçekleştirilmiştir. Eğitilmiş modellerin performansı, Adana, Bursa, Elazığ ve Yozgat gibi farklı inşaat projelerinde sistematik olarak karşılaştırılmıştır. Modellerin gelecekteki CPI ve SPI değerlerini doğru bir şekilde tahmin etme yeteneği, çeşitli proje aşamalarında test edilmiştir. Bu aşama, modellerin farklı zaman dilimlerinde ve proje ölçeklerinde detaylı performans değerlendirmelerini içermekte ve her bir modelin güçlü ve zayıf yönlerinin kapsamlı bir şekilde anlaşılmasını sağlamaktadır.
- **Aşama 6: Üretici Modeller Aracılığıyla Hibrit Veri Setlerinin Oluşturulması:** Bu aşamada, GAN'lar ve VAE'ler gibi üretici modellerin kullanılmasıyla sentetik verilerin oluşturulmuştur. Bunun nedeni, mekansal-zamansal tahmin modellerinde oluşabilecek sınıf dengesizliği sorununu ele almak ve modellerin çeşitli veri zehirlenmesi ve düşman


saldırılarına karşı sağlamlığını artırmaktadır. Sentetik verilerin üretilmesi, bu aşamada hibrit mekansal-zamansal inşaat ilerleme performansı tahmin modellerinin geliştirilmesine olanak tanımakta ve veri çeşitliliğini artırarak model güvenilirliğini iyileştirmede yeni bir yol sunmaktadır.

2.2. Mekansal-Zamansal Modeller İçin Girdi Verileri

2.2.1. Veri Toplama ve Hazırlık

Türkiye'deki dört farklı projeden (Bursa, Yozgat, Elazığ ve Adana) 2015 ile 2019 yılları arasında farklı dönemlere ait haftalık inşaat ilerleme raporları elde edilmiştir. Toplamda 175 haftalık ilerleme raporu bulunmaktadır. Bursa'dan alınan ilerleme raporları 18 aylık bir inşaat dönemiyle ilişkili 77 haftalık rapordan oluşurken, Yozgat'tan sadece 19 aylık bir süreçte 22 haftalık ilerleme raporu elde edilebilinmiştir. Bu inşaat raporları, PDF ve Microsoft Excel formatlarında olup bu şehirlerde yürütülen birçok bina inşaatını içeren verilerden oluşmaktadır. Elde edilen raporlar, yapılandırılmamış, yarı yapılandırılmış ve yapılandırılmış formlarda ilerleme kayıtlarını içermektedir. Bu çalışmanın başlangıcında, farklı projelerden elde edilen inşaat ilerleme kayıtlarının yapılandırılmış bir yaklaşımla derlenmesi amaçlanmıştır. Ancak, verilerin çeşitliliği, eksik veya tutarsız kayıtlar gibi sorunlar nedeniyle yapılandırılmış bir yaklaşımı takip etmek zorlaşmıştır. Farklı projelerden çıkarılan inşaat ilerleme verilerinin kalitesini ve tutarlılığını sağlamak amacıyla, bu tez boyunca veri toplama ve hazırlık süreci, Şekil 9'da gösterildiği gibi, birçok aşamada tekrarlanmıştır. Bu yinelemeli yaklaşım, projeler arasında tutarsız bir şekilde toplanan ve aynı kalitede olmayan verilerin değişkenliği ve farklı dağılımlarından dolayı gerekli olmuştur. Projenin doğası veya veri toplama dönemi ne olursa olsun her veri seti için bu adımlara tekrar tekrar dönülmesi temel verilerin sağlam olmasını sağlayarak kötü kalitedeki verilerin (“garbage in, garbage out” senaryoları) riskini en aza indirmiştir.

Şekil 9, haftalık inşaat raporlarının elde edilmesinden başlayarak, veri düzenleme, temizleme, hazırlama, dönüştürme ve kalite kontrol aşamalarını içeren kapsamlı bir iş akışını özetlemektedir.



Şekil 9. Farklı veri hazırlama aşamalarında tekrarlanan adım detayları.

Bu süreç, her veri setinin kendine özgü özelliklerinin uygun şekilde yönetilmesini sağlamak amacıyla veri doğrulama, profil oluşturma, yapılandırma ve görselleştirme gibi adımları içermektedir. Örneğin, veri temizleme adımları dilbilgisi hatalarının düzeltilmesini, veri tiplerinin dönüştürülmesini ve tarih-zaman formatlarının standartlaştırılmasını içermektedir. Ayrıca, farklı Excel dosyalarındaki kayıtların birleştirilmesi ve farklı sayfalardaki sütunların hizalanması, veri bütünlüğünü ve alaka düzeyini korumak için dikkatli bir şekilde ele alınmış adımlardır. Verinin yüksek ayrıntı seviyesi, özellikle kısa ömürlü inşaat aktivitelerinin olduğu durumlarda, bu adımların tekrar tekrar uygulanmasını gerektirmiştir. Bu da mekansal-zamansal modellere girdi olacak verilerin yüksek kalite ve güvenilirlikte olmasını sağlamıştır.

1. Raporların Yapılandırılması: Adana, Bursa, Elazığ ve Yozgat'ta gerçekleştirilen yapım projelerine ait inşaat aktivitelerine ilişkin ilerleme raporları gözden geçirilerek tipik bir yapı oluşturulmuştur. Farklı haftalarda Excel'e işlenen her bir rapor, Özet, Verimlilik ve İlerleme, Gantt Şeması gibi birden fazla sayfa içermektedir. Veriler, çeşitli projelerden gelen Gantt Şemaları, Verimlilik ve Özet sayfalarına odaklanılarak yapılandırılmıştır. Veriler daha sonra birleştirilmiş ve doğruluk ile tutarlılığı sağlamak amacıyla temizlenmiştir. Raporların Özet Sayfası, Şekil 10'da gösterildiği gibi, genellikle 16'sı kategorik, 2'si sayısal olmak üzere toplam 22 özellik sütunu içermektedir.

[illegible]

Şekil 10. Haftalık ilerleme raporlarındaki Özet sayfasının ekran görüntüsü.

Her Özet sayfası yaklaşık 10000 kayıttan oluşmakta olup, her bir inşaat aktivitesinin miktarını, önemini, ağırlığını ve başlangıç-bitiş tarihlerini ayrıntılı bir şekilde sunmaktadır. Ayrıca, ana iş paketleri için haftalık ortalama CPI ve SPI metriklerini, inşaat projesi hakkında bilgileri, başlangıç ve planlanan bitiş tarihlerini, toplam alanı, yüklenici firmayı ve proje adını içermektedir. Farklı inşaat aktiviteleri için planlanan ve gerçekleşen kişi-saatler ile ilerleme durumunu da içeren Özet sayfası, her aktivitenin önemini ve ağırlığını belirtmektedir. Verimlilik ve İlerleme Sayfası (bkz. Şekil 11) ise yaklaşık 40000 kayıt içermekte olup, her hafta her projedeki farklı verimlilik ve ilerleme metriklerine işaret eden yaklaşık 40 sütun içermektedir. Örneğin, planlanan, gerçekleşen ve kazanılan toplam ve birim kişi-saatlerini, ana yüklenici hakkında bilgileri, her aktivitenin kalan haftalarını ve planlanan ile gerçekleşen ilerleme yüzdelerini içermektedir.

#### ##### PROJESİ														
HAFTALIK ŞANTİYE İLERLEME VE VERİMLİLİK DEĞERLENDİRME TABLOSU														
Bölge Kodu	İnşaat Tipi	Birim	Abrık (%)	Metraj	İlerleme	TOPLAM Ad-Sa	Planlanan Toplam Ad-Sa	Kazanılan Toplam Ad-Sa	Gerçekleşen Toplam Ad-Sa	İlerleme Yüzdesi (%)	Planlanan Yüzde	SPI	İleri / Geri	Planlanan ÜNİT
TOPLAM			100.00%			13,843,991.23	1,992,197.62	1,691,397.65	1,344,753.44	12.22%	14.39%	0.8	Geride	1.3
Toprak İşleri ve Peyzaj 3.33%														
01010110	Kazi İşleri	m³	0.77%	2,127,749.16	1,770,009.03	106,387.46	88,757.90	88,500.45	66,152.12	83.19%	83.43%	1.0	Geride	1.3
01010130	Zemin Tesviyesi	m³	0.04%	114,000.00	77,999.77	5,700.00	4,800.00	3,899.99	7,999.23	68.42%	84.21%	0.8	Geride	0.5
01010210	Dolgu İşleri	m³	0.42%	1,159,282.80	177,101.29	57,964.14	13,593.47	8,855.06	6,241.14	15.28%	23.45%	0.7	Geride	1.4
01010310	Temel Altı Drenaj Hattı	mt	0.08%	1,741.00	441.57	10,446.00	3,362.53	2,649.40	43.45	25.36%	32.19%	0.8	Geride	61.0
01010320	Yağmur suyu	mt	0.23%	5,300.00		31,800.00						-	Başlamadı	6.00
01010330	Kanalizasyon	mt	0.15%	3,400.00		20,400.00						-	Başlamadı	6.00
01010360	İçme Suyu	mt	0.05%	1,350.00		6,750.00						-	Başlamadı	5.00
01020110	Temel Pili Dolgu	m³	0.00%	402.00	280.88	40.20	40.20	28.09	966.38	69.87%	100.00%	0.7	Geride	0.10
01020120	Temel Dolgu-Çakıl	m³	0.03%	44,000.00	8,536.00	4,400.00	4,400.00	853.60	2,624.88	19.40%	100.00%	0.2	Geride	0.31
01020320	Toprakarme Duvar	m³	0.57%	14,075.00	2,111.25	78,820.00	17,734.49	11,823.00	1,395.00	15.00%	22.50%	0.7	Geride	5.60
07010110	Kırmataş	m³	0.02%	11,800.00		2,360.00						-	Başlamadı	0.20
07010120	Plentmik	t	0.01%	20,748.00		1,778.40						-	Başlamadı	0.09
07020320	Sis Havuzu E/M	m³	0.01%	400.00		800.00						-	Başlamadı	2.00
07020430	Çevre Duvarı/İstinat Duvarları	Mt	0.17%	4,750.00		23,750.00						-	Başlamadı	5.00
07020430	Diğer Peyzaj İşleri	Set	0.01%	1.00		1,600.00						-	Başlamadı	1600.00
12020410	Yol Çiğirleri		0.00%	1.00		300.00						-	Başlamadı	300.00
12020620	Trafik İşaretlemleri		0.00%	1.00		500.00						-	Başlamadı	500.00
Yalıtım İşleri 0.94%														
01040210	Grobeton	m³	0.04%	106,500.00	71,950.95	6,070.50	4,153.50	4,101.20	3,763.83	67.56%	68.42%	1.0	Geride	0.06
01040230	Membran Su Yalıtımı	m²	0.10%	114,150.00	77,119.72	13,569.15	9,243.55	9,128.35	4,050.18	67.27%	68.12%	1.0	Geride	0.12
01040240	Keçe	m²	0.01%	114,150.00	77,117.64	1,141.40	781.00	771.15	2,308.85	67.56%	68.42%	1.0	Geride	0.01
01040260	Koruma Betonu	m³	0.03%	106,500.00	71,950.94	4,260.00	2,914.74	2,878.04	5,076.41	67.56%	68.42%	1.0	Geride	0.04
01040310	Astar	m³	0.01%	45,900.00	31,530.22	917.96	633.17	630.64	1,413.17	68.70%	68.98%	1.0	Geride	0.02
01040320	Membran Su Yalıtımı	m²	0.08%	45,900.00	30,820.36	11,474.95	7,750.22	7,705.06	3,541.49	67.15%	67.54%	1.0	Geride	0.25
01040330	XPS	m³	0.08%	45,900.00	31,687.40	11,475.03	7,969.18	7,921.85	2,067.25	69.04%	69.49%	1.0	Geride	0.25
01040340	Koruma Levhası	m²	0.01%	40,792.54	27,972.35	2,059.67	1,407.09	1,398.65	927.66	68.57%	68.99%	1.0	Geride	0.05
04010140	XPS-Çatı/Teras	m³	0.07%	101,275.00		10,127.50						-	Başlamadı	0.10
04010155	Çatı Eğim Betonu	m³	0.07%	101,275.00		10,127.50						-	Başlamadı	0.10
04010156	Çatı Koruma Betonu	m³	0.05%	34,084.15		6,816.83						-	Başlamadı	0.20
04010160	Su Yalıtımı	m³	0.09%	101,275.00		12,153.00						-	Başlamadı	1.12
06010120	Duvar Ses Yalıtımı	m³	0.01%	1,020.00		1,020.00						-	Başlamadı	1.00
06010130	Bitümlü Membran	m³	0.00%	830.00		166.00						-	Başlamadı	0.20
06010131	Sıvı Yalıtım-Duvar	m³	0.01%	7,900.00		1,896.00						-	Başlamadı	0.24
06020135	Döşeme Ses Yalıtımı	m³	0.00%	250.00		250.00						-	Başlamadı	1.00
06020140	Bitümlü Membran	m³	0.04%	30,258.87		6,051.77						-	Başlamadı	0.20
SUMMARY GRAFİK İlerleme ve Verimlilik Breakdown Actual Quantity Actual Ad-Sa Grafik Alttık GANTT CHART PRIMAVERA +														

Şekil 11. Haftalık ilerleme raporlarındaki Verimlilik ve İlerleme sayfasının ekran görüntüsü.

Verimlilik ve İlerleme sayfasında yer alan önemli bir bileşen olan SPI sınıfı veya haftalık SPI sütunlarında depolanan program bilgisi, bu sütunlar geride, normal, ileride, başlamadı ve tamamlandı gibi açıklayıcı kategorilere ayrılmıştır. Benzer şekilde, her aktivitenin verimliliği CPI sütunlarında ; haftalık CPI sütununda CPI'nin sayısal değeri raporlanırken, CPI sınıf sütununda ise performans verimli, verimsiz veya başlamadı şeklinde kategorize edilerek raporlanmıştır. Verimlilik ve İlerleme Sayfası her iş paketinin ağırlığı, planlanan, gerçekleşen ve kazanılan birimler gibi ayrıntılı bilgilerin yanı sıra kişi-saat verilerini de içermekte olup, işgücü tahsisi ve verimlilik hakkında içgörüler sunmaktadır.

Gantt Şeması sayfası, Şekil 12'de gösterildiği gibi, inşaat projelerinin zaman çizelgeleri ve kilometre taşlarını ayrıntılı bir şekilde sunan birkaç sütundan oluşmaktadır.

B	C	D	E	F	H	I	J	L	M
Grup-1	Grup-2	Grup-3	Grup-4	Grup-5	Activity ID	Activity Name	Resource ID	Budgeted Units	Resource Type
						Resource Type: Labor		15712062.3	
								15712062.3	
						WBS: ADN160916-B03.4 Yapım İşleri / Construction Works		13727331.9	
						WBS: ADN160916-B03.4.0 Mobilizasyon Ve Saha Hazırlık / Mobilization & Site Pre		15000	
						WBS: ADN160916-B03.4.0.1 Mobilizasyon Saha Hazırlık İşleri / Mobilization Site Pr		5000	
GENEL	Contingen	Mobilizasy	Contingency		ADN.GN.G.14.01	Mobilizasyon Saha Hazırlık İşleri / Mobilization A99999999		5000	Labor
						WBS: ADN160916-B03.4.0.2 Mobilizasyon Altyapı İşleri / Mobilization		5000	
GENEL	Contingen	Mobilizasy	Contingency		ADN.GN.G.13.01	Mobilizasyon Altyapı İşleri / Mobilization Infra A99999999		5000	Labor
						WBS: ADN160916-B03.4.0.3 Mobilizasyon Yapıları / Mobilization Sup		5000	
GENEL	Contingen	Mobilizasy	Contingency		ADN.GN.G.15.01	Mobilizasyon Yapıları / Mobilization Superstr A99999999		5000	Labor
						WBS: ADN160916-B03.4.1 Ana Hastane İnşaat İşleri / Main Hospital C		10133586.84	
						WBS: ADN160916-B03.4.1.01 Kazı ve Dolgu İşleri / Ground Works - S		126692.8024	
						WBS: ADN160916-B03.4.1.01.1 Zemin İşleri / Ground		89470.59258	
						WBS: ADN160916-B03.4.1.01.1.1 ZEMİN KAZI İŞLERİ / GROUND PRO		72820.81158	
ANA HAST	Toprak	İşç	Kazı	Toprak İşleri	ADN.MH.ZM.1.1.01	Makinalı Kazı / Excavation With Machinery	A01010110	68570.81158	Labor
ANA HAST	Toprak	İşç	Zemin tes	Toprak İşleri	ADN.MH.ZM.1.1.02	Zemin Tesviyesi / Grading	A01010130	4250	Labor
						WBS: ADN160916-B03.4.1.01.1.2 ZEMİN DOLGU İŞLERİ / GROUND C		6649.781	
ANA HAST	Toprak	İşç	Dolgu İşleri	Toprak İşleri	ADN.MH.ZM.1.2.01	Toprak Dolgu Yapılması / Earth Backfilling	A01010210	6649.781	Labor
						WBS: ADN160916-B03.4.1.01.1.3 YERALTI SANAT YAPILARI / UNDER		10000	
ANA HAST	Toprak	İşç	Yeraltı Su	Altyapı İşleri	ADN.MH.ZM.1.3.01	Yeraltı Suyu Drenaj İşleri / Underground Water	A01010310	10000	Labor
						WBS: ADN160916-B03.4.1.01.2 İstinad Duvarları / Retaining Walls		3317.54	
ANA HAST	Toprak	İşç	Fore Kazık	İksa İşleri	ADN.MH.RW.2.1.01	İksa İşleri	A01020110	1900.62	Labor
ANA HAST	Toprak	İşç	Baslık Kırıs	İksa İşleri	ADN.MH.RW.2.1.01	İksa İşleri	A01020140	467.92	Labor
ANA HAST	Toprak	İşç	Ankraj Sıst	İksa İşleri	ADN.MH.RW.2.1.01	İksa İşleri	A01020160	949	Labor
						WBS: ADN160916-B03.4.1.01.4 Zemin İyileştirme Ve Temel İzolasyon		33904.66982	
						WBS: ADN160916-B03.4.1.01.4.1 TEMEL İZOLASYONLARI / FOUNDA		19502.29907	
ANA HAST	Yalıtım	İşç	İzolasyon	İzolasyon	ADN.MH.RW.3.1.01	Temel İzolasyonları / Foundation Insulations	A01040210	5020.9647	Labor
ANA HAST	Yalıtım	İşç	Membran	İzolasyon	ADN.MH.RW.3.1.01	Temel İzolasyonları / Foundation Insulations	A01040230	9978.817626	Labor
ANA HAST	Yalıtım	İşç	Kece	İzolasyon	ADN.MH.RW.3.1.01	Temel İzolasyonları / Foundation Insulations	A01040240	901.4767497	Labor
ANA HAST	Yalıtım	İşç	İzolasyon	İzolasyon	ADN.MH.RW.3.1.01	Temel İzolasyonları / Foundation Insulations	A01040260	3601.039993	Labor
						WBS: ADN160916-B03.4.1.01.4.2 BODRUM PERDE İZOLASYONLARI		14402.37075	
ANA HAST	Yalıtım	İşç	Zıft	İzolasyon	ADN.MH.RW.3.2.01	Bodrum Perde İzolasyonları / Basement Exter	A01040310	531.9153945	Labor
ANA HAST	Yalıtım	İşç	Membran	İzolasyon	ADN.MH.RW.3.2.01	Bodrum Perde İzolasyonları / Basement Exter	A01040320	5760.3172	Labor
ANA HAST	Yalıtım	İşç	Isı Yalıtımı	İzolasyon	ADN.MH.RW.3.2.01	Bodrum Perde İzolasyonları / Basement Exter	A01040330	6819.144038	Labor
ANA HAST	Yalıtım	İşç	Briket İzol	İzolasyon	ADN.MH.RW.3.2.01	Bodrum Perde İzolasyonları / Basement Exter	A01040340	1290.994121	Labor
						WBS: ADN160916-B03.4.1.02 Kaba Yapı İşleri / Structure Primary Ele		2612801.413	


Şekil 12. Haftalık ilerleme raporlarındaki Gantt şeması sayfasının ekran görüntüsü.

Gantt şeması sayfaları, genellikle diğer veri setleriyle ilişkili her bir aktiviteye ait farklı WBS seviyelerine odaklanmıştır. Ayrıca inşaat alanı, başlangıç ve bitiş tarihleri gibi projeye özgü bilgiler de içermektedir. Gantt Şeması sayfaları, inşaat aktivitelerine ilişkin çeşitli ayrıntı düzeylerini sağlayan verilere de yer vermektedir. Bu sayfalar, farklı projelerdeki aktivitelerin hiyerarşik yapısını detaylandırmakta olup, WBS grup 1, WBS grup 2, WBS grup 3 ve ana WBS gibi WBS seviyelerini içermektedir. Toplanan veri setlerinde WBS grup 1 genellikle her projedeki inşaat bölgesi veya belirli inşaat alanını tanımlamaktadır. Her bir projede birkaç bina yer aldığı için (genellikle 5 ila 7 bina), WBS grup 1 bu farklı inşaat bölgelerini ayırmaya yardımcı olmaktadır. WBS grup 2 ise elektrik, mekanik, peyzaj gibi ana iş paketlerini kategorize etmektedir. Gantt Şeması sayfalarında daha ayrıntılı WBS grup 4 ve 5 seviyeleri de yer almasına rağmen, bu seviyeler genellikle boş bırakılmış veya eksik kayıtlar içermektedir.

2. Sütun Başlıklarının Belirlenmesi ve Atanması: Her sütunun içeriği incelenmiş ve ilgili satır, kolon başlığı olarak belirlenerek tüm veri setleri boyunca başlık olarak atanmıştır. Bu adım, her kategoriye özgü verilerin doğru bir şekilde çıkarılmasına ve işlenmesine

yardımcı olmuştur. Sütun açıklamalarının birden fazla satıra yayıldığı durumlarda, bu satırlar tek bir kolon başlığı altında toplanmıştır. Bu konsolidasyon, netlik sağlamak ve sonraki veri analiz süreçlerini karmaşıklştırabilecek gereksiz tekrarları önlemek için kritik öneme sahiptir.

3. Düzenli İfadelerin Kullanımıyla Veri Çıkarma: Özellikle, Özet sayfaları birden fazla tablo içerdiğinden, başlıklardaki ve bu tabloların son satırındaki anahtar kelimeleri ayarlamak ve tanımlamak için düzenli ifadeler kullanılmıştır. Her haftaya ait farklı özet tabloları çıkarılmış ve karşılık gelen sütunlar altında hizalanarak birleştirilmiştir.
4. Sütun Adlarının Standartlaştırılması: Excel sayfalarında doğrudan eşleşen kategorilerdeki sütun adları tutarlılığı sağlamak için standartlaştırılmıştır. Farklı projeler arasında benzer fakat birebir aynı olmayan kategoriler için sütun adları karşılaştırmalı analizleri kolaylaştırmak amacıyla birleştirilmiştir. Bu durum, veri toplama ve projeler arası karşılaştırmaların sorunsuz bir şekilde yürütülebilmesini sağlamıştır.
5. Boş Alanların Budanması: Veri çıkarma adımından önce, içerik içermeyen tüm sütunlar ve satırlar elenmiştir. Bu adım, veri setinin boyutunu kontrol etmek ve veri işleme sırasında hesaplama verimliliğini artırmak için gerekli olmuştur. Bu işlem sonucunda, her proje için 40 ile 47 sütun arasında değişen bir veri seti oluşturulmuştur.
6. Haftalık Veri Setlerinin Birleştirilmesi: Benzer Excel sayfaları farklı haftalar boyunca birleştirilmiş ve her projeye ait her bir sayfa ile ilgili ayrı veri setleri oluşturulmuştur. Özellikle, her mega inşaat projesinin yapılandırılmış raporlarından Özet, Verimlilik ve İlerleme ile Gantt Şeması veri setleri filtrelenmiştir.
7. Büyük Veri Görselleştirme Panosuyla İlk Keşifsel Veri Analizi : Haftalık raporların birleştirilmesiyle oluşan büyük veri setlerini yönetmek ve görselleştirmek için bir büyük veri panosu kullanılmıştır. Bu pano, farklı veri setleri arasında benzer anlamlara sahip kategorik adlardaki tutarsızlıkların kontrol edilmesine olanak tanımış ve kolon adlarının tutarlılığı için standartlaştırılmasına yol açmıştır. Şekil 13 ilk keşifsel veri analizi (Exploratory Data Analysis, EDA) için kullanılan pano ortamının ekran görüntüsünü göstermektedir.




Şekil 13. Kullanılan büyük veri panosunun ekran görüntüsü.

Şekil 13'te gösterildiği gibi, Özet veri seti için tasarlanan pano 16'sı kategorik, 5'i sayısal ve 1'i metin olmak üzere toplamda 22 özellik sergilemektedir.

8. Tutarsızlıkların Yönetimi: Farklı projelerdeki kayıt tarzlarındaki değişkenlikler, tutarsız terimler, yazım hataları ve kategorilendirmeler bir dizi zorlukları da beraberinde getirmiştir. Çalışmada, başlangıçta farklı projeler arasında WBS gruplarının ana

kategorilerini standartlaştırarak model karşılaştırılabilirliği sağlanmıştır. Ancak, gerçek dünya uygulamaları bu kayıtların, öngörüsöl görevler ve gelecekteki proje hedeflerine göre ayarlanmasını gerektirmektedir. Örneğin, bazı projeler toprak işleri ve peyzaj görevlerini tek bir WBS kategorisi altında gruplarken, diğerleri zemin ve altyapı çalışmalarını birleştirmiştir. Ayrıca, CPI sütunlarındaki “verimli/verimsiz” gibi karışık kategoriler veya metin alanlarındaki yanlış girişler olan “False” gibi kayıtlar düzeltilmiştir. Benzer şekilde, SPI sütunlarındaki bazı kayıtlar “önde/geride” gibi karışık durumları içermekle birlikte bu kayıtlar dilbilgisi hatalarını da barındırıyordu. Bu nedenle, özellik sütunları tekrar tekrar değerlendirilerek bu tutarsızlıklar ve dilbilgisi hataları düzeltilmiştir.

9. Kayıtlardaki Hataları Tespit Etmek İçin İkincil EDA: Geniş kapsamlı kayıtların yönetimi ve düzeltilmesi özellikle inşaat aktivite sütunlarının ayrıntılı yapısı göz önüne alındığında önemli zorluklar yaratmaktadır. Verinin büyük hacmi ve kayıtların detaylı yapısı, veri kalitesi ve güvenilirliğini sağlamak için titiz bir dikkat gerektirmektedir. Bu sebeple, bu tezde en sık rastlanan kategorilerin belirlenmesi ve veri seti genelinde etiketlerin tutarlılığının gözlemlenmesi amacıyla ikincil bir EDA gerçekleştirildi. Bu süreç, farklı bina inşaatlarını kapsayan 1000'den fazla inşaat aktivitesini içeren kapsamlı kayıtların yönetimiyle ilgili zorluklar düşünüldüğünde, tezin en kritik aşamalarından biri olarak görülebilir. Veri çıkarma ve hazırlama prosedürleri boyunca her bir adımın doğruluğunu sağlamak ve proje yaşam döngüsü boyunca veri bütünlüğünü korumak için çok sayıda EDA iteratif olarak gerçekleştirildi. Buna rağmen, veri setinin geniş boyutu ve karmaşıklığı nedeniyle gözden kaçan hataların olma olasılıklarının varlığı kabul edilmelidir.
10. Veri Kalite Kontrolü ve Anomali Tespiti: Anomali tespiti, bir veri setinde beklenmeyen veya alışılmadık olayları veya kalıpları tanımlama sürecidir. Bu çalışma kapsamında, inşaat ilerleme veri setinde anormal kayıtları tespit etmek amacıyla istatistiksel ve ML yaklaşımları kullanıldı. Temizlenmiş veri setinde anormal kayıtları belirlemek için farklı anomali tespiti teknikleri uygulandı. Şekil 14 Adana ilinde gerçekleşen yapım projesine ait veriler üzerinde istatistiksel ve ML anomali tespiti yaklaşımları kullanılarak belirlenen anomalileri göstermektedir.



Şekil 14. (a) Z-skoru ve (b) İzolasyon Ormanı yaklaşımları kullanılarak tespit edilen anomalilerin sonuçları.


11. Başlangıç Veri Tabanı: Başlangıç veri tabanı Özet, Verimlilik, İlerleme ve Gantt şeması veri setlerinden toplanan verilerle ilgilidir.
12. Veri Birleştirme ve Toplama: Özet, Üretkenlik ve İlerleme tabloları önerilen mekansal-zamansal modellerin eğitimi için verilerin bütünleşik bir görünümünü sağlamak amacıyla birleştirilmiştir. Gantt Şemalarındaki veriler, detaylı zamanlama ve görev segmentasyonlarını içerecek şekilde birleştirilmiş olup, bu işlem veri setlerinin zamansal ve mekansal boyutlarla daha da geliştirilmesine yardımcı olmuştur.
13. Kodlama: Temizlenmiş veri setindeki kategorik sütunlar etiket kodlaması kullanılarak sayısal formatlara dönüştürülmüştür. Bu işlemde, “aktivite türü” ve “taşeron” gibi kategorik özellikler her kategori için benzersiz bir numara ile temsil edilmiştir.

2.2.2. Veri Tanımlaması

Her projedeki farklı bina inşaatlarına ait veriler ayrı olarak yönetilmiştir. Örneğin, Elazığ projesinden elde edilen FTR binası ve teknik bina inşaat verileri, her biri 221477 kayıttan oluşan 24 parça halinde saklanmıştır. Benzer şekilde, YGAP binası ve dış saha inşaat verileri de her biri 72197 kayıttan oluşmuştur. Elazığ'daki genel bina inşaatı verileri ise 11199 kayıttan oluşan 2 parça halinde depolanmıştır. Elazığ'daki farklı bina inşaatları için son veri seti 2248127 satır ve 34 sütundan oluşmuştur. Ancak raporlardaki mükerrer kayıtlar nedeniyle, bu sayı yinelemeleri azaltma işleminden sonra 420916 satıra düşmüştür. Elazığ'daki veri seti kaplama, elektrik ve mekanik işler gibi ana WBS grup 2 kategorilerine ayrılmıştır ve bu kategoriler altında çeşitli kayıtlar tutulmuştur. Örneğin, kaplama işleri

130000'den fazla aktiviteyi içerirken, toprak işleri ve peyzaj gibi daha küçük kategoriler 300'den az aktiviteyi temsil etmiştir. Veri setinde 200'den fazla benzersiz inşaat faaliyet grubu, WBS grup 3 altında sınıflandırılmış ve bu gruplar 600 bireysel inşaat aktivitesine bölünmüştür. Bu aktivite grupları, Elazığ projesinde görev alan 250'den fazla farklı taşeron firma tarafından gerçekleştirilmiş olup, bu durum projenin yönetimindeki karmaşıklığı ve çeşitliliği göstermektedir. Her inşaat aktivitesi gerekli iş gücü yatırımını yansıtan belirli bir iş saati ile ilişkilendirilmiştir. Elazığ veri seti 40 benzersiz tarihe ait kayıtlar içermekte olup bu tarihler inşaat aktivitelerinin belirli başlangıç ve bitiş tarihleriyle birlikte kaydedildiği dönemleri ayrıntılı olarak sunmaktadır. Ayrıca, proje kapsamında çeşitli katlar veya birimler olarak sınıflandırılan 90'dan fazla farklı inşaat bölgesi belirlenmiş olup bu durum mekansal detay seviyesini daha da artırmıştır. WBS grup 2 sütunu, inşaat ilerleme kayıtlarını haftalık teslimat programları aracılığıyla zamansal olarak entegre eden önemli bir bağlantı noktası olarak işlev görmüştür. Elazığ için nihai yapılandırılmış veri seti 34 sütundan oluşan 335826 kayıt içermektedir. Ancak WBS grup 5 gibi bazı sütunlar büyük ölçüde boş kalmış olup, yalnızca 2469 kayıt doldurulmuştur. Bunun yanı sıra, veri setinde yıllar arasında inşaat aktivitelerinin dağılımında önemli bir farklılık gözlenmiştir. En fazla aktivite 2018 yılında kaydedilmiş olup, bunu 2017 takip etmiştir ve 2016'dan çok az sayıda kayıt bulunmuştur. Elazığ'daki inşaat aktivitelerinin zamansal dağılımı özellikle 2018 yılında işlerin yoğunlaştığı kritik dönemleri ortaya koymuştur. Bu yıla ait, 212205 kaydın varlığı bu dönemde yoğun bir proje yürütümünün gerçekleştirildiğinin göstergesi olmuştur. Bu artış ağırlıklı olarak Mart, Nisan ve Mayıs aylarında yoğunlaşmış olup, bu aylarda sırasıyla 62520, 53377 ve 39532 aktivite kaydedilmiştir. Buna karşılık, yaz aylarında aktivitelerde bir düşüş gözlemlenmiş olup, Temmuz ve Ağustos aylarında belirgin şekilde daha düşük rakamlar kaydedilmiştir. Elazığ'daki inşaat aktivitelerinin yıllık ve aylık varyasyonu, kaynakların verimli şekilde tahsis edilmesi ve proje takvimlerine uyumun sağlanması için zamansal faktörlerin proje planlamasına dahil edilmesi gerekliliğini vurgulamaktadır. Haftalık bazda veri setinin daha ayrıntılı incelenmesi, belirli haftalarda inşaat aktivitelerinde dalgalanmalar olduğunu ortaya koymuştur. Örneğin, 7 Nisan 2018 ve 31 Mart 2018 tarihlerinde sırasıyla 5158 ve 3862 aktivite kaydedilmiş olup, bu tarihlerde proje kilometre taşlarında kritik atılımlar olduğunu göstermektedir. Ancak, 15 Temmuz 2018 ve 30 Ağustos 2018 tarihlerinde sadece 9 kayıtlı sınırlı olan önemli düşüşler de gözlenmiş olup bu durum muhtemelen proje döngüsündeki geçiş aşamalarını veya mobilizasyon aşamalarını işaret etmektedir.


Şekil 15'te projelerin zamansal yayılımını ve aktivite tamamlama yoğunluğunu görselleştirilmektedir. Böylelikle , projelerin nasıl bir ilerleme kaydettiği ayrıntılarıyla sunularak proje tamamlama tarihlerinin zamansal yayılımı ve yoğunluğu grafiksel olarak gösterilmiştir.



Şekil 15. Projelerdeki aktivitelerin tamamlanma tarihlerinin dağılımları.

Şekil 15'ten de görülebildiği üzere, projeler birkaç yıl boyunca farklı dönemlere yayılmıştır. Adana özellikle 2017'nin ikinci yarısında ve 2018 boyunca aynı anda tamamlanan birkaç projenin kümelenmiş bitiş tarihleri ile karakterize edilmiştir. Bu durum, projeleri tamamlamak için stratejik bir çaba olduğunu düşündürmektedir. Bursa 2017 ortasından 2019 sonuna kadar daha sürekli ve eşit bir tamamlama dağılımı sergilemiş olup, projelerin aşamalı olarak tamamlandığı görülmektedir. Elazığ'daki projelerin tamamlama tarihlerinin yoğunlaştığı dönem ise 2017 ortasından 2018 ortasına kadar olan süreçtir, bu da muhtemelen belirli son teslim tarihlerine veya finansman döngülerine bağlı olarak yüksek bir aktivite dönemini işaret etmektedir. Son olarak, Yozgat'ta projelerin çoğunun 2016'nın sonuna kadar tamamlanmış olması, inşaat aktivitelerinin daha kısa bir zaman diliminde hızlı


bir şekilde tamamlandığını göstermektedir. Her veri setinde gözlemlenen bu zamansal varyasyon, mekansal-zamansal modellerin eğitilmesinde kritik bir unsur olup model performansının farklı veri setlerinde kapsamlı bir şekilde değerlendirilmesine olanak sağlayacağı düşünülmektedir. Faaliyet kayıtlarının haftalık dağılımını daha iyi anlamak için, farklı projelerdeki ilerleme kayıtlarının haftalara göre sıklığı Şekil 16'da gösterilmektedir.




Şekil 16. Projelerin haftalar boyunca inşaat ilerleme kayıtlarının sıklığı.

Şekil 16'da gösterildiği gibi, Adana, Bursa, Elazığ ve Yozgat'tan toplanan veri setleri zaman içinde inşaat aktivitelerinin dağılımında her biri kendine özgü farklılıklar sergilemiştir. Örneğin, Adana'nın kayıtları 1. haftadan 52. haftaya kadar uzanmakta olup 44 haftada önemli bir zirve ile istikrarlı bir aktivite seviyesi göstermiştir. Bu durum, yoğun inşaat çabalarının bulunduğu bir proje aşamasını işaret etmektedir. Bununla birlikte, 26. haftadan sonra kayıtlarda boşluklar olması, potansiyel olarak veri toplama sürecinde karşılaşılan başlangıç zorluklarına işaret edebilir. Bursa'nın verileri ise 1. haftadan 52. haftaya kadar uzanmakta olup, 1. haftada güçlü bir başlangıç ve ardından aktivitelerin kademeli olarak azalması, projenin başlangıçta hız kazandığını ve ardından bir denge aşamasına girdiğini göstermektedir. Buna karşılık, Elazığ'da birden fazla aktivite zirvesi görülmekte olup, bu durum, birden fazla proje teslimatı veya kilometre taşına bağlı olarak artan çalışma aşamalarını işaret etmektedir. Yozgat'ın verileri ise daha az haftada yoğunlaşmış aktiviteler göstererek, eksik başlangıç raporlarıyla birlikte daha yoğun bir proje zaman çizelgesi sunmaktadır.

Veri seçme süreci EDA ile yönlendirilmiş olup beklenen tahmin çıktısı ile ilgili olmayan veya yinelenen içeriğe sahip sütunlar kaldırılmıştır. Bu sayede yalnızca anlamlı özellikler korunmuştur. Örneğin, kişi saatleri ve kazanılan değer, çeşitli inşaat aktivitelerine doğrudan emek girdisini yansıttığı için kritik olarak değerlendirilmiştir. Literatürde de desteklendiği gibi inşaat zaman ve maliyet tahminlerinin büyük ölçüde kişi saatleri gibi verimlilik faktörleri tarafından yönlendirildiği gerçeğiyle uyumludur (Hwang & Liu, 2010). Bu odaklanma, kaynak kullanımının ve verimliliğin ayrıntılı bir değerlendirmesini sağlayarak çalışmanın inşaat projelerini yönetmek için mekansal-zamansal bir model geliştirme amacını desteklemiştir. Kalan özelliklerin alaka düzeyini korumak amacıyla özellik seçimi öncesinde ve sonrasında Pearson korelasyonu gibi çeşitli analizler gerçekleştirilmiştir. Buna bağlı olarak, Şekil 17 ve 18'de seçilen özellikler arasındaki Pearson korelasyonunu ve bu özelliklerin sırasıyla CPI ve SPI tahmin çıktılarıyla ilişkisi gösterilmekte olup bu değişkenlerin proje sonuçlarını tahmin etmedeki birbirleriyle olan ilişkileri ortaya koyulmaktadır.



Şekil 17. Seçilen özelliklerin ve CPI tahmininin Pearson korelasyonu.



Şekil 18. Seçilen özelliklerin ve SPI tahmininin Pearson korelasyonu.

Miktar (C8) ve Hafta (C21) gibi özellikler arasındaki korelasyon veri setleri arasında önemli ölçüde değişiklik göstermekte olup bu da proje karmaşıklıkları ve işin zamansal dağılımındaki farklılıkları göstermektedir. Ayrıca, WBS grup 2 (C1), Aktivite grubu (C2) ve CPI veya SPI çıktıları arasında farklı derecelerde korelasyon gözlenmiş olup bu durum

aktivitelerin organizasyon yapısının ve kategorize edilmesinin proje maliyet performansını etkilediğini göstermektedir. Bu durum, her bölgedeki yönetim uygulamaları ve proje kapsamı arasındaki farklılıkları yansıtabilir. Özellikle, Planlanan birim kişi saati ve Gerçekleşen birim kişi saati özellikleri (C16 ve C17) arasında yüksek korelasyon gözlemlenmiştir. Bu korelasyon tüm veri setlerinde güçlü bir doğrusal ilişki göstermekte olup planlanan kişi saatlerinin harcanan gerçek kişi saatlerle yakından uyumlu olduğunu ortaya koymaktadır. Bu ilişki, aktivitelerin kazanılan değerini değerlendirmek açısından önemlidir ve projelerin zaman çizelgelerine ve bütçelerine ne kadar sadık kaldığını yansıtmaktadır. Özellikle Bursa ve Elazığ veri setleri, Adana ve Yozgat'a kıyasla daha yüksek korelasyon değerleri göstermekte olup bu durum bu bölgelerde daha tutarlı proje yürütme ve izleme süreçleri olduğuna işaret etmektedir. Tablo 3 dört mega inşaat projesinden türetilen temizlenmiş veri setinin istatistiksel özelliklerini sunmaktadır.

Tablo 3. Mekansal-zamansal ML modellerinde kullanılan kodlanmış veri setinin istatistiksel detayları.


Proje adı	Özellik niteliklerinin sütunu	CPI tahmini veri kümesi		SPI tahmini veri kümesi	
		Sayım	Benzersiz kategoriler	Sayım	Benzersiz kategoriler
Adana	Hafta	119660	41	122446	41
	Miktar	119660	4392	122446	4392
	Ağırlık (%)	119660	30	122446	30
	Planlanan ilerleme (%)	119660	182	122446	236
	Planlanan birim kişi-saat	119660	139	122446	139
	Gerçekleşen birim kişi-saat	119660	2319	122446	2319
	WBS grubu 2	119660	8	122446	8
	Aktivite grubu	119660	232	122446	232
	CPI/SPI sınıfı	119660	2	122446	2
	Düğüm	119660	232	122446	232
	Kenar	119660	190	122446	190
Bursa	Hafta	267763	52	312643	52
	Miktar	267763	5907	312643	6645
	Ağırlık (%)	267763	63	312643	72
	Planlanan ilerleme (%)	267763	880	312643	899
	Planlanan birim kişi-saat	267763	167	312643	197
	Gerçekleşen birim kişi-saat	267763	1556	312643	1556

Tablo 3'nin devamı

	WBS grubu 2	267763	8	312643	8
	Aktivite grubu	267763	155	312643	195
	CPI/SPI sınıfı	267763	300	312643	304
	Düğüm	267763	155	312643	195
	Kenar	267763	300	312643	304
Elazığ	Hafta	218257	53	238407	53
	Miktar	218257	5,237	238407	5,238
	Ağırlık (%)	218257	40	238407	40
	Planlanan ilerleme (%)	218257	940	238407	966
	Planlanan birim kişi-saat	218257	226	238407	241
	Gerçekleşen birim kişi-saat	218257	2,577	238407	2,577
	WBS grubu 2	218257	8	238407	8
	Aktivite grubu	218257	228	238407	229
	CPI/SPI sınıfı	218257	2	238407	2
	Düğüm	218257	228	238407	229
	Kenar	218257	246	238407	246
Yozgat	Hafta	26553	28	26553	28
	Miktar	26553	1,585	26553	1,585
	Ağırlık (%)	26553	24	26553	24
	Planlanan ilerleme (%)	26,553	94	26553	128
	Planlanan birim kişi-saat	26553	162	26553	164
	Gerçekleşen birim kişi-saat	26553	1,964	26553	1,964
	WBS grubu 2	25459	8	26553	8
	Aktivite grubu	26553	317	26553	317
	CPI/SPI sınıfı	26553	2	26553	2
	Düğüm	26553	317	26553	317
	Kenar	26553	130	26553	130

Veri kümesindeki ana özellikler iki kategoriye ayrılmıştır: zamansal özellikler ve mekansal özellikler. Zamansal özellikler, inşaat aktivitelerinin hafta bazında ilerlemesini temsil ederken, mekansal özellikler her bir projedeki farklı iş paketlerini ve aktivite gruplarını temsil etmektedir. Haftalık sütun, aktivitelerin haftalık olarak ilerleyişini sergileyen bir zamansal özellik oluşturmaktadır. Örneğin, Bursa projesinde veriler 1. haftadan 52. haftaya kadar toplanmış ve modelin aktivitelerin zaman içinde nasıl ilerlediğini değerlendirmesine olanak tanımıştır. Aktivite grubu sütunu WBS içindeki aktivitelerin

gruplanmasını belirtmektedir. Örneğin, Adana projesinde, “Demir donatı montajı”, “Kalıp montajı” ve “Beton dökümü” gibi 232 farklı aktivite grubu bulunmuştur. Her inşaat projesi, kendi kaynak gereksinimleri, zaman çizelgeleri ve bağımlılıkları olan birden fazla örtüşen aktiviteyi içermektedir. Bu aktiviteler izole bir şekilde gerçekleşmemiş, aksine zaman içinde gelişen karmaşık bir ağ oluşturmuştur. Ayrıca, iş gücü mevcudiyeti, hava koşulları ve malzeme teslimatları gibi sürekli değişen değişkenlerle birlikte inşaat sahalarının dinamik doğası, tahminleri daha da zorlaştırmıştır. Ağırlık (%) sütunu her bir aktivitenin toplam proje ilerlemesine katkısı açısından ağırlığını göstermiştir. Örneğin, Elazığ veri setinde temel çalışmalarına ilişkin aktiviteler boyama gibi daha küçük tamamlayıcı aktivitelere kıyasla daha yüksek bir ağırlık yüzdesine sahip olmuştur. Planlanan ilerleme sütunu, belirli bir haftaya kadar tamamlanması planlanan her bir aktivitenin yüzdesini temsil etmektedir. Örneğin, Yozgat projesinde temel çalışmalarının 10. haftada %40 oranında tamamlanması planlanırken, elektrik işlerinin aynı haftada yalnızca %20 oranında tamamlanması planlanmıştır. Bu sütun, gerçek ilerlemenin karşılaştırıldığı bir kıyas noktası olarak dikkate alınmıştır. Planlanan kişi-saat sütunu, bir aktiviteyi tamamlamak için gereken tahmini kişi-saat değerini içermektedir. İş gücü gereksinimlerini ve zamanlama verimliliğini anlamak açısından kritik öneme sahiptir. Örneğin, Adana veri setinde belirli bir hafta için çelik donatı aktiviteleri için planlanan kişi-saat 3000 saat, kalıp montajı için ise 1500 saat olmuştur. Gerçek kişi-saat sütunu, her bir aktiviteye gerçekten harcanan kişi-saat sayısını göstermektedir. Bu sütun, planlanan ve gerçek iş gücü kaynakları arasındaki farkı izlemeye olanak tanıyarak CPI ve SPI hesaplamasında önemli bir faktör olmuştur. Bu sütunlar karşılaştırıldığında verimlilik ve kaynak kullanımı hakkında içgörüler elde edilmiştir. WBS grubu 2 sütunu, bir aktivitenin ait olduğu belirli WBS grubunu tanımlamaktadır. WBS projeyi yönetilebilir bölümlere ayıran hiyerarşik bir yapıdır. Örneğin Adana'nın WBS grubu 2 sütunu, “Elektrik Tesisatı” ve “Yalıtım” gibi sekiz benzersiz kategori içermiştir. Şekil 19 projelerdeki WBS grubu 2 sütunundaki kategorilerin sıklığını göstermektedir.



Şekil 19. Adana, Bursa, Elazığ ve Yozgat veri setlerindeki WBS grubu 2 sütunlarındaki kategorilerin sıklığı.

Adana veri seti aktivitelerin iki önemli dönemde belirgin bir yoğunlaşma gösterdiğini ortaya koymuştur: projenin başlarında (1-15. haftalar) ve sonlarına doğru (45-50. haftalar). Elektrik işleri ve ince işler, özellikle projenin erken haftalarında baskınken mekanik işler ve kaplama işleri son aşamalarda daha belirgin hale gelmiştir. Bu desen projenin erken safhalarında yoğun aktivite dönemleri, orta haftalarda ise daha düşük ilerleme yaşadığına

işaret etmektedir. Buna göre projenin ilk aşamalarda maliyet verimliliğini yönetmesine rağmen, sonlara doğru zorluklarla karşılaştığı düşünülmektedir. CPI'daki dalgalanmaların bu dönemsel farklılıklardan kaynaklanmış olması muhtemeldir. Benzer şekilde, SPI dağılımı da CPI ile paralellik göstermiş ve aynı dönemlerde yoğun aktiviteler ortaya çıkmıştır. Erken haftalarda elektrik ve ince işlerin sıklığı, başlangıçta planlanan zaman çizelgesine uyum sağlandığını göstermektedir. Bununla birlikte, projenin ilerleyen aşamalarında mekanik işlerdeki keskin artış, kritik görevlerin tamamlanmasında gecikmelere işaret etmekte ve projenin zaman çizelgesine yetişme çabalarını yansıtmaktadır. Bu aktivitelerdeki net artışlar, projenin önceki gecikmelerden kurtulma çabalarını vurgulayarak, SPI tahminlerini hem verimli hem de verimsiz dönemler açısından etkilemiştir.


Bursa projenin süresi boyunca daha dengeli bir dağılım gösteren bir aktivite profiline sahiptir (Haftalar 0-50). Veri seti proje boyunca mekanik işler ve ince işlerin sürekli varlığına işaret etmiş yalıtım işleri ve hafriyat işleri de istikrarlı bir şekilde ilerlemiştir. Dengeli dağılım, projenin tutarlı bir ilerleme kaydettiğini ancak herhangi bir WBS kategorisinin herhangi bir dönemde baskın olmaması nedeniyle maliyet etkinliğini sürdürmede zorluklar yaşadığını göstermiştir. Bursa için SPI veri seti de aktivitelerin sabit bir ilerleme gerçekleştirdiğini yansıtarak herhangi bir kategoride dramatik değişim veya ani artış göstermemiştir. Bu dengeli dağılım, projenin takvime uygun ilerlediğini ve mekanik işlerle ince işlerin ilerlemeyi sürdürmeye en çok katkıda bulunduğunu işaret etmiştir. Ancak, proje boyunca bu aktivitelerin yüksek sıklığı programlama ve kaynak tahsisinde verimsizliklere işaret ederek genel SPI'yi etkileyebileceği düşünülmektedir.

Elazığ veri seti, özellikle projenin ilk yarısında (Haftalar 0-25) çeşitli ve yüksek sıklıkta WBS kategorilerinin dağılımını göstermektedir. Mekanik işler ve ince işler yaygın olarak görülmekte olup, elektrik işlerinden de önemli katkılar gelmiştir. Çeşitli ve yoğun erken dönem aktiviteleri hızlı bir başlangıç yapmayı hedefleyen bir projeye işaret etmekle birlikte, eşzamanlı olarak birden fazla aktivitenin yürütülmesi nedeniyle maliyet yönetiminde zorluklar yaşanmış olunabileceği düşünülmektedir. Sonraki haftalarda aktivitelerin azalması ya aktivitelerin sona erdiğini ya da bütçe aşımı nedeniyle ilerlemenin kısıtlandığını işaret etmektedir. SPI dağılımı da CPI ile yakından benzerlik göstermekte olup erken dönemde mekanik işler ve ince işlere odaklanıldığını göstermektedir. Projenin başlangıçta programın ilerisinde kalmaya çalıştığını ancak daha sonra bu tempoyu sürdürmede zorluklar yaşandığını ve gecikmelere yol açtığını sergilenmiştir. Veri seti,


projenin verimli bir başlangıç yapmış olabileceğini ancak bu verimliliğin tüm aktiviteler boyunca sürdürülemediğini ve bunun SPI tahminlerini etkilediğini göstermiştir.

Yozgat veri seti en küçük ve en yoğun olanıdır. Aktiviteler 10. ve 35. haftalar arasında yoğunlaşmıştır. Mekanik işler ve ince işler baskın olup elektrik işleri ve kaplama işleri de katkıda bulunmuştur. Yoğun aktivite periyodu projenin sıkı kısıtlamalar altında çalışmış olabileceğini ve belirli aşamalarda maliyet etkinliği sağlarken sıkıştırılmış zaman çizelgesi nedeniyle bütçe aşmaları riskini artırabileceğini göstermiştir. Yozgat'taki SPI dağılımı da projenin yoğun ve sıkışık doğasını yansıtmaktadır. Mekanik işler ve ince işlerin sıklığı, projenin muhtemelen son tarihlere uymak için büyük baskı altında olduğunu ve bunun hem verimli hem de gecikmeli dönemlere yol açabileceğini göstermiştir. Kısa bir süre içinde aktivitelerin yüksek yoğunlukta gerçekleşmesi, projenin bu aşamada hem zamanında hem de verimli olduğunu, ancak gecikmeleri veya verimsizlikleri yönetme esnekliğinin sınırlı olabileceğini düşündürmektedir.

Şekiller 20 ve 21 dört farklı proje boyunca inşaat Aktivite gruplarının haftalık dağılımına daha derin bir bakış sunarak, belirli inşaat aktivitelerinin haftadan haftaya nasıl farklılık gösterdiğini ortaya koymaktadır.



Şekil 20. Adana, Bursa, Elazığ ve Yozgat projelerinde CPI tahmin veri setlerindeki inşaat Aktivite gruplarının sıklığı: (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat.



Şekil 21. Adana, Bursa, Elazığ ve Yozgat projelerinde SPI tahmin veri setlerindeki inşaat Aktivite gruplarının sıklığı: (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat.

Adana'da histogram genel olarak dengeli bir dağılıma sahip değişken bir aktivite grubu dağılımı göstermiş ve 10., 30. ve 50. haftaya yakın dönemlerde belirgin zirveler bulunmuştur. Bu desen, proje yaşam döngüsünde aktivitelerin yoğunlaştığı birkaç kritik aşamaya işaret etmekte olup bu durum proje dönüm noktaları veya hızlı gelişim aşamalarına yanıt olarak gerçekleşmiş olabilir. Adana'daki veri seti özellikle 24 ve 37. haftalar arasındaki eksik kayıtlarla önemli boşluklar göstermiştir. Bu veri eksikliği etkili model eğitimi ve tahmin doğruluğu için gerekli olan sürekliliği bozduğu için oldukça kritik öneme sahip olmuştur. Bu tür boşluklar özellikle eksik dönemlerde zaman hassasiyeti taşıyan olayların veya koşulların tahmin edilmesi için modellerin performansını düşürebilir.

Bursa aktivite sıklığında daha belirgin bir değişkenlik sergilemekte ve özellikle 25. ve 40. haftalar civarında aktivitelerin belirgin zirvelere ulaştığı dönemler göstermektedir. Bu dönemler muhtemelen proje teslimatları veya kritik yapısal tamamlamalar nedeniyle inşaat çabalarının arttığı dönemlerdir. Elazığ veri seti Bursa kadar geniş olmasa da minimal eksik kayıtlarla yüksek veri bütünlüğünü korumaktadır. Sergilenen aktivite deseni 10. ve 30. haftalar arasında aktivitelerin belirgin şekilde arttığı daha yoğun bir dalgalanma serisi

göstermektedir. Bu artış birden fazla aktivitenin üst üste geldiği veya proje zaman çizelgelerine uymak için senkronize edildiği bir inşaatın temel aşamasını yansıtmaktadır.

Genel olarak, Elazığ'ın veri seti güvenilir tahmin performansı sağlayan sağlam bir model eğitime temel olmuş olup daha küçük veri seti boyutu nedeniyle Bursa kadar etkili olmayabileceği de kabul edilmektedir.

Yozgat ise farklı bir eğilim göstermektedir. Daha az haftalık veriye sahip olmakla birlikte, 35. hafta civarında aktivitelerde keskin bir artış gözlenmiştir. Bu projenin tamamlanmasına yönelik son bir hamle veya gecikmelerin ardından yakalama aşamasının gerçekleştirildiğine işaret etmektedir. Bu durum, sınırlı süresi (Bursa ve Elazığ için 52 haftaya kıyasla yalnızca 30 hafta veri) ve 10., 27. ve 37. haftalarda olduğu gibi düzensiz eksik girişler nedeniyle zorluklar yaratmaktadır. Bu veri setinin parçalı doğası, özellikle uzun vadeli eğilimlerin veya sonuçların tahmin edilmesinde daha az etkili model eğitimi ve tahmin sonuçlarının elde edilmesine yol açabilir.


Veri seti boyutlarındaki ve bütünlüklerindeki farklılıklar çeşitli lokasyonlardaki tahmin modellerinin etkinliğini önemli ölçüde etkilemiştir. Bursa ve Elazığ'dan elde edilen kapsamlı veri setleri mekansal-zamansal modellerin eğitimi için daha sağlam bir temel olmakta ve tahminlerde daha yüksek doğruluk ve güvenilirlik sağlamaktadır. Buna karşılık, Adana ve Yozgat veri setlerindeki boşluklar yalnızca model eğitimi sürecini zorlaştırmakla kalmayıp bu veri setlerinden geliştirilen modellerin genelleştirilebilirliğini ve sağlamlığını da tehlikeye atmıştır. İdeal bir senaryoda, inşaat firmalarının Bursa ve Elazığ veri setlerinde görülen veri toplama tutarlılığını örnek alması beklenir. Ancak, gerçek dünya kısıtlamaları, hatalar, sipariş değişiklikleri, aşırı koşullar ve hatta öngörülemeyen olaylar nedeniyle proje kesintileri gibi durumlar eksik veri setlerine yol açabilmektedir. Bu faktörler düzensiz veri girdileriyle başa çıkabilecek ve yine de yeterli performans gösterebilecek modellerin geliştirilmesini gerekli kılmaktadır. Bu da gerçek dünya düzensizliklerini karşılayabilecek sağlam model eğitiminin önemini vurgulamaktadır. Bu çalışmada Adana, Bursa, Elazığ ve Yozgat'tan elde edilen veri setlerinin incelenmesi inşaat yönetimi alanında kapsamlı ve tutarlı veri toplamının kritik rolünü öne çıkarmaktadır. Bulgular, veri tutarsızlıklarıyla başa çıkabilecek ve yine de doğru tahminler sağlayabilecek uyarlanabilir modelleme stratejilerine olan ihtiyacı vurgulamaktadır. Bu da etkili proje yönetimi ve operasyonel verimlilik için gerekli olmaktadır. Veri seti kalitesi ve boyutlarındaki farklılıklar aynı zamanda tahmin modellerinin çalışması gereken değişken koşulları yansıtırken genel model performansını ve

güvenilirliğini artırmak için veri toplama uygulamalarının geliştirilmesine odaklanılmasını önermektedir.

Bu çalışmada dört büyük ölçekli inşaat projesinin performansı CPI ve SPI gibi temel performans göstergeleri kullanılarak analiz edilmiştir. Her proje için veri seti analiz edilerek projelerin CPI ve SPI performansı açısından verimli olup olmadığı belirlenmiştir. Analizler ilgili proje sahalarında veri toplama süreçlerine dahil olan saha yöneticileriyle yapılan görüşmelerle de ayrıca desteklenmiştir: CPI ve SPI temel performans göstergeleri için kullanılan tanımlar aşağıdaki gibi verilmektedir.

- Verimli CPI ($CPI \geq 1$): Bu, projenin maliyet açısından verimli olduğunu ve işi ayrılan bütçe dahilinde veya altında tamamladığını gösterir.
- Verimsiz CPI ($CPI < 1$): Bu, projenin maliyet aşımaları yaşadığını, yani gerçekleşen maliyetlerin planlanan bütçeleri aştığını ifade eder.
- Zamanında SPI ($SPI \geq 1$): Bu, projenin zamanında veya takviminin ilerisinde olduğunu, işleri planlandığı gibi ya da daha hızlı tamamladığını gösterir.
- Gecikmiş SPI ($SPI < 1$): Bu, projenin planlanan takvimin gerisinde olduğunu, yani planlanandan daha az işin tamamlandığını gösterir.

Şekil 22 farklı veri setlerinde CPI ve SPI tahmin sütunlarındaki tahmin etiketlerinin sayısını göstermektedir.




Şekil 22. Farklı veri setlerinde CPI ve SPI tahmin sütunlarındaki tahmin etiketlerinin sayısı.

CPI ve SPI sınıfları manuel kodlama yoluyla proje verimliliğini yansıtacak şekilde etiketlenmiştir; “verimsiz” CPI sınıfları sıfır olarak etiketlenirken, “verimli” ve “normal”

sınıflar bir olarak işaretlenmiştir. Benzer şekilde, SPI için “gecikmiş” aktiviteler sıfır olarak etiketlenmiş, “normal”, “zamanında”, “tamamlanmış” ve “ileride” olan aktiviteler bir olarak işaretlenmiştir. Bu etiketleme stratejisi çalışmanın inşaat planlarındaki tutarsızlıkları işaretleyebilen ve iyi planlanmış aktiviteleri iyi performansın göstergeleri olarak tanımlayabilen bir model geliştirme amacına temel teşkil etmiştir. Sonuç olarak, CPI sınıflarının dağılımı, 201222 kaydın Verimli (Etiket 1) ve 134604 kaydın Verimsiz (Etiket 0) olarak etiketlenmiştir. Bu veri setinde çeşitli seviyelerde sınıf dengesizliği gözlenmiştir. Örneğin, Adana'da proje çoğunlukla maliyet açısından verimli iken ($CPI \geq 1$ için 47305 kayıt, $CPI < 1$ için 35452 kayıt) süre açısından gecikmişti ($SPI < 1$ için 62106 kayıt, $SPI \geq 1$ için 23064 kayıt). Benzer şekilde, Bursa da benzer bir desen sergilemiştir: Maliyet açısından genellikle verimli iken ($CPI \geq 1$ için 184392 kayıt, $CPI < 1$ için 83371 kayıt) zamanlama yönünden gecikmişti ($SPI < 1$ için 226357 kayıt, $SPI \geq 1$ için 86286 kayıt). Bu dengesizlik, modeller için özellikle bazı veri setlerinde yeterince temsil edilmeyen gecikmiş SPI sınıfını yönetmede zorluk teşkil etmiştir. “

Dört inşaat projesinin (Adana, Bursa, Elazığ ve Yozgat) zaman dilimleri boyunca genel sınıf dengesizliğine ek olarak, iki temel performans göstergesi (CPI ve SPI) arasında da belirgin bir sınıf dengesizliği görülmektedir. Bu dengesizlik, her projenin farklı aşamalarında değişiklik göstermekte olup Şekil 23'te verilmektedir. Şekil 23 CPI ve SPI sınıflarının—CPI için verimli/verimsiz ve SPI için zamanında/gecikmiş—ilerleyen haftalar içerisindeki sıklığını göstermektedir.



Şekil 23. Adana, Bursa, Elazığ ve Yozgat veri setlerinde CPI ve SPI sütunlarındaki kategorilerin sıklığı.

Şekil 23, proje yaşam döngüsü boyunca CPI ve SPI sınıflarının inşaat zaman çizelgelerinin farklı noktalarındaki dağılımlarını vurgulamaktadır. Adana için CPI dağılımı proje süresinin büyük bir kısmında (Haftalar 1-30 ve Haftalar 45-50) aktivitelerin verimli olarak etiklendiğini göstermektedir. Verimlilikte belirgin bir zirve 10. ve 20. haftalar arasında gözlenirken, projenin ortasında verimlilikte bir düşüş yaşanmıştır. Daha düşük aktivite dönemi sonrasında, projenin sonunda verimlilik tekrar artmıştır. Buna karşılık, Adana için SPI dağılımı aktivitelerin büyük ölçüde gecikmeli olduğunu ve özellikle erken haftalarda (Haftalar 1-20) gecikmelerin baskın olduğunu ortaya koymaktadır. 30. ve 40.

haftalar arasında gecikmelerde önemli bir düşüş olsa da projenin sonunda gecikmeler yeniden artmıştır. Bu durum, projenin maliyet açısından verimli olmasına rağmen sürekli olarak takvim uyumunda zorlandığını göstermektedir. Adana'daki CPI ve SPI arasındaki bu karşıtlık, maliyet ve zamanlama performansını aynı anda yönetmenin zorluklarını ortaya koymaktadır. Proje maliyet açısından verimli kalırken sürekli gecikmelerle karşılaşmıştır ki bu büyük ölçekli inşaat projelerinde sıklıkla görülen bir sorundur. Bu sorun bir alanda sağlanan verimliliğin genellikle diğer alanın zayıflaması pahasına üstlenilerek elde edilir.

Bursa'da CPI dağılımında verimli etiketler baskın olup verimlilik proje boyunca (Haftalar 0-50) nispeten sabit kalmıştır. Özellikle projenin ortasında dalgalanmalar olsa da genel eğilim projenin çoğu zaman diliminde maliyet verimliliğini koruduğunu göstermektedir. Adana'ya benzer şekilde, SPI dağılımında gecikmeli aktiviteler Bursa'da da baskındır. Bazı iyileşme dönemlerine rağmen, proje özellikle ilk yarısında (Haftalar 0-30) zamanlama uyumunda büyük ölçüde zorlanmıştır. Projenin maliyet açısından verimli olmasına rağmen sürekli gecikmeler yaşanması, maliyetlerin kontrol altında tutulmasının sıklıkla zamanın feda edilmesini gerektirdiğini ve bu durumun zamanlama kaymalarına yol açan yaygın bir eğilim olarak karşılaşıldığını yansıtmaktadır.


Elazığ'da projenin erken döneminde (Haftalar 0-30) yüksek sıklıkta verimli aktiviteler görülmekte ancak proje ilerledikçe verimlilikte kademeli bir düşüş yaşanmaktadır. Veri seti projenin maliyetleri yönetme konusunda güçlü bir başlangıç yaptığını ancak ilerledikçe verimliliği sürdürmenin daha zor hale geldiğini göstermektedir. Elazığ için SPI dağılımı, CPI verilerine benzer bir desen göstermekte ancak ters bir eğilimle; gecikmeli aktiviteler, özellikle projenin orta ve son aşamalarında baskın hale gelmiştir. Bu durum, projenin başlangıçta verimli olmasına rağmen özellikle daha fazla aktivite tamamlandıkça zamanlama uyumunun sorun haline geldiğini göstermektedir. Elazığ projesi gibi maliyet açısından verimli olan projelerin ilerledikçe gecikmeler yaşaması, özellikle kaynak tahsisi ve görev yönetiminin daha karmaşık hale geldiği bu aşamalarda sorunların artması gibi tanıdık bir eğilimi sergilemektedir.

Yozgat için CPI dağılımı diğer projelere kıyasla verimli ve verimsiz aktiviteler arasında daha dengeli bir dağılım sunmaktadır. Bu projede maliyet verimliliğinde daha fazla değişkenlik yaşanmış verimsizlik dönemleri zaman çizelgesi boyunca (Haftalar 10-35) aralıklı olarak ortaya çıkmıştır. Bu dalgalanmalara rağmen, projenin ortasında verimliliğin baskın olduğu açıkça görülmektedir. Buna karşılık, SPI dağılımı daha dengeli ancak büyük ölçüde gecikmeli aktivitelerden oluşmaktadır. Diğer projelere benzer şekilde, Yozgat'ta da

takvimi tutturma konusunda zorluklar yaşamıştır. Ancak Adana veya Bursa'ya kıyasla daha fazla zamanında tamamlanan aktivite dönemleri vardır. Yozgat maliyet performansı açısından daha değişken bir yapıya sahip olup bu durumun projenin daha küçük boyutlu ve sıralı olmasından kaynaklanmış olabileceği düşünülmektedir. Bununla birlikte, maliyet verimliliğinin sağlandığı dönemlerde bile tanıdık bir zorluk olan takvim gecikmeleriyle karşı karşıya kalınmıştır.

CPI tahminleri verimli etiketlerin baskınlığı nedeniyle genellikle başarılı olmuştur. Ancak, SPI tahminleri gecikmeli aktivitelerin yüksek sıklığı nedeniyle daha zorlayıcı olmuştur. Projeler boyunca gecikmelerin sürekliliği, gelecekteki çalışmaların zamanlama uyumunun karmaşık dinamiklerini daha iyi yakalayabilmek için dikkat mekanizmaları veya dizi modelleme gibi ileri teknikleri keşfetmesi gerektiğini göstermektedir. Bu tutarlı gözlem, inşaat projelerinde maliyetleri verimli bir şekilde yönetmenin öncelikli bir odak noktası olmasına rağmen zamanlama uyumunun sağlanmasının önemli bir zorluk olarak kaldığını göstermektedir. Projeler genellikle kaynakları verimli bir şekilde tahsis ederek aktivitelerin bütçe dahilinde tamamlanmasını sağlarken inşaat görevlerinin karmaşık ve birbirine bağımlı doğası nedeniyle zaman yönetimi sıkça zarar görmektedir. Bu çalışmada, sınıf dağılımlarının proje zaman çizelgesi boyunca dalgalanacağı dikkate alınarak mekansal-zamansal modeller geliştirilmiştir.

Şekil 24 CPI tahmini için her bir veri setindeki farklı pencerelerdeki kayıt sayısını göstermektedir. Farklı şehirlerdeki mega projelerden elde edilen veri setleri, her biri 21 haftalık dönemleri kapsayan ve yaklaşık %70'i eğitim için, geri kalan %30'u ise doğrulama ve test setleri arasında bölünmüş olan kaydırmalı pencerelere ayrılmıştır. Her pencere, proje yaşam döngüsü içinde belirli bir dönemi temsil etmiş ve bu sayede modeller o döneme özgü değişimleri öğrenebilmiş ve uyum sağlayabilmiştir. Bu segmentasyon stratejisi inşaat projesi verilerinin zaman içindeki dinamik ve değişen doğasını yakalamayı ve modellerin en güncel ve ilgili bilgilerle eğitilmesini sağlamayı hedeflemiştir.



Şekil 24. Farklı ilerleme haftaları boyunca (a) Adana, (b) Bursa, (c) Elazığ ve (d) Yozgat projelerindeki eğitim, test ve doğrulama kayıtlarının dağılımı.

Şekil 24a'da gösterildiği gibi, Adana veri seti CPI tahmini için altı pencereye ayrılmış olup eğitim süreleri kademeli olarak ileri kaydırılmıştır. Eğitim örnekleri 26642 ile 52307 arasında, doğrulama örnekleri 3252 ile 12558 arasında ve test örnekleri 2809 ile 13273 arasında değişmiştir. Benzer şekilde, Adana için SPI tahmin veri seti de altı pencereden oluşmuş olup CPI veri setine kıyasla biraz daha yüksek örnek sayıları içermiştir. Eğitim örnekleri 27347 ile 53753 arasında, doğrulama örnekleri 3456 ile 13018 arasında ve test örnekleri 2909 ile 13708 arasında değişmiştir. Adana inşaatından elde edilen verilerde özellikle 3., 4. ve 5. pencerelerde raporların eksik olduğu dönemlerle örtüşen önemli boşluklar bulunmaktadır. Bu boşluklar, modelin etkili bir şekilde öğrenme yeteneğini potansiyel olarak etkilemiş ve bu pencerelerde tahmin doğruluğunun azalmasına neden olmuştur.

Bursa veri seti (Şekil 24b) erken orta proje pencerelerinde veri hacimlerinin zirveye ulaştığı sekiz kaydırmalı pencere içermektedir. Bursa CPI tahmin verileri sekiz pencereyi kapsamış olup, Adana'ya kıyasla daha uzun bir tahmin aralığını işaret etmektedir. Eğitim örnekleri 37332 ile 119944 arasında, doğrulama örnekleri 5194 ile 14991 arasında ve test örnekleri 7314 ile 23855 arasında değişmiştir. SPI tahmini için Bursa veri seti de sekiz pencere içermekte olup, eğitim örnekleri 43577 ile 133579 arasında, doğrulama örnekleri 6069 ile 17158 arasında ve test örnekleri 8582 ile 27697 arasında değişmiştir. Adana veri setiyle karşılaştırıldığında Bursa projesinden daha tutarlı kayıtlar toplamış olup zaman çizelgesinde daha az kesinti ve eksik veri bulunmaktadır.

Elazığ veri seti (Şekil 24c) dokuz pencereye yayılmakta olup son pencerelerdeki veri hacminde belirgin bir düşüş gözlenmektedir. Elazığ'ın CPI tahmin veri seti pencereler ilerledikçe eğitim örneklerinin 114452'den 17432'ye düştüğü dokuz pencereyi içermektedir. Doğrulama örnekleri 1276 ile 24733 arasında, test örnekleri ise 3722 ile 25482 arasında değişmektedir. Bu veri seti, çeşitli proje aşamalarını yakalamayı amaçlayan kapsamlı bir zaman aralığını yansıtmaktadır. Elazığ için SPI tahmini, dokuz pencereye CPI yapısının aynısını izlemektedir. Eğitim örnekleri 123806 ile 17971 arasında, doğrulama örnekleri 1302 ile 26583 arasında ve test örnekleri 3747 ile 27834 arasında değişmektedir. Bursa veri setine benzer şekilde, Elazığ veri seti de en çok veriyi proje başlangıcı ve orta dönemlerinde içermektedir. Elazığ'da veri boşlukları mevcut olmakla birlikte, Adana veri setine göre daha az belirgin olup, daha istikrarlı bir veri toplama sürecini işaret etmektedir.

Yozgat projesinden toplanan daha az sayıda inşaat ilerleme kaydı göz önüne alındığında (Şekil 24d), veri seti yalnızca iki pencereye bölünmüştür. Toplanan raporlar,


Yozgat projesinin ilk 10 haftasına ait ilerleme kayıtlarını içermemektedir. Ancak, projenin sonraki aşamalarında eksik veri noktaları minimum düzeyde olup bu da daha güçlü ve tutarlı bir veri toplama çabasını göstermektedir.

Şekil 24'ten gözlemlendiği üzere, mekansal-zamansal CPI ve SPI tahmin modelleri için kullanılan girdi verileri her proje boyunca veri setleri ve tahmin zaman dilimlerinde önemli ölçüde değişkenlik göstermektedir. Adana'da, ilk iki pencereden sonra belirgin kayıt eksikliği desenleri kaydedilmiştir. Özellikle, 3. pencerede eğitim, test ve doğrulama veri setleri arasında 15 haftayı aşan bir boşluk görülmektedir. 4. penceredeki bu zaman süreksizliği, eğitim ve doğrulama veri setlerini test setinden ayırmakta ve eski mekansal-zamansal modellerin uzun vadeli sonuçlar için kullanılmasındaki zorlukları ortaya koymaktadır. Adana projesindeki sonraki pencerelerde (5 ve 6) kayıtların olmaması, eğitim verilerinde 15 haftadan fazla boşluk yaratmış ve bu durum mekansal-zamansal modellerin ardışık öğrenme yeteneğini olumsuz etkilemiştir. Buna karşılık, en kapsamlı kayıt sayısına sahip olan Bursa, sekiz pencere boyunca geniş bir zaman dilimini kapsayarak önemli boşluklar olmadan proje aşamalarının geniş bir yelpazesini yakalamış ve daha tutarlı model eğitimi ve doğrulamasını kolaylaştırmıştır. Dokuz pencereye yayılan Elazığ veri seti, proje dinamiklerine dair daha zengin analitik bakış açıları sunarak en ayrıntılı zaman içgörülerini sağlamaktadır. Buna karşılık, yalnızca iki pencereye yayılan Yozgat veri seti daha sınırlı olmakla birlikte, hedeflenmiş analitik yaklaşımlar için uygundur. Farklı şehirler ve pencerelerde eğitim, doğrulama ve test aşamalarındaki örnek sayılarındaki değişkenlik inşaat veri setlerinin çeşitli doğasını ortaya koymuştur. Bu çeşitlilik, CPI ve SPI'yi doğru bir şekilde tahmin edebilecek sağlam mekansal-zamansal modellerin kapsamlı bir şekilde değerlendirilmesi ve seçilmesi için önemlidir. Bu tür modeller, proje maliyetlerini ve zamanlamalarını etkili bir şekilde yönetmek için hayati önem taşımakta olup inşaat projesi verilerinin karmaşıklıklarını ve değişkenliklerini ele alacak uyarlanabilir ve iyi kalibre edilmiş modellere olan ihtiyacı vurgulamaktadır.

2.3. Mekansal-Zamansal Modellerin Girdi Ağlar

Bu tezin ara hedeflerinden biri mekansal-zamansal modellerin girdi ağlarının tasarımı ve yapılandırılmasıdır. Bu ağlar, inşaat ilerleme raporlarından hareketle hem inşaat aktivite verilerini hem aktiviteler arasındaki mekansal ilişkileri hem de zamansal sıralamaları kapsayan yapılandırılmış bir formata dönüştürülmüştür. Bu yapılandırma, etkili modelleme


için hayati öneme sahiptir. Bu tezde önerilen ağ tabanlı modelleme yaklaşımında, her inşaat aktivitesi bir düğüm yani veri noktası olarak temsil edilmiştir. Veri setindeki her satır bir aktiviteyi temsil eden bir düğüm olarak ele alınmıştır. Şekil 25'te projelerden alınan veri setini depolayan mekansal-zamansal CPI ve SPI tahmin modellerinde yer alan düğümlerin 100 adetlik bir bölümüne yönelik görselleştirilmesi sunulmaktadır.



Şekil 25. Projelere ait veri setini saklayan mekansal-zamansal CPI ve SPI tahmin modellerine ait 100 örnek düğümün görselleştirilmesi.

WBS kodları ve teslimat haftası gibi temel özellikler ana nitelikler olarak sistematik bir şekilde kaydedilmiş ve her düğümde depolanmıştır. Bu düğümler arasındaki bağlantılar

kenarlar olarak adlandırılmakta ve belirli kriterler doğrultusunda belirlenmiştir. Veri setinin büyük boyutu nedeniyle düğümler arasındaki bağlantılar, düğümler arasındaki bağlantıların varlığını veya yokluğunu gösteren ikili bir matris olan bitişiklik matrisi ile kurulmamıştır. Bunun yerine bu çalışmada, bahsedilen kriterlere göre doğrudan bağlantılı aktivite düğümü çiftlerini belirten kaynak-hedef bağlantı veri seti kullanılmıştır. Düğümler arasındaki bağlantılar onların mekansal ve zamansal nitelikleriyle tanımlanmıştır. Örneğin, eğer iki aktivite aynı WBS kodunu paylaşıyor ve aynı teslimat haftası için planlanıyorsa bağlantılı kabul edilmişlerdir. Bu bağlantı, yönlü bir bağlantı olarak her bağlantılı aktivite çiftini içeren kaynak-hedef veri setine kaydedilmiştir. Bu bağlantılar, her zaman diliminde alt ağların oluşturulmasına olanak sağlamış ve genellikle bir haftalık bir dönemi kapsamıştır. Her alt ağ, aynı hafta içinde gerçekleşen elektrik, mekanik veya yalıtım gibi aynı WBS'ye ait aktivite grubunu temsil etmiştir. Şekil 26 Adana, Bursa, Elazığ ve Yozgat projelerinde CPI ve SPI sınıflandırmaları için girdi ağlarının nasıl yapılandırıldığını göstermektedir.



Şekil 26. İnşaat ilerleme raporlarına dayanan girdi ağının yapılandırılması.

Şekil 26 farklı projelerden elde edilen veri seti ile ilişkili her bir girdi ağından örnek düğümleri göstermekte ve her projenin verisinin bir ağ grafiği olarak nasıl organize edildiği süreci detaylandırmaktadır. Süreç, her satırın kaydedilen ana nitelikleriyle birlikte bir inşaat aktivitesini temsil ettiği bir düğüm veri setinin oluşturulmasıyla başlamaktadır. Ardından, bağlantı veri seti tanıtılmıştır. Bağlantı veri seti, düğümler arasındaki bağlantıları yakalamakta olup bu bağlantılar paylaşılan WBS kodları ve teslimat haftalarına göre belirlenmiştir. Bu bağlantılar, bağlantı veri setindeki kaynak-hedef sütunlarında kaydedilmiştir. Sürecin son adımında, düğüm bilgileri bağlantı veri seti ile birleştirilerek bir girdi ağı oluşturulmuştur. Bu ağ, aynı WBS ve teslimat haftası içindeki aktiviteler arasındaki mekansal ilişkileri temsil etmektedir.


2.4. Mekansal-Zamansal Modellerin Yapılandırılması

Bu çalışmanın ana amacı mevcut literatüre daha kapsamlı inşaat ilerleme (zaman ve maliyet) tahmin modelleri geliştirerek katkıda bulunmaktır. İnşaat yönetimi literatürü, genellikle en doğru tahmin edicinin seçimine odaklanırken, bu çalışmada geliştirilen tahmin edici, inşaat ilerlemesinin daha güvenilir bir şekilde tahmin edilmesini sağlamak için hem model girdisine hem de tahmin ediciye odaklanmaktadır. Buna bağlı olarak, bu tezde GCN, GAT, GatedGNN ve artık ResGatedGNN modelleri ile mekansal ve zamansal bağlantıların kullanıldığı statik mekansal-zamansal modeller araştırılmıştır. Ayrıca, dinamik mekansal-zamansal modeller, zaman serileri ve GNN ile RNN varyantlarının farklı kombinasyonlarının değerlendirilmesi yoluyla araştırılmış, yönlü ve çift yönlü RNN, LSTM ve GRU'nun GCN, GAT ve geçit mekanizmaları ile entegrasyonu yapılmıştır. Böylelikle hem zamansal hem de mekansal özellik çıkarımının güçlü yönlerinden faydalanılmıştır.

2.4.1. GCN Modelinin Yapılandırılması

GCN ilk olarak geleneksel ML modellerine mekansal bir boyut eklemek amacıyla araştırılmıştır. Grafikler üzerinde yapılan evrimsel işlemlerle GCN komşu düğümlerden bilgi toplayarak mekansal ilişkileri verinin içine etkin bir şekilde gömmektedir. Bu model, inşaat yönetimi için ML modellerine mekansal içgörülerin dahil edilmesi için temel bir çerçeve sağlamış ve sonraki modeller için bir altyapı sunarak mekansal ve statik zamansal verilerin ilk kavranışını güçlendirmiştir. Bu çalışmada, GCN çıktısı CPI ve SPI'yi tahmin edecek şekilde ayarlanmıştır. Şekil 27 bu çalışmada kullanılan GCN modelinin mimarisini

göstermektedir. Grafikteki evrişimsel katmanlar, Kipf & Welling (2016) tarafından açıklanan şekilde ayarlanmış olup PyTorch Python kütüphanesi kullanılarak uygulanmıştır.




Şekil 27. CPI ve SPI tahmini için yapılandırılmış GCN modelinin mimarisi.

Şekil 27’de gösterildiği gibi model iki GCN evrişimsel katmanı içermekte olup her iki katmanda da mesaj geçişi işlemi uygulanmaktadır. İlk evrişimsel katmanın ardından doğrusal olmayan bir aktivasyon fonksiyonu, σ , uygulanmış ve doğrusal olmayan aktivasyon için düzeltilmiş doğrusal birim ReLU (Agarap, 2018) fonksiyonu kullanılmıştır. Modelin aşırı öğrenmesini (overfitting) önlemek için rastgele seçilen nöronların eğitim

sırasında devre dışı bırakıldığı bir Dropout oranı ayarlanmıştır. Daha sonra, ilk GCN katmanının çıktısının ikinci evrimsel katman üzerinden işlenilmesine devam edilmiştir.

2.4.2. GAT Modelinin Yapılandırılması

GAT dikkat mekanizmasıyla GCN'nin yeteneklerini genişleterek düğüm ilişkilerinin çeşitli yönlerini dinamik olarak yakalamak için birden fazla dikkat mekanizmasından yararlanmış ve modelin önemli özelliklere odaklanarak mekansal bağımlılıkların anlaşılmasını geliştirmiştir. Şekil 28 bu çalışmada kullanılan GAT modelinin mimarisini göstermektedir. Veličković vd. (2018) tarafından açıklanan bu model grafik evrimsel katmanlar içinde dikkat mekanizması kullanmaktadır.




Şekil 28. CPI ve SPI tahmini için yapılandırılmış GAT modelinin mimarisi.

Bu dikkat mekanizması modelin, öğrenme sürecini yönlendirerek girdi düğümlerindeki en etkili görev kayıtlarına odaklanmasını sağlamaktadır. Model, her biri çoklu kafalı (Multi-head) dikkat ve Dropout mekanizması seçenekleri içeren birden fazla grafik evrişimsel katman kullanmaktadır. Uygulanan GAT modeli mekansal inşaat aktivite verilerini işlemek için statik grafik yapısıyla çalışmakta olup modelde düğümler varlıkları, kenarlar ise ilişkileri temsil etmektedir. Model, paralel olarak birden fazla dikkat mekanizması kullanarak, farklı konumlardaki farklı temsil alt uzaylarında bulunan bilgiye dikkat etmektedir. Bu çoklu kafalı dikkat mekanizması, evrişimsel katmanlar boyunca tekrar tekrar uygulanmakta olup GAT'nin farklı soyutlama seviyelerinde özellik temsillerini öğrenmesini sağlamaktadır. Bu çalışmada aktivasyon fonksiyonu olarak üstel doğrusal birim (Exponential Linear Unit, ELU) (Clevert vd., 2015) dikkate alınmıştır.

2.4.3. GatedGNN Modellerinin Yapılandırılması

GNN'nin geçitli varyantı olan GatedGNN, bilgi akışını kontrol etmek için kullanılan bir geçit mekanizması tanıtılarak GNN'nin dinamik ve karmaşık mekansal etkileşimleri yönetme yeteneğini artırmıştır. Bu geçit mekanizması, modelin farklı düğümlerden gelen bilgileri seçici olarak önceliklendirmesine olanak tanıyarak yoğun bağlantılı girdi ağlarında özellik toplamanın bütünlüğünü korumak adına önem arz etmektedir. Şekil 29 yapılandırılmış GatedGNN modelinde kullanılan katmanları göstermektedir.




Şekil 29. Çalışmada kullanılan GatedGNN mimarisi.

İleri geçiş sırasında GatedGNN modeli, giriş düğümü özelliklerine ilk doğrusal dönüşümü uygulamak için tam bağlantılı sinir ağlarını kullanır ve bu özellikleri daha yüksek boyutlu bir uzaya haritalar. Ardından, ReLU aktivasyonu (Agarap, 2018) ve GatedGNN katmanı devreye girmektedir. Burada düğüm komşularından özellik toplama sırasında bilgi akışı geçitler aracılığıyla kontrol edilir. Daha sonra Dropout katmanı, GatedGNN'nin genelleme yeteneğini artırmak amacıyla bilginin bir kısmını sıfırlamaktadır. Kalan bilgi birimleri GatedGNN tarafından öğrenilen özellikleri CPI ve SPI sınıfları için sayısal olarak sınıflandırılmak üzere ikinci tam bağlantılı sinir ağı katmanına gönderilir. Çalışmada önerilen GatedGNN modelinin PyTorch kullanılarak yazılan Python kodu detayları Şekil 85 Ek 1'de verilmektedir.

2.4.4. ResGatedGNN Modellerinin Yapılandırılması

Artık bağlantılar (Residual Connections) ile birleştirilmiş GatedGNN (ResGatedGNN), derin ağ mimarilerinin eğitimiyle ilgili olarak karşılaşılan kaybolan gradyan (Vanishing Gradient) problemini çözmek için geliştirilmiştir. Bu bağlantılar, modelin katmanlar boyunca gradyan bilgisini kaybetmeden daha derin temsil öğrenmesini sağlamış olup grafik sinir ağlarında öğrenmenin derinliğini ve stabilitesini artırma yolunda önemli bir hesaplama adımını temsil etmektedir. Şekil 30 özelliklerin geçit mekanizması aracılığıyla yayılmasını ve artık bağlantılar kullanarak öğrenilmesini sağlayan ResGatedGNN katmanını içeren yapılandırılmış ResGatedGNN modelinin mimarisini göstermektedir.



Şekil 30. Çalışmada kullanılan ResGatedGNN mimarisi.

Şekil 30'da açıklandığı gibi modelin öğrenme süreci, daha önce CPI ve SPI tahmin görevleri için yapılandırılmış olan inşaat aktivite ilerleme ağının temel yapısal bilgilerini kapsayan bir girdi katmanı ile başlar. Bu modelin odağı ResGatedGNN katmanı olup geçitli grafik konvolüsyonları ve artık bağlantılar uygulanmaktadır. Bu katman, ağdaki bilgi akışını kontrol etmek için geçit mekanizmasını kullanarak özellik yayılımını gerçekleştirirken artık bağlantılar öğrenme sinyalinin birden fazla katman boyunca korunmasına yardımcı olur. Aşırı öğrenmeyi önlemek amacıyla ResGatedGNN katmanının çıktısına bir Dropout katmanı uygulanır. Daha sonra dönüştürülen özellikler gizli boyuttan çıktı boyutuna özellikleri eşleyen doğrusal bir dönüşüm gerçekleştirecek olan tam bağlantılı bir katmana iletilir. Son olarak, tam bağlantılı katmanın çıktısına Sigmoid aktivasyon fonksiyonu uygulanarak çıktılar 0 ile 1 arasında ölçeklenir.

2.4.5. GCRNN Modellerinin (RNN-GCN, GCN-RNN, Bi-RNN-GCN ve GCN-Bi-RNN)Yapılandırılması


Dinamik mekansal-zamansal ML tahmin modelleri, RNN'in varyantları ile GNN modellerini birleştirerek elde edilen hibrit bir hesaplama yaklaşımını temsil etmektedir. Bu kombinasyon, RNN'lerin sıralı veri işleme yeteneklerini GNN'lerin mekansal bilgi toplama verimliliği ile birleştirerek modelin hem zamansal dinamikleri hem de mekansal özellikleri tek bir çerçeve içinde ele almasını sağlamıştır. Mekansal-zamansal modellerin daha kapsamlı bir şekilde değerlendirilmesi için bu çalışmada, zamansal özelliklerin ilk olarak çıkarılması amacıyla RNN tabanlı modelleri kullanmıştır. Bu özellikler daha sonra mekansal olarak GNN'ler aracılığıyla işlenmiştir. Bu yapı, mekansal ilişkilerin zamansal dinamiklerden önce analiz edilmesini sağladığı için hesaplama açısından avantaj sağlamış olup mekansal-zamansal desenlerin öğrenilmesi için iyi yapılandırılmış ve fazla katmanlı bir yaklaşım sunmaktadır. Bu tez çalışmasında ayrıca zamansal işlemeye göre mekansal işlemi önceliklendiren mekansal-zamansal kombinasyonları da araştırmıştır.

Proje uygulama aşamasındaki inşaat aktivitelerinin zamansal sıralarını ve bu aktivitelerin diğer ilgili aktivitelere bağımlılığını ele alabilen bir model daha kapsamlı bir inşaat ilerleme tahmin modeli sunabilir. Bu durum bu çalışmada, aynı hafta içinde ve aynı WBS altında teslim edilen diğer aktivitelerin etkisini hesaba katarak farklı inşaat aktivitelerinin maliyet ve zamanlama performanslarını öğrenmek için GCN ve RNN modellerinin farklı kombinasyonlarını mekansal-zamansal bir yaklaşımla incelenmesini

teşvik etmiştir. RNN, inşaat projesi ilerleme haftaları boyunca verileri işleyerek ardışık bağımlılıkları yakalarken GCN, aktivitelerin paylaşılan gerçekleştirme haftası ve WBS temelinde bağımlılıklarını öğrenir. Bu çalışmada dört kombinasyon incelenmiştir: RNN-GCN, GCN-RNN, Bi-RNN-GCN ve GCN-Bi-RNN. Her bir kombinasyonun mantığı mekansal ve zamansal bağımlılıkları yakalamak adına kullandıkları benzersiz mekanizmalara dayanmaktadır. RNN-GCN modeli, mekansal öğrenmeden önce zamansal bağımlılıkları tek yönlü olarak işler. GCN-RNN modeli, önce mekansal ilişkileri öğrenip ardından zamansal bağımlılıkları işler. Bi-RNN veri setlerinde mevcut olan önceki ve sonraki haftaların zamansal bağımlılıklarını dikkate alır. Buna uygun olarak Bi-RNN-GCN, mekansal ilişkileri öğrenmeden önce zamansal bağımlılıkları çift yönlü olarak ele alırken GCN-Bi-RNN, önce mekansal ilişkileri öğrenip ardından çift yönlü zamansal bağımlılıkları araştırır.

Önerilen bu mekansal-zamansal kombinasyon modellerinin ile hem görev teslimlerinin zamansal sıralarından hem de WBS ve paylaşılan haftalar tarafından tanımlanan mekansal ilişkilerinden etkili bir şekilde öğrenme gerçekleştirebilmesi amaçlanmaktadır. Bu maksatla modeller, RNN veya Bi-RNN katmanları tarafından yakalanan ve inşaat haftalarının dizilerini işleyerek proje zaman çizelgesi boyunca görevlerin ilerleyişini anlayan zamansal bağımlılıkları hesaba katarken mekansal bağımlılıkları hesaba katmak için GCN katmanları, düğümlerin görevleri kenarların ise aynı WBS ve paylaşılan teslimat haftaları içindeki görevler arasındaki bağımlılıkları temsil edildiği ağ yapısını kullanır.

Şekil 31 RNN ve GCN modellerini birleştirerek yapılandırılan mekansal-zamansal modellerin mimarisini göstermektedir. RNN ve GCN katmanlarının farklı yapılandırmalarla birleştirilmesi yoluyla bu çalışmada, zamansal ve mekansal ilişki çıkarım sırasının inşaat ilerleme performansı tahminine olan etkisi de incelemiştir.



Şekil 31. CPI ve SPI tahmininde yapılandırılan (a) RNN-GCN ve (b) GCN-RNN modellerinin mimarisi.

Şekil 31a'da gösterildiği gibi giriş katmanı, düğümlerde saklanan inşaat aktiviteleri özelliklerini ve bağlantı bilgilerini sırayla işler. Bu giriş katmanı, farklı haftalardaki aktivite ilerlemeleri arasındaki zamansal bağımlılıkları yakalamak için RNN katmanlarında sıralı olarak işlenmiştir. RNN, aktivite ilerleme özelliklerini bir dizi boyutuna dönüştürerek zamansal desenleri yakalar ve RNN mekanizmaları aracılığıyla işler. RNN'nin çıktısının sonraki katmanda işlenmesi amacıyla sıra boyutu kaldırılmıştır. RNN katmanının çıktısı, eğitim sırasında giriş birimlerinin bir kısmını rastgele sıfırlayan bir Dropout katmanına iletilir ve bu da modelin aşırı öğrenmesini önlemek amacıyla daha iyi genelleştirme


yapmasına yardımcı olur. Daha sonra RNN-GCN modelinin mekansal bileşeni olan GCN katmanı, düğüm özelliklerinin bilgilerini işlerken komşu aktivite düğümlerinden gelen bilgileri toplar. GCN, düğüm özellikleri arasındaki mekansal bağımlılıkları yakalamak için bağlantı veri setindeki düğüm dizinlerini kullanarak grafik evrişim işlemlerini uygular. GCN katmanının çıktısı ReLU aktivasyon fonksiyonu ile etkinleştirilmiştir (Agarap, 2018). Son çıktıda, sınıflandırma olasılıklarını üretmek için softmax fonksiyonu uygulanmıştır. Kısaca RNN-GCN modeli, önce RNN katmanı aracılığıyla düğüm özelliklerinin sırasını işleyerek zamansal bağımlılıkları yakalar ardından GCN ile mekansal bilgi toplama işlemini uygular. Bu yapılandırma, RNN-GCN modelinin zamansal bağımlılıkları etkili bir şekilde öğrenmesine ve ardından mekansal bağımlılığın kullanmasına olanak tanır. Tersine, GCN-RNN modeli (Şekil 31b) bilgi toplamanın mekansal bileşenini önceliklendirir. Burada GCN katmanı ilk olarak komşu düğümlerden gelen özellikleri toplar ve mekansal bağımlılığı yakalar ardından zamansal bilgi işlemeyi RNN ile gerçekleştirir. Böylelikle, GCN-RNN modeli mekansal bağımlılıkları kullanarak zamansal bilgi işlemenin daha zengin bilgi barındıran düğüm özellikleri üzerinde gerçekleştirilmesine imkan tanır.

Bi-RNN kullanımının veri setindeki hem önceki inşaat ilerleme haftalarından (geçmiş) hem de sonraki haftalardan (gelecek) gelen bağımlılıkları bilmenin faydalı olduğu görevlerde tahmin performansını önemli ölçüde artırabildiği gösterilmiştir (M. Berglund vd., 2015). Bu doğrultuda bu çalışmada hem zamansal hem de mekansal bağımlılıkları ele almak için Bi-RNN'in GCN ile birleştirilmesinin etkinliği de araştırılmaktadır. Bu bağlamda, Bi-RNN-GCN konfigürasyonu önce zamansal bilgiyi çift yönlü olarak işleyip ardından mekansal bilgi toplama işlemini GCN ile gerçekleştirir. Aksine GCN-Bi-RNN konfigürasyonu, önce mekansal bilgiyi GCN ile derleyip ardından Bi-RNN kullanarak zamansal bilgiyi çift yönlü olarak işlemektedir. Hem Bi-RNN-GCN hem de GCN-Bi-RNN modellerinde, Bi-RNN katmanı hem geçmiş hem de gelecekteki haftalardan gelen zamansal bağımlılıkları yakalamaktadır.

2.4.6. AttGCRNN Modellerinin (RNN-GAT, GAT-RNN, Bi-RNN-GAT ve GAT-Bi-RNN) Yapılandırılması

Araştırmalar dikkat mekanizmasının girdi verilerinin en alakalı kısımlarına odaklanmasıyla model performansını iyileştirmede önemli bir rol oynadığını göstermiştir (Lee, 2022; F. Mostofi & Toğan, 2023b; J. Wang vd., 2022; Z. G. Zhou, 2022). Bu nedenle,

bu çalışmada da RNN ile GAT'in farklı birleştirme biçimlerinin dört konfigürasyon yapılandırması altında etkinliği değerlendirilmiştir. Yapılandırılan dört konfigürasyon şu şekildedir: RNN ardından GAT (RNN-GAT), GAT ardından RNN (GAT-RNN), çift yönlü RNN ardından GAT (Bi-RNN-GAT) ve GAT ardından çift yönlü RNN (GAT-Bi-RNN). Şekil 32 yapılandırılmış dikkat tabanlı mekansal-zamansal modellerin mimarisini detaylandırmaktadır.



Şekil 32. CPI ve SPI tahmini için yapılandırılmış (a) RNN-GAT ve (b) GAT-RNN modellerinin mimarisini.


Şekil 32a'da gösterildiği gibi yapılandırılmış modellerde, RNN önceki inşaat ilerleme haftalarından bilgi toplarken Bi-RNN geçmiş ve gelecekteki durumlardan zamansal

bağımlılıkları öğrenir. Entegre edilen GAT modeli her inşaat aktivitesini düğümünün çevresindeki farklı komşuların özelliklerini de dikkate alarak aktivitenin önemini dinamik olarak ağırlıklandırır. Bu entegrasyon, GCN'nin RNN'ye eklenmesinden daha karmaşık bir yapıya ve daha fazla katman sayısına neden olmaktadır. Çünkü GAT katmanları, dikkat skorları için ek hesaplamalar gerektirmektedir. Dikkat mekanizmalarıyla yapılandırılmış mekansal-zamansal modeller, modelin önemli mekansal bağımlılıkları yakalama yeteneğini artırmaktadır. Bu unsur RNN veya Bi-RNN'nin zamansal bilgi işlemeyle birleştirildiğinde hem grafik yapılı hem de sıralı verileri içeren inşaat ilerleme tahmin modelinin tahmin performansını artırması beklenilmektedir.

Avantajlarına rağmen, RNN modellerinin uzun vadeli bağımlılıkları öğrenme yeteneğini kısıtlayan kaybolan gradyan sorunu ile karşılaşabileceği belirtilmektedir (Eskandari vd., 2021). Çalışmanın sonraki bölümlerinde RNN'nin bu eksikliğini gidermek amacıyla gerçekleştirilen LSTM ve GRU modellerinin GCN ve GAT gibi mekansal modellerle birleştirilmesiyle elde edilen uzun diziler boyunca bilgiyi daha iyi koruyup güncelleyebilen mekanizmaların yapılandırılması araştırmalarına değinilmektedir.

2.4.7. GCNLSTM Modellerinin (LSTM-GCN, GCN-LSTM, Bi-LSTM-GCN ve GCN-Bi-LSTM) Yapılandırılması

Çalışmada sıralı verilerdeki uzun vadeli bağımlılıkları yakalamak için LSTM modellerini ile grafik yapılı verilerden özellikleri toplamak için GCN'leri birleştirmenin tahmin performansına olan etkisi de araştırılmıştır. Bu amaçla , dört model yapılandırılmış olup modeller sırası ile GCN-LSTM, GCN-Bi-LSTM, LSTM-GCN ve Bi-LSTM-GCN olarak isimlendirilmiştir. İlk iki model mekansal bağımlılıkları yakalamak için GCN katmanı üzerinden verileri işlemekte ardından LSTM ve Bi-LSTM katmanları ile zamansal bağımlılıkları modellemektedir. Bun karşılık, son iki model zamansal bağımlılıkları işlemek için önce LSTM ve Bi-LSTM katmanını kullanmakta ardından mekansal özellikleri entegre etmek için GCN katmanını kullanmaktadır. Modellerin birleştirilmesi hem zamansal hem de mekansal bağımlılıkların dinamik olarak öğrenilmesini sağlamaktadır. Şekil 33 LSTM ile GCN'yi birleştiren yapılandırılmış mekansal-zamansal modellerin mimarisini göstermektedir.



Şekil 33. CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GCN ve (b) GCN-LSTM modellerinin mimarisi.

Şekil 33a'da gösterildiği gibi LSTM-GCN modelinin giriş katmanı, inşaat aktivitelerini temsil eden düğüm özellikleri dizisini ve bağlantı bilgilerini alır. Giriş özellikleri bir dizi boyutu eklemek için yeniden şekillendirilir. Bu işlem, LSTM'in verileri (toplu, dizi, özellik) formatında beklemesi nedeniyle gerekli olmaktadır. Burada toplu boyutu aktivite düğümlerinin sayısını, dizi boyutu sıraların uzunluğunu (bu durumda her düğüm bir tek sıra olarak işlenir) son olarak da özellik boyutu özniteliklerin sayısını temsil etmektedir. Ardından LSTM katmanları, zamansal bağımlılıkları yakalamak için sıralı verileri işlemektedir. Her LSTM katmanında dönüştürülmüş giriş özellikleri, LSTM tarafından işlenilmekte ve zamansal desenler yakalanmaktadır. Daha sonra, LSTM çıktısının


bir sonraki Dropout katmanında kullanılabilmesi için dizi boyutu kaldırılır. Dropout katmanında bazı bilgi birimleri, aşırı öğrenmeyi önlemeye yardımcı olmak ve modelin genelleme yeteneklerini geliştirmek amacıyla rastgele sıfırlanmaktadır. Daha sonra çıktı düğüm özellikleri komşu düğümlerden mekansal bilgileri toplayan bir GCN katmanına geçirilmekte ve son olarak da sınıf olasılıklarını üretmek için log Softmax fonksiyonu uygulanmaktadır.

Buna karşılık GCN-LSTM modeli (Şekil 33b) düğüm özelliklerine öncelikle GCN modeli uygulayarak grafik konvolüsyonu aracılığıyla mekansal bağımlılıkları yakalar. Bu katman, her düğüm için geliştirilmiş özellik temsilleri üretmek komşu düğümlerden bilgileri toplar. GCN'in çıktısı, LSTM modelinin sıralı veriyi işleyebilmesi için bir dizi boyutu daha eklenerek yeniden şekillendirilir. LSTM katmanı, sıralı verileri işleyerek zamansal bağımlılıkları yakalar. LSTM'den sonra dizi boyutu kaldırılır ve aşırı öğrenmeyi önlemek amacıyla Dropout uygulanır. Son olarak tam bağlantılı bir katman, düğüm özelliklerini çıktı boyutuna eşler ve log Softmax uygulanarak sınıf olasılıkları üretilir.

Çalışmada yapılandırılan diğer iki Bi-LSTM-GCN ve GCN-Bi-LSTM modelleri yukarıda LSTM-GCN ve GCN-LSTM modelleri için detaylandırılan aynı işleyiş süreçlerine ve model mimarilerine sahiptir. Ancak Bi-LSTM-GCN ve GCN-Bi-LSTM modellerinde zamansal bağımlılıkları modellemek için LSTM yerine Bi-LSTM'i kullanılır.

2.4.8. AttGCNLSTM Modellerinin (LSTM-GAT, GAT-LSTM, Bi-LSTM-GAT ve GAT-Bi-LSTM) Yapılandırılması

RNN modellerinin uzun vadeli bağımlılıkları öğrenme yeteneğini kısıtlayan kaybolan gradyan sorununu (Eskandari vd., 2021) gidermek için çalışmada yapılandırılan ve performans incelemesi yapılan LTSM ve GAT tabanlı birleştirme konfigürasyonları LSTM-GAT, GAT-LSTM, Bi- LSTM-GAT ve GAT-Bi-LSTM'dır. Şekil 34 LSTM-GAT ve GAT-LSTM modellerinin katman yapılandırmasını detaylandırmaktadır.



Şekil 34. CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GAT ve (b) GAT-LSTM modellerinin mimarisi.


Şekil 34a'da gösterildiği gibi LSTM-GAT modeli, önce zamansal bağımlılıkları yakalamak için LSTM kullanarak sıralı verileri işler, ardından mekansal ilişkileri yakalamak için GAT katmanı ile grafik tabanlı öğrenme uygular. GAT katmanı önemli komşulara seçici odaklanmayı sağlayan dikkat mekanizmasını düğümler üzerinde uygular. GAT katmanından sonra ELU (Clevert vd., 2015) aktivasyonu aracılığıyla doğrusal olmayanlık tanıtılarak özellik temsili yeteneği artırılır. Daha sonra tam bağlantılı katman, dikkatle güçlendirilmiş özellikleri çıktı boyutlarına eşler ve log Softmax fonksiyonu ile CPI ve SPI sınıflarının çıktısı

olasılıkları hesaplanır. Diğer taraftan, GAT-LSTM modeli (Şekil 34b) öncelikle inşaat ilerleme kayıtlarını işler ardından aşırı öğrenmeyi azaltarak genelleme yeteneğini artırmak için Dropout mekanizmasını içeren dikkat mekanizmalarını uygular. GAT sonrası ELU aktivasyonu (Clevert vd., 2015) gerçekleştirilir. Ardından LSTM katmanı, GAT tarafından işlenmiş özelliklerden zamansal sıralı desenleri öğrenir. Tam bağlantılı katman ve Logaritmik Softmax fonksiyonu LSTM çıktısını nihai çıktı boyutlarına dönüştürür.

LSTM-GAT ve GAT-LSTM modellerine benzer şekilde, zamansal bağımlılıkları veriyi hem ileri hem de geri yönlerde işleyerek özellik çıkarımı yapabilen Bi-LSTM-GAT ve GAT-Bi-LSTM modelleri de bu çalışmada yapılandırılmıştır.

2.4.9. GCN-GRU Modellerinin (GRU-GCN, GCN-GRU, Bi-GRU-GCN ve GCN-Bi-GRU) Yapılandırılması

RNN ve LSTM tabanlı mekansal-zamansal modellere benzer şekilde bu tez çalışmasında, mekansal ilişkilerin (bir inşaat projesindeki görevler veya alt görevler arasındaki) ve zamansal dinamiklerin (zaman içinde ilerleme) daha verimli öğrenilmesini sağlayan GRU ile GCN'in birleştirilmesine dayanan yeni mekansal-zamansal modeller geliştirilmiştir. Şekil 35 yapılandırılmış GRU-GCN ve GCN-GRU modellerinin ayrıntılı yapısını sunmaktadır.




Şekil 35. CPI ve SPI tahmini için yapılandırılmış (a) GRU-GCN ve (b) GCN-GRU modellerinin mimarisi.

Şekil 35a GRU-GCN modelinin yapılandırılma sürecini detaylandırmaktadır. Bu model mekansal özellik toplaması için GCN uygulanmadan önce GRU'yu kullanarak sıralı desenleri öğrenir. Bu yapılandırmada, GRU katmanı sıralı veriyi (örneğin, haftalık ilerleme) işler ve zamansal özellikleri gizli bir durumda saklar. Ardından, GCN katmanı komşu düğümlerdeki bilgileri toplar bu sırada Dropout katmanı aşırı öğrenmeyi önlemek için eğitim sırasında GCN sonrası uygulanır. ReLU aktivasyonu (Agarap, 2018) daha iyi özellik temsili için GCN çıktısına doğrusal olmayan bir yapı kazandırma amaçlı gerçekleştirilir. Çıkış katmanında ise tam bağlantılı bir katman özellikleri çıktı sınıflarına veya tahminlere haritalar. Şekil 35b'de detaylandırılan GCN-GRU modelinin amacı, önce GCN aracılığıyla

düğüm özelliklerini mekansal bilgi ile zenginleştirmek ardından GRU kullanarak bu özellikler arasındaki zamansal etkileşimleri yakalamaktır. Bu amaçla, GCN katmanı düğüm özelliklerini komşu düğüm bilgileri ile bütünleştirir ardından GRU katmanı zamansal olarak zenginleştirilmiş özellikler dizisini analiz eder. Dropout katmanı özellik haritasından rastgele birimlerin çıkartılmasıyla aşırı öğrenmeyi azaltır. Çıkış katmanındaki tam bağlantılı katman ise zamansal olarak işlenmiş özellikleri nihai tahminlere dönüştürür. Ayrıca, mekansal toplama için GCN kullanılmadan önce ileri ve geri bağımlılıkları yakalamak için çift yönlü GRU'dan yararlanmak amacıyla Bi-GRU-GCN ve GCN-Bi-GRU modelleri de yapılandırılmıştır.

2.4.10. AttGCN-GRU Modellerinin Yapılandırılması (GRU-GAT, GAT-GRU, Bi-GRU-GAT ve GAT-Bi-GRU)

Bu tezde ayrıca, mekansal bileşende dikkat mekanizmasının ve zamansal bileşende geçitli mekanizmanın uygulandığı bir mekansal-zamansal modelde bu mekanizmaların birleşim etkisi de araştırılmıştır. Bu amaçla, kaybolan gradyan problemini ortadan kaldırabilen geçitli mekanizmaya sahip bir RNN olan GRU (Eskandari vd., 2021), GAT modeliyle birleştirilmiştir. İncelemesi gerçekleştirilen yapılandırılmış modeller GRU'dan sonra GAT (GRU-GAT), GAT'tan sonra GRU (GAT-GRU), Çift Yönlü GRU'dan sonra GAT (Bi-GRU-GAT) ve GAT'tan sonra Çift Yönlü GRU (GAT-Bi-GRU) olarak isimlendirilmiştir. Şekil 36 yapılandırılmış GRU-GAT ve GAT-GRU modellerinin mimarisini detaylandırmaktadır.




Şekil 36. CPI ve SPI tahmini için yapılandırılmış (a) GRU-GAT ve (b) GAT-GRU modellerinin mimarisi.

Yapılandırılmış mimarilerdeki GAT dikkat mekanizmasıyla birlikte modellere farklı komşuların önemini dinamik olarak değerlendirme imkanı sağlar (Veličković vd., 2018).

2.4.11. GatedGRNN Modellerinin (RNN-GatedGNN, GatedGNN-RNN) Yapılandırılması

Çalışmada RNN'nin GatedGNN ile birleştirilmesiyle elde edilen modellerinin incelemesi de gerçekleştirilmiştir. Bu birleşim konfigürasyonları ile hem zamansal hem de mekansal bağımlılıkların etkili bir şekilde yakalanılarak tahmin modelinin performansına olumlu yönde etki etmesi beklenmektedir. RNN katmanlarının kullanılması, ardışık

verilerdeki uzun vadeli bağımlılıkları yakalarken GatedGNN katmanları, geçit mekanizmalarını kullanarak özellik toplama sürecini geliştirirler. Şekil 37 yapılandırılmış RNN-GatedGNN ve GatedGNN-RNN modellerinin mimarisini detaylandırmaktadır.




Şekil 37. CPI ve SPI tahmini için yapılandırılmış (a) RNN-GatedGNN ve (b) GatedGNN-RNN modellerinin mimarisini.

Şekil 37'da gösterildiği gibi RNN-GatedGNN modelinin RNN bileşeni, önce girdi verilerini sıralı olarak işler. Ardından, sıra boyutunun çıkarılmasıyla elde edilen çıktı geçitli grafik evrişimi kullanarak komşulardan özellikleri toplayan bir GatedGNN katmanına gönderilir. Aşırı öğrenmeyi önlemek için bir Dropout katmanı ve ikinci bir tam bağlantılı katman kullanılarak model çıktısı hazırlanır. CPI veya SPI sınıfının olasılıklarını tahmin

etmek için bir Log Softmax fonksiyonu kullanılmıştır. Şekil 37b'de gösterilen RNN-GatedGNN modelinde, ilk olarak girdi verilerini işlemek için bir tam bağlantılı katman kullanılır ardından komşulardan özellik toplamak için GatedGNN katmanı kullanılır. Burada verilerin RNN katmanı aracılığıyla işlenmesi için bir sıra boyutu eklenir ve ardından aşırı öğrenmeyi önlemek amacıyla bir Dropout katmanı uygulanır. Model daha sonra tahmin çıktısını hazırlamak için ikinci bir tam bağlantılı katman ve Log Softmax aktivasyon fonksiyonu kullanır. Önerilen GatedGNN-RNN ve RNN-GatedGNN modellerinin PyTorch kullanılarak yazılan Python kodu detayları Ek 1 (Ek Şekil 2 ve 3'te) verilmektedir.

2.4.12. AttGatedGRNN Modellerinin (RNN-GatedGAT, GatedGAT-RNN) Yapılandırılması


Bir önceki bölümde değinildiği üzere hem zamansal hem de mekansal bağımlılıkların etkili bir şekilde yakalanarak tahmin modelinin performansına olumlu yönde etki etmesi beklenen diğer model birleşim konfigürasyonları RNN-GatedGAT ve GatedGAT-RNN'dir. Şekil 38 yapılandırılmış RNN-GatedGAT ve GatedGAT-RNN modellerinin katmanlarını göstermektedir.



Şekil 38. CPI ve SPI tahmini için yapılandırılmış (a) RNN-GatedGAT ve (b) GatedGAT-RNN modellerinin mimarisi.

2.4.13. GatedGNNLSTM Modellerinin (LSTM-GatedGNN, GatedGNN-LSTM) Yapılandırılması

LSTM ile GatedGNN'nin birleştirilmesi modelin hem geçitli evrişim hem de LSTM'in mekansal ve zamansal bilgi işlemedeki güçlü yönlerinden faydalanılmasını sağlar. GatedGNN grafik yapılandırılmış verilerden mekansal özelliklerin toplanmasını iyileştirirken LSTM'ler ardışık verilerde uzun vadeli bağımlılıkları yakalamada etkilidir. Şekil 39 bu çalışmada kullanılan GatedGNN-LSTM modellerinin mimarisini göstermektedir.




Şekil 39. CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GatedGNN ve (b) GatedGNN-LSTM modellerinin mimarisi.

Şekil 39'a göre LSTM-GatedGNN modeli, girdi verilerini işlemek için önce tam bağlantılı bir katman kullanır ardından GatedGNN katmanında geçitli evrişim mekanizmasıyla özellik toplama işlemini gerçekleştirir. Daha sonra veriler LSTM katmanı tarafından ardışık olarak işlenir. Dropout katmanı ayarlanmış Dropout oranına göre düğüm özelliklerini rastgele sıfırlar. Son olarak ,ikinci tam bağlantılı katman ve Log Softmax katmanı uygulanarak tahmin çıktısı hazırlanır.

2.4.14. AttGatedGNNLSTM Modellerinin (LSTM-GatedGAT, GatedGAT-LSTM) Yapılandırılması


Bu çalışmada, özellik toplama işleminden önce farklı komşuların önemini dinamik olarak değerlendirmede LSTM mekanizmalarıyla GAT'in geçitli yapısının birleşiminin sağlayabileceği performans etkinliği de değerlendirmiştir. Bu yapılandırma, zamansal ve mekansal boyutlarda hem uzun vadeli hafızayı hem de dikkatli işlem yeteneklerini kullanma imkanı tanımaktadır. Buna uygun olarak LSTM-GatedGAT ve GatedGAT-LSTM modelleri Şekil 40'ta ayrıntılı olarak gösterildiği şekilde yapılandırılmıştır.



Şekil 40. CPI ve SPI tahmini için yapılandırılmış (a) LSTM-GatedGAT ve (b) GatedGAT-LSTM modellerinin mimarisi.

2.4.15. GatedGNNGRU Modellerinin Yapılandırılması (GRU-GatedGNN, GatedGNN-GRU)

Çalışmanın bu bölümünde GRU ile GatedGNN'in birleşim kombinasyonu incelenmektedir. GRU zamanla ilgili verileri geçitli mekanizmalar aracılığıyla etkili bir şekilde işleyebilen olup zamansal boyutları ele almada uzmanlaşmıştır. GatedGNN ise mekansal bileşene odaklanmakta ve mekansal bilgileri seçici olarak işlemek için kendi geçitli mekanizmasını kullanmaktadır. Bu birleşim ile mimariye çift geçitli mekanizmaların dahil edilmesinin CPI ve SPI tahmin görevleri için mekansal ve zamansal bilgilerin yönetilmesinde belirgin bir avantaj sağlaması beklenmektedir. Şekil 41 yapılandırılmış GRU-GatedGNN ve GatedGNN-GRU modellerinin süreç prosedürleri gösterilmektedir.




Şekil 41. CPI ve SPI tahmininde yapılandırılmış (a) GRU-GatedGNN ve (b) GatedGNN-GRU modellerinin mimarisi.

Şekil 41a'da görüldüğü gibi GRU-GatedGNN modelinde GRU katmanı, unutma ve giriş kapılarını tek bir güncelleme kapısında birleştiren basitleştirilmiş LSTM mimarisi ile dizisel verilerdeki uzun vadeli bağımlılıkları yakalarken daha verimli hesaplama sağlar. Ardından tam bağlantılı katman veriler üzerinde doğrusal bir dönüşüm gerçekleştirir ve veriler, bağlanmış komşu düğümlerdeki inşaat aktivitesi özelliklerini toplamak için geçitli evrişim mekanizması uygulayan GatedGNN katmanına gönderilir. Veriler daha sonra Dropout katmanı ve ikinci tam bağlantılı katman aracılığıyla işlenir ve Log Softmax aktivasyonu ile tahmin sonucu hazırlanır. Öte yandan, GatedGNN-GRU konfigürasyonu (Şekil 41b) önce tam bağlantılı bir katman ve bir GCN katmanı aracılığıyla inşaat aktivitesi özelliklerini mekansal olarak işler. Veriler daha sonra GRU katmanından geçerek dizisel olarak işlenir ve ardından sırası ile Dropout, ikinci tam bağlantılı katman ve Log Softmax aktivasyonuna tabi tutularak her bir CPI veya SPI sınıfının olasılıkları üretilir. Önerilen GatedGNN-GRU ve GRU-GatedGNN modellerinin PyTorch kullanılarak yazılan Python kodu detayları Ek 1'da yer alan Ek Şekil 4 ve 5'te verilmektedir.

2.4.16. AttGatedGNNGRU Modellerinin Yapılandırılması (GRU-GatedGAT, GatedGAT-GRU)

Bu tez çalışmasında incelenen son mekansal-zamansal model konfigürasyonu GatedGNNGRU modelinde dikkat mekanizmasının uygulanmasıyla elde edilen GRU-GatedGAT ve GatedGAT-GRU modelleridir. Böylelikle, GRU'nun sahip olduğu zamansal geçit mekanizması ile GatedGAT'in sahip olduğu mekansal geçit ve dikkat mekanizmalarının hem mekansal hem de zamansal verilerin etkin bir şekilde işlenmesi için ideal bir yapılandırmanın elde edilmesi hedeflenmektedir. Modellerin konfigürasyon detayları Şekil 42'de gösterilmektedir.



Şekil 42. CPI ve SPI tahmininde yapılandırılmış (a) GRU-GatedGAT ve (b) GatedGAT-GRU modellerinin mimarisi.

GRU-GatedGAT modeli (Şekil 42a) verileri önce GRU katmanı aracılığıyla ardışık olarak işler ve ardından tam bağlantılı bir katman ile mekansal veriler GatedGAT katmanında işlenir. Dikkat mekanizması uygulanarak bağlı inşaat aktivitesi düğümlerinden bilgi toplanır. Dropout katmanı modelin genelleme yeteneğini artırmak için uygulanır. İkinci tam bağlantılı katman ve Log Softmax aktivasyonu uygulanarak model çıktısı elde edilir. GatedGAT-GRU modeli (Şekil 42b) öncelikle inşaat ilerleme aktivite kayıtlarının mekansal ilişkilendirmesini GatedGAT katmanı aracılığıyla gerçekleştirir. Ardından GRU katmanı ile dizisel işlem yapılır. GRU-GatedGAT modeline benzer şekilde, çıktı Dropout katmanı, ikinci tam bağlantılı katman ve Log Softmax aktivasyonu uygulanarak oluşturulur.

2.5. Performans Metriklerinin Entegrasyonu ve Değerlendirilmesi

Bu bölüm inşaat ilerleme tahminine yönelik olarak geliştirilen mekansal-zamansal ML modellerinin performans değerlendirmelerinin geliştirilen performans göstergeleri(metrikler) ışığında kapsamlı bir inceleme çerçevesi sunmaktadır. Bu çerçevede, çalışmada geliştirilen mekansal-zamansal modellerin CPI ve SPI ilerleme tahminine ilişkin öngörü yeteneklerinin ayrıntılı ve çok yönlü bir analizini sağlamak amacıyla inşa edilmiş olup yapılandırılan 36 adet mekansal-zamansal modelin karmaşık performans özelliklerini, dört farklı veri seti içinde 25 ayrı pencere (zaman dilimi) boyunca değerlendirmek üzere tasarlanmıştır. Çalışmada, tipik performans metrikleri (doğruluk, kesinlik, F1 skoru vd. gibi) kullanılarak gerçekleştirilen geleneksel performans ölçümü uygulamalarından farklı olarak 25 performans metriğinden oluşan bir performans göstergesi seti benimsenmiştir. İnşaat verilerinin kendine özgü yapılarına yönelik değerlendirme metriklerinin oluşturulması hayati önemdedir. Bu metrikler, modelleri çeşitli hata türlerine karşı doğrulamalı ve inşaat veri setlerinde sıklıkla karşılaşılan sınıf dengesizliği sorununu ele almalıdır. Farklı metriklerin ölçülmesi modellerin yalnızca istatistiksel olarak tutarlı değil aynı zamanda gerçek dünya koşullarında da uygulanabilir olmasını sağlayacaktır. Bu öngörüden hareketle çalışmada, inşaat proje yönetiminde yenilikçi bir yaklaşım sunularak bilgisayar bilimleri alanından etiket değiştirme (Label Flipping), özellik manipülasyonu (Feature Manipulation) ve veri zehirlenme (Data Poisoning) gibi siber saldırı simülasyonları da model performans değerlendirmelerinde göz önüne alınmıştır. Bu saldırılar, esas olarak siber güvenlikle ilgili olmasına rağmen inşaat projelerinde de verilerin elde edilme süreçleri, kaydedilmeleri ve saklanmaları dikkate alındığında, verilerin bu yönde manipüle edilmesinin mümkün olabileceği durumların olası olduğu görülmektedir. Dahası bu saldırılar, veri kalitesini bozacak kasıtlı ihlalleri veya istemsiz hataları da ifade etmektedir. Bu tür bozulmalara karşı dayanıklı modellerin geliştirilmesi model güvenilirliğinin sağlanması açısından önemli ölçüde katkıda bulunacaktır.

2.5.1. Doğruluk Değerlendirme Metrikleri

Model performansının değerlendirilmesi seçilen grafik sinir ağlar (GNN) modellerinin ve kıyaslama modellerinin inşaat ilerleme tahmin görevindeki başarılarının anlaşılması açısından hayati öneme sahiptir. Geliştirilen ML tabanlı tahmin modellerinin performans

değerlendirmesi için ölçülen ana değerlendirme metrikleri, doğruluk, kesinlik, geri çağırma (Recall), F1 skoru ve alıcı işletim karakteristiği eğrisi altındaki alan (Area Under the Receiver Operating Curve (AUC-ROC)) gibi çeşitli metriklerdir ve bu metrikler her modelin performansına ayrıntılı bir bakış sunmaktadır.

- Doğruluk (Accuracy): Bu metrik, model tahminlerinin genel doğruluğunu, tahmin edilen sınıflamaları (CPI için verimli/verimsiz, SPI için zamanında/gecikmiş) gerçek sonuçlarla karşılaştırarak ölçer (Chicco & Jurman, 2020). Metriğin matematiksel ifadesi Denklem (11)'de verilmektedir (Chicco & Jurman, 2020). Yüksek doğruluk puanı, modelin verimli ve verimsiz ile zamanında ve gecikmiş aktiviteleri etkili bir şekilde ayırt ettiğini gösterir. Metrik modelin genel performansını anlamak için faydalı olmakla birlikte, sınıfların oranlarının dengesiz olduğu veri setlerinde daha az bilgilendirici olabilir (Chicco & Jurman, 2020).

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (11)$$

Denklem (11)'de; doğru pozitif (True Positive, TP) CPI tahmin görevinde doğru tahmin edilen verimli etiketlerin veya SPI tahmin görevinde doğru tahmin edilen zamanında etiketlerin sayısını temsil eder. Doğru negatif (True Negative, TN) CPI görevinde doğru tahmin edilen verimsiz etiketlerin veya SPI görevinde doğru tahmin edilen gecikmiş etiketlerin sayısını ifade eder. Yanlış pozitif (False Positive, FP) yanlış tahmin edilen verimli veya zamanında etiketlerin sayısını gösterir. Yanlış negatif (False Negative, FN) yanlış tahmin edilen verimsiz veya gecikmiş etiketlerin sayısını belirtir.

- Kesinlik (Precision): Doğru tahmin edilen pozitif sınıfların oranını değerlendirir (örneğin, verimli CPI'yi 1 olarak tahmin etmek) ve tüm pozitif tahminler arasından doğru olanları ölçer (Chicco & Jurman, 2020; Hand vd., 2021). Yüksek kesinlik değeri, modelin verimlilik veya zamanında durumunu tahmin ettiğinde doğru olma olasılığının yüksek olduğunu gösterir. Metrik, modelin yanlış pozitif tahminlerinin yüksek olduğu durumlarda kritik öneme sahiptir. Bir diğer değişle, model pozitif bir sonuç tahmin ettiğinde, bu tahminin doğru olma ihtimalinin yüksek olması önemlidir (Chicco & Jurman, 2020; Hand vd., 2021).

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (12)$$

- Geri Çağırma (Recall): Aynı zamanda duyarlılık olarak da bilinen bu metrik, modelin tüm gerçek pozitif vakaları doğru bir şekilde tanıma yeteneğini değerlendirir (Chicco & Jurman, 2020; Hand vd., 2021). Yüksek geri çağırma değeri (bakınız Denklem (13)), modelin çoğu verimli veya zamanında aktiviteyi yakalamada başarılı olduğunu gösterir. Metriğin değerlendirilmesi, özellikle pozitif örneklerin mümkün olduğunca fazla tespit edilmesinin önemli olduğu senaryolarda önem taşımaktadır (Chicco & Jurman, 2020; Hand vd., 2021).

$$\text{Geri çağırma} = \frac{TP}{TP + FN} \quad (13)$$

- F1 Skoru (F1 Score): Kesinlik ve geri çağırma metriklerinin tek bir metrikte birleştirilmesiyle modelin tahmin performansının dengeli bir ölçüsünü sunar (Denklem (14), (Chicco & Jurman, 2020; Hand vd., 2021). Metrik, özellikle veri setinde verimli ve verimsiz aktiviteler veya zamanında ve gecikmiş aktiviteler arasında bir dengesizlik olduğunda değerlendirilmesi önem arz etmektedir. F1 skoru, sınıf dağılımının dengesiz olduğu durumlarda doğruluktan daha kapsamlı bir performans ölçüsü sunar (Chicco & Jurman, 2020; Hand vd., 2021).

$$\text{F1 Skoru} = 2 \times \frac{(\text{Kesinlik} \times \text{Geri çağırma})}{(\text{Kesinlik} + \text{Geri çağırma})} \quad (14)$$

- Özgüllük (Specificity): Doğru tespit edilen gerçek negatiflerin oranını ölçmekte ve Denklem (15) aracılığıyla hesaplanmaktadır. Modelin, tüm negatif örnekleri ne kadar iyi bulabildiğini gösterir (Hand vd., 2021).

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (15)$$

- AUC-ROC: AUC bir modelin rastgele seçilen bir pozitif örneği rastgele seçilen bir negatif örneğe göre daha yüksek sıralamada yerleştirme olasılığını temsil eder. ROC ise eğrisi altındaki alan pozitif ve negatif vakalar arasındaki ayrımı değerlendirir (Hanley &

McNeil, 1982) ve 0,5 ile 1,0 arasında değişen bir skaler değerle ikili sınıflandırıcıların genel performansını yansıtır (Melo, 2013). AUC, ROC eğrisi altındaki yamuk alanların toplanmasıyla hesaplanır; daha yüksek bir AUC değeri, modelin daha iyi performans gösterdiğini işaret eder (Melo, 2013). İki'den fazla sınıf içeren durumlar için, AUC değeri sınıfların ikili karşılaştırmalarının ortalaması alınarak genelleştirilebilir (Hand & Till, 2001). AUC-ROC modelin tüm olası sınıflandırma eşiklerinde performansını özetleyen tek bir skor olarak, doğru pozitif oranı (duyarlılık) ile yanlış pozitif oranı (özgüllük) arasındaki dengenin göstergesidir. Bir modelin yüksek bir AUC değeri elde etmesi karar eşiği değişse bile doğru sınıfı belirleme konusunda yetkin olduğunu gösterir.

Yukarıda detaylandırılan metrik dizisi, modellerin tahmin doğruluğunun ötesine geçerek modellerin doğru pozitifleri tanımlama konusundaki kesinliklerini, tüm ilgili vakaları tespit etme yeteneklerini (geri çağırma) ve kesinlik ile geri çağırma arasındaki dengeyi (F1 skoru) değerlendirmektedir. Bu metrikler, geliştirilen mekansal-zamansal modellerin farklı senaryolar ve veri setleri arasında tutarlı tahmin performansı ile hem doğru hem de güvenilir olma göstergelerini sunmak amacıyla bu çalışmada da benimsenmiştir. Böylelikle, çalışmada geliştirilen hangi modellerin inşaat yönetimi içinde belirli tahmin görevlerine en uygun olduğunun açıkça anlaşılması sağlanır. Öte yandan, belirli modellerin eksik kaldığı alanları gösterilerek bu modellerin daha da geliştirilmesi ve iyileştirilmesi için izlenecek değerli içgörüler sunar.

2.5.2. Siber Saldırı Değerlendirme Metrikleri

İnşaat sektörünün dijitalleşmesi sektördeki çeşitli süreçlerin haritalanması, izlenmesi ve kontrol edilmesini dijital araçlar aracılığıyla mümkün kılarak inşaat süreçleri ile zamanlamaların optimize edilmesine imkan sağlamaktadır (L. Zhang, Li, vd, 2024). Ancak, inşaat sektörünün dijitalleşmeye olan ilgisi arttıkça siber saldırı riski de artırmaktadır (Mantha & García de Soto, 2021; D. Yao & García de Soto, 2024). Akıllı inşaat çözümleri için genel bir çözüm olarak önerilen ML modelleri (L. Zhang, Li, vd., 2024), güvenlik ve gizlilik sorunlarına karşı savunmasız kalmaktadır (B. Zhang vd., 2023). Bu tehditler, yanlış tahminlere ve hatalı karar verme süreçlerine yol açarak proje zaman çizelgeleri, maliyetler ve güvenlik üzerinde ciddi sonuçlar doğurabilir. Bunun yansıması olarak da proje paydaşlarının olumsuz yönde etkilendiği ciddi sonuçlar görülebilir. Dijitalleşmenin

hızlanması siber güvenlik bileşenleri gibi sistemlerin manipülasyonunu önlemek için dayanıklı ML modellerine olan ihtiyacı artırmaktadır (Aladağ vd., 2019).

ML modelinin sağlamlığı, onun özellikle saldırıların tarafından tasarlanan bozulmalar karşısında, giriş verilerindeki kötü niyetli değişiklikler veya gürültülü kesintilere rağmen doğru ve öngörülebilir bir şekilde çalışabilme yeteneğini ifade eder (H. Zhang vd., 2024). Çekişmeli saldırılara ve veri zehirlenmeye karşı ML'deki sağlamlık, birçok alanda kapsamlı bir şekilde incelenmiştir. Aladağ vd. (2019) MNIST veri seti üzerinde yapılan veri zehirlenme saldırılarına karşı ML modellerinin savunmasızlığını vurgulamış ve model sağlamlığını artıran Otomatik Kodlayıcı (Autoencoder) gibi üretici bir model kullanarak yeni bir savunma mekanizması önermiştir. Bu yöndeki çalışmalar, karmaşık ve birbirine bağlı veri yapılarıyla çalışan modellerin sağlamlığını sağlamadaki zorlukları öne çıkarmaktadır.

Çekişmeli saldırı eğitim verilerinin kasıtlı olarak bozulmasını içerir (L. Zhang vd., 2024) ve bu durum yüksek olasılıkla ML modellerinin yanlış sınıflandırma yapmasına yol açar (Balda vd., 2019). Çekişmeli örnekler, insanlar tarafından fark edilmeyen kötü niyetli kayıtlardır ve tahmin modellerinin eğitim girdisini değiştirmek için kullanılır (Papernot vd., 2017). Örneğin, inşaat ilerleme raporlarında yapılacak küçük değişiklikler, bir ML modelinin proje zaman çizelgelerini ve maliyetlerini yanlış tahmin etmesine neden olarak gecikmelere ve mali kayıplara yol açabilir. Sinir ağları üzerine yapılan araştırmalar, eğitim girdisi kasıtlı olarak bozulmuş çekişmeli kayıtlar içeren modellerin çekişmeli örnekleri tutarlı bir şekilde yanlış sınıflandırdığını göstermiş ve bu savunmasızlığın başlıca nedeninin doğrusal doğası olduğunu vurgulamıştır (Goodfellow vd., 2014). Diğer ML yöntemleri ile karşılaştırıldığında, derin öğrenme yaklaşımları hesaplama açısından verimli eğitim modelleri sunarlar ancak eğitim girdisi kasıtlı saldırılarla bozulduğunda, bu modellerin de çekişmeli örneklerle karşı savunmasız olduğunu gösterilmiştir (Papernot vd., 2016).

Bu çalışmada, çeşitli inşaat ilerleme senaryoları ve farklı zaman dilimlerinden elde edilen hem grafik yapılı hem de grafik yapısız veri kümeleri kullanılarak simüle edilen çekişmeli koşullar altında ML modellerinin performans sağlamlığı da değerlendirilmiştir. Bu değerlendirmedeki amaç sistematik bozulma ve model tepkilerinin analizi ile savunmasızlıkların belirlenmesidir. Bu maksatla, çalışmada geliştirilen modellerin sağlamlıklarının testi için çekişmeli saldırılar (FGSM) ve zehirlenme saldırıları (etiket değiştirme, rastgele etiket atama, özellik manipülasyonu) dikkate alınmıştır.

- Hızlı Gradyan İşareti Yöntemi (FGSM): FGSM mekansal-zamansal inşaat ilerleme tahmin modellerinin performans dayanıklılığını test etmek için kullanılan bir çekişmeli

saldırı tekniğidir. Bu yöntem girdi verilerine dikkatlice hesaplanmış bozulmaların gradyan yönünde eklenmesiyle gerçekleştirilir (Naqvi vd., 2023). FGSM ile ilgili yapılan geniş kapsamlı araştırmalar, genellikle görüntü verileri üzerinde yoğunlaşmış olmakla birlikte tablo verilerinin de benzer şekilde çekişmeli saldırılara karşı savunmasız olduğu belirtilmiştir (H. Xia vd., 2024; Cartella vd., 2021). Çalışmada kullanılan FGSM aşağıda ayrıntılı olarak verilen adımları içerir:

- **Model Kullanımı ve Kayıp Fonksiyonu:** Model, orijinal giriş verileri ile beslenir ve çıktılar, tahmin edilen sonuçlar ile gerçek etiket arasındaki farkı ölçen kayıp fonksiyonu için kullanılır (J. Xu vd., 2019). FGSM, kayıp fonksiyonu olarak negatif logaritmik olabilirlik fonksiyonunu kullanır. Yüksek kayıp, modelin verilen girdi üzerinde daha kötü performans gösterdiğini işaret eder.
- **Gradyan Hesaplaması:** Kayıp fonksiyonunun model parametrelerine ve giriş verilerine göre gradyanları hesaplanır. Bu gradyanlar, kayıp fonksiyonunun giriş veri elemanlarına göre ne kadar arttığını gösterir ve hangi özelliklerin kayıptaki artışı en üst düzeye çıkarmak için ne ölçüde değiştirilmesi gerektiğini belirler.
- **Gradyan Hesaplamasının İzlenmesi:** Çekişmeli bozulmanın kayıp fonksiyonunun giriş verilerine göre elde edilen gradyanına bağlı olduğu dikkate alınarak giriş özellikleri için gradyanlar takip edilir.
- **Çekişmeli Örneklerin Üretilmesi:** Kayıp fonksiyonunun giriş özelliklerine göre gradyanlarının işareti çıkarılır. Her özellik için en kötü durum bozulmasının yönünü belirlemek amacıyla işaret fonksiyonu kullanılır.
- **Gradyanın İşareti:** İşaret fonksiyonu, giriş verilerinin gradyanlarına uygulanır ve gradyanın işaretine bağlı olarak -1, 0 veya 1 olarak geri dönülür. Bu işlem, giriş verilerinin her bir elemanının kaybı en üst düzeye çıkarmak için hangi yönde bozulması gerektiğini tanımlar. Gradyanın büyüklüğü yerine işaretini kullanmak bozulmanın küçük fakat etkili olmasını sağlar ve mümkünse girdiyi karar sınırının ötesine iteler.
- **Bozulma Hesaplaması:** Gradyanın hesaplanan işareti bozulmanın büyüklüğünü kontrol eden küçük bir skaler ϵ ile çarpılır. FGSM saldırısının başarısı kullanılan bozulmaların neredeyse fark edilemeyecek kadar küçük olmasını sağlarken çekişmeli saldırıların karakteristik özelliğini ortaya koyar (Naqvi vd., 2023).
- **Çekişmeli Örneklerin Yaratılması:** Daha sonra bozulma orijinal giriş verilerine eklenir. Sonuç olarak, kaybı en üst düzeye çıkaran ve potansiyel olarak modelin

yanlış tahminler yapmasına yol açan hafifçe değiştirilmiş yeni bir giriş verisi seti elde edilir. Böylelikle, eklenen bozulmayla orijinal girdilere minimal fakat stratejik bir şekilde uygulanarak modelin yanlış tahminler yapması sağlanır.

- Yeniden Değerlendirme: Çekişmeli veriler üretildikten sonra model bu bozulmuş giriş verilerini kullanarak yeniden değerlendirir. FGSM saldırısının etkinliği, modelin performans metriklerinin (doğruluk, F1 skoru, kesinlik, geri çağırma ve AUC) orijinal (bozulmamış) verilere göre ne kadar bozulduğuna bakılarak ölçülür. Bu yeniden değerlendirme, modelin bu tür çekişmeli saldırılara karşı savunmasızlığını ortaya koyar.
- Veri Zehirleme: Çekişmeli saldırının bir alt kümesi olan veri zehirleme, tahmin modelinin eğitiminden önce giriş setine kötü niyetli verilerin eklenmesini içerir (Jagielski vd., 2018). Güvenilir ve güvensiz kaynaklardan veri toplamak, saldırganların eğitim veri setini zehirleyerek ML modelinin performansının bozulmasına olanak sağlar (Paudice vd., 2018). Eğitim verilerinin küçük bir bölümünü manipüle ederek (Y. Wang & Chaudhuri, 2018) saldırgan, eğitilmiş ML modelinin istenen etiketleri (örneğin, spam e-postaların yanlış sınıflandırılması gibi) tahmin etme davranışını kontrol etmeyi amaçlar (Ma vd., 2020). Literatürdeki çalışmalarla benzer şekilde (Aryal vd., 2023; N. Cheng vd., 2021), bu çalışmada da veri zehirleme yöntemleri kullanılarak verilerin %10'u zehirlenmiştir. Verinin bu oranda bile kötü niyetli katılımcılar tarafından manipüle edilmesi modelin tahmin doğruluğunu büyük ölçüde düşürebilir (Gajbhiye vd., 2023).
- Etiket Değiştirme: Veri zehirlenmesinin zararlı bir türüdür (N. Cheng vd., 2021) ve bu yöntemde veri kümesindeki etiketlerin belirli bir yüzdesi kasıtlı olarak ters sınıfa çevrilir (Paudice vd., 2018). Etiket değiştirme saldırısında, saldırganlar GNN modellerinin sınırlı sayıda eğitim düğümünün etiketlerini değiştirirler (M. Zhang vd., 2020). Bu durum ML modelinin sınıflandırma performansının düşmesine neden olabilir (Li vd., 2023; Paudice vd., 2018). Aşağıda, bu çalışmada etiket değiştirme yöntemi kullanılarak veri setinin nasıl zehirlendiği detaylandırılmaktadır.
 - Yüzde ve Seçim: Yüzde, saldırının gücünü belirleyen bir ölçüttür ve veri kümesindeki toplam etiketlerin hangi kısmının tersine çevrileceğini gösterir (Chan vd., 2021). Etiketleri çevrilecek olan düğümlerin indeksleri rastgele seçilmiştir.
 - Çevirme Süreci: Etiketlerin çevrilmesi, özellikle ikili sınıflandırmayı hedef alarak mod işlemi aracılığıyla 0 olan bir etiketi 1'e, 1 olan bir etiketi de 0'a çevirir.

- Veriyi Yeniden Yapılandırma: Etiketler çevrildikten sonra manipüle edilmiş etiketler, orijinal özellikler ve grafik yapısıyla yeni veriler oluşturulur. Bu zehirlenmiş veri kümesi daha sonra modelin farklı doğruluk metrikleri üzerindeki performansını değerlendirmek için kullanılır.
- Rastgele Etiket Ataması: Rastgele etiket ataması (rastgele etiket değişikliği / rastgele etiket gürültüsü), etiket değiştirmeye kıyasla olası etiketler kümesine tamamen yeni etiketlerin rastgele atanması nedeniyle daha yüksek düzeyde belirsizlik sunar. Bu yöntem, modelin aşırı bozulmuş etiket bilgilerine karşı dayanıklılığını değerlendirir. Aşağıda, bu çalışmada takip edilen rastgele etiket ataması yönteminin adımları verilmektedir.
 - Etiket Seçimi: Etiket değiştirme gibi etiketlerin belirli bir yüzdesi (10%) yeniden atama için hedef alınır (Shanthini vd., 2019). Yeni etiketler veri kümesinde bulunan benzersiz etiketlerden rastgele seçilir ve bunların ait olduğu sınıfların gerçek dağılımlarından türetildiği kabul edilir.
 - Yeniden Atama Süreci: Seçilen indekslerdeki etiketler bu yeni seçilmiş etiketlerle değiştirilir.
- Özellik Manipülasyonu: Özellik manipülasyonu, gürültü ekleyerek belirli bir düğümün alt kümesinin giriş özelliklerini doğrudan değiştirir (Mivule, 2013). Bu değişim, giriş verilerinin gürültülü veya eksik olabileceği senaryoları simüle ederek modelin bozulmuş girdileri doğru şekilde yorumlama yeteneğini zorlar. Aşağıda, bu çalışmada takip edilen özellik manipülasyonu yönteminin adımları verilmektedir.
 - Gürültü Ekleme: Bir gürültü seviyesi belirlenerek hangi düğümlerin özelliklerinin manipüle edileceğini belirlemek için benzer bir seçim süreci kullanılır. Rastgele gürültü (10%) oluşturularak belirlenen gürültü seviyesi ile ölçeklendirilir. Sonrasında, gürültü seçilen düğümlerin orijinal özelliklerine eklenilir.
 - Veri Yeniden Yapılandırma: Gürültü içeren yeni özellikler orijinal özelliklerin yerini alırken orijinal etiketler ve grafik yapısı korunur.

Bu çalışmada kullanılan her bir sağlamlık metriği, yapılandırılan mekansal-zamansal modellerin performansına farklı bir bakış açısı sunmaktadır. Her saldırı türü, modelin ve eğitim verilerinin farklı yönlerini zorlayarak potansiyel zayıf noktaların ve güçlü yanların gözlenilmesini sağlar.

FGSM kasıtlı olarak hazırlanmış çeşitli örneklerle karşı modelin savunmasını test eder ve saldırganların belirli hatalar oluşturmak için model eğitimindeki zayıflıkları nasıl

kullanabileceğini gösterir. Veri zehirlenme saldırısında olduğu gibi etiket değiştirilmede de modelin yanlış etiketlere olan hassasiyeti doğrudan değerlendirir. Etiket değiştirme durumu karşısında yüksek performans metrikleri (doğruluk ve F1 skoru gibi) gösteren bir model, etiket gürültüsüne karşı da güçlü bir dayanıklılığa sahip olduğunu gösterir. Bu durum, manuel veri etiketleme hatalarının meydana gelebileceği ortamlarda güvenilir tahminlerin elde edilmesinde kritik önem taşır. İnşaat projelerinde manuel veri girişi, insan hatası veya verinin yanlış yorumlanması nedeniyle yanlış etiketlemelere rastlanılabilmektedir (Byrne vd., 2013). Etiket değiştirme bu hataları taklit eder ve bu tür hataların modelin operasyonel kullanımı üzerindeki etkisini gösterir. Rastgele etiket atama, yapılandırılmış mekansal-zamansal modellerin etiket verilerindeki tamamen rastgele gürültüye karşı hassasiyetini daha etkin bir şekilde ölçer. Böyle bir durum altında yapılan değerlendirme, modelin anlamsız veya oldukça tutarsız verileri filtreleme yeteneğini ortaya çıkarır. Bu durum, etiket bütünlüğünün tehlikeye girebileceği uygulamalarda önem arz etmektedir. Böyle bir durumda rastgele etiket atama, tamamen yanlış veya bozulmuş etiketlerin veri setinde bulunmasının etkisi bu yolla simüle edilebilir. Özellik manipülasyonu saldırısı modelin girdi verilerinin bozulmasına ne kadar dayanıklı olduğunu özelliklere gürültü ekleyerek test eder. Gürültü veya eksik veri üzerinde iyi genelleme yapma yeteneğine sahip sağlam bir mekansal-zamansal inşaat ilerleme performansı tahmin modeli, bu tür saldırılara karşı direnç gösterir. Uzaktan algılama veya inşaat alanında veri toplama gibi pratik uygulamalarda, cihaz arızaları veya dış çevresel faktörler nedeniyle zaman zaman hatalı, eksik veya gürültülü veri üretilebilir (Byrne vd., 2013). Özellik manipülasyonu, bu tür veri toplama hatalarını taklit edebilir ve bu tür sorunların modelin doğruluğunu nasıl etkileyebileceğini değerlendirmek için bir öngörü sağlar.

2.6. Mekansal-Zamansal Modellerin Eğitimi, Değerlendirilmesi ve Seçimi

2.6.1. Parametre Başlatma ve Model Eğitimi

Farklı model yapılandırmalarını hızlı bir şekilde test etmek için eğitimin ilk aşaması, kısa dönemlerle (5 ila 50 epoch) deneme yanılma yaklaşımıyla başlamıştır. Toplamda 36 mekansal-zamansal model değerlendirilmiş ve her biri veri setlerinde 25 farklı pencere

üzerinde test edilmiştir. Tablo 4 bu çalışmada geliştirilen mekansal-zamansal CPI ve SPI tahmin modellerinin yapılandırması için ayarlanan parametreleri detaylandırmaktadır.

Tablo 4. Yapılandırılmış mekansal-zamansal modellerin eğitim parametreleri.

Bileşen	Açıklama	Parametre	Detaylar
Katmanlar	Model mimarisindeki katman sayısı	Katman sayısı	RNN, LSTM, GRU konfigürasyonları genellikle çoklu katmanları içerir
Girdi katmanı	İlk grafik evrişimsel katman	Girdi boyutu	Girdi özelliklerinin boyutu
Çıktı katmanı	İkinci grafik evrişimsel katman	Çıktı boyutu	Çıktı özelliklerinin boyutu
		Gizli boyut	Gizli katman özelliklerinin boyutu. İkinci katmana giden girdi özelliklerinin boyutu
ReLU aktivasyonu	İlk grafik evrişim katmanından sonraki aktivasyon fonksiyonu	-	İlk evrişimden sonra ReLU uygulanır
Dropout	Düzenleme katmanı	Dropout oranı	Girdiyi sıfıra ayarlama olasılığı
Optimizatör	Modeli optimize eder	Öğrenme oranı Ağırlık bozulması	Adam optimizasyonu için öğrenme oranı Düzenleme için ağırlık bozulması
Kayıp fonksiyonu	Modelin hatasını hesaplamak için kullanılan fonksiyon		
Yayılan adımlar	GatedGNN'deki mekansal-zamansal veri yayılımı adımları	Adım sayısı (K)	GatedGNN'de etkili veri yayılımı için ayarlanmıştır
Dikkat mekanizması	Modelin veri bağımlılıklarına duyarlılığını artıran mekanizmalar	Paralel dikkat mekanizması sayısı	
Eğitim	Eğitim iterasyonlarını yönetir	Epoch Sabır Parti boyutu	Toplam eğitim epoch sayısı Erken durdurma için sabır Her partideki örnek sayısı

Bu modellerin her biri, farklı proje aşamaları için hem CPI hem de SPI tahmini yapmakta kullanılacak olduğundan toplam hesaplama yükü 200'den fazla benzersiz ML modelinin eğitilmesini gerektirmiştir. Sınırlı sayıda epoch kullanılmasına rağmen değerlendirilen kombinasyonların çokluğu nedeniyle hesaplama çabası bakımından oldukça yoğun hesaplamalar gerekmiştir. Gerçekleştirilen denemeler, GatedGNN içeren modellerin diğer mimarilere göre daha iyi performans gösterdiğini ortaya koyarak bu model ailesine yönelik ince ayar çalışmalarına odaklanılması gerektiği sonucuna varılmasına yol açmıştır.

GatedGNN mimarisi en umut verici model mimarisi olarak belirlendikten sonra, bu aileye ait modellerin tam olarak yakınsaması için 100 ila 500 epoch arasında daha uzun eğitim dönemleri uygulanmıştır. Bu uzun eğitim döngüleri, parametrelerde daha ayrıntılı ayarlamalar yapılmasına olanak tanımıştır. Modeller, gizli boyutların (8, 16, 32, 64, 128), Dropout oranlarının (%0,3 ila %0,9) ve GatedGNN mimarisine eklenen RNN katmanlarının

(1, 2, 3) çeşitli yapılandırmaları ile optimize edilmiştir. Model eğitimi Cross-Entropy kayıp fonksiyonu ve Adam (Kingma & Ba, 2014) optimizasyonu ile yönlendirilmiş, 0.01, 0.001 öğrenme oranı ve 0,0005 ağırlık bozulması parametreleri kullanılmıştır. Model, test veri seti üzerinde 32, 64, 128 parti boyutları ile 500 epoch boyunca eğitilmiş ve erken yakınsama durumunda eğitimi durdurmak için 20 sabır kullanılmıştır. Aşırı öğrenmeyi önlemek için eğitim, doğrulama kaybı izlenerek daha da kontrol edilmiştir.


İnşaat veri setlerindeki önemli sınıf dengesizliği göz önüne alındığında — verimli CPI ve gecikmiş SPI etiketleri baskın durumda olduğundan — sadece doğruluk yeterli bir performans ölçütü olarak değerlendirilmemiştir. Bunun yerine F1 skoru birincil değerlendirme ölçütü olarak kullanılmıştır. Çünkü bu metrik az temsil edilen sınıflar için hem hassasiyet hem de geri çağırma değerlerini dikkate alarak dengesizliği daha iyi yansıtmaktadır (Hand Vd., 2021).

Başlangıç değerlendirme aşamasından sonra en yüksek F1 skoruna ulaşan en başarılı GatedGNN modeliyle tüm 36 mekansal-zamansal ML yapılandırması boyunca daha fazla eğitim ve değerlendirme gerçekleştirilmiştir. Modeller 500 epoch boyunca eğitilmiş ve sabır parametresi olarak 25 değeri dikkate alınmıştır. Bu değerler, doğrulama kaybında bir iyileşme gözlemlenmediği takdirde eğitimin erken durdurulmasını sağlayarak hesaplama kaynaklarının optimize edilmesine imkan tanımıştır. Modellerin dikkat mekanizmaları içermesi durumunda, modellerin zamansal ve mekansal bağımlılıklara olan duyarlılığını artırmak için paralel dikkat mekanizmaları kullanılmıştır. Bu mekanizmalar proje zaman çizelgesinin farklı noktalarındaki aktiviteler arasındaki karmaşık etkileşimleri yakalamada etkili olmuştur. RNN, LSTM ve GRU tabanlı mimarilerde katman sayısı ve GatedGNN'deki adım sayısı (K) iki olarak ayarlanmıştır. Bu yapılandırma modellerin hem mekansal hem de zamansal boyutlar arasında bilgiyi etkin bir şekilde yaymasını sağlamış aynı zamanda derin yinelemeli mimarilerde meydana gelebilecek kaybolan gradyan problemi gibi sorunları hafifletmiştir.

2.6.2. Mekansal-Zamansal Modellerin Değerlendirilmesi

Bu tez çalışmasının yöntem bölümü, CPI ve SPI tahmini için en güvenilir mekansal-zamansal modelleri yapılandırarak onların performans değerlendirmesini gerçekleştirmek amacıyla biçimlendirilmiştir. Bu biçimlerdeki ana unsur, model yapılandırmada farklı mekanizmaları sistematik olarak gerçekleştirerek bunlardan en iyi performansı


sergileyenlerin tespiti için kutu grafik analizi aracılığıyla ayrıntılı performans değerlendirmelerini yapmaktır. Ek 2’de (Ek Tablolar 1 ve 2) Adana, Bursa, Elazığ ve Yozgat’taki dört farklı projede yapılandırılan mekansal-zamansal modellerin farklı pencereler boyunca CPI ve SPI tahminleri için sergiledikleri en yüksek doğruluk performans detayları sunulmaktadır. Şekil 43’te Adana projesindeki farklı döngüsel pencereler boyunca geliştirilen mekansal-zamansal modellerin CPI tahmin doğruluğu performanslarını gösterilmektedir.



Şekil 43. Adana veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.

Şekil 43 Adana veri setinin için dikkate alınan altı pencere boyunca modellerin performanslarını sunarken aynı zamanda modellerin doğruluk seviyelerinin tutarlılığını da ortaya koymaktadır. Modellerin özellikle, Pencere 1 ve 2'deki performans göstergeleri oldukça tatmin edici olup bu durum, modellerin tam veri setlerinden yararlanarak daha doğru tahminler yapabilmesine olanak tanımıştır. Bi-RNN-GAT ve GRU-GeçitliGNN (GRU-GatedGNN) modelleri yüksek doğruluklarıyla öne çıkmaktadır. Ancak, Pencere 3'ten itibaren, doğrulukta belirgin bir düşüş gözlenmiştir. Bu durum, eğitim ve doğrulama veri setleri arasındaki 15 haftalık aralığa atfedilebilir; bu da muhtemelen modellerin verilerden etkili bir şekilde öğrenme yeteneğini bozmuştur. Bozulma, Pencere 4'ten 6'ya kadar devam etmiş ve verilerdeki boşluklar, modellerin performansını daha da zayıflatmıştır. Bu eğilim, modellerin eksik veri dizileriyle karşılaştıklarında tahmin yeteneklerinde kritik bir zafiyeti vurgulamakta olup, model iyileştirilmesi için gerçekleştirilecek potansiyel uğraş alanını işaret etmektedir.


Şekil 44 Adana projesinde farklı döngüsel pencerelerde mekansal-zamansal modellerin SPI tahminindeki doğruluk performansını göstermektedir. CPI tahminlerinde olduğu gibi, ilk pencereler daha yüksek performans seviyeleri göstermiş; GatedGNN ve RNN-GatedGAT gibi modeller tam veri koşulları altında son derece başarılı performans sergilemiştir. Ancak, SPI tahmin performansı daha sonraki pencerelerde keskin bir şekilde düşmüştür. Uzun veri boşlukları, modellerin (sanırım SPI) tahminlerini doğru bir şekilde öngörme yeteneklerini önemli ölçüde etkilemiş ve bu da modellerin eksik veya tutarsız veri bulunan gerçek dünya senaryolarında uygulanmasında ciddi bir zorluk oluşturmıştır.



Şekil 44. Adana veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları.

Bursa projesi veri seti için mekansal-zamansal modellerin sekiz döngüsel pencerede CPI tahmin doğruluğu Şekil 45'te gösterilmektedir. Burada, daha koyu tonlar daha yüksek doğruluğu ifade etmektedir. GatedGNN-RNN ve RNN-GatedGNN modelleri, 3. pencerede en iyi performansı sergileyerek 0,9'a yakın bir doğruluk elde etmiştir., Ancak 1. pencerede, özellikle GRU-GatedGNN modeli daha düşük performans göstererek yaklaşık 0,88 seviyelerinde kalmıştır. İlk pencerelerdeki bazı tutarsızlıklara rağmen, Bursa projesi verileri


için geliştirilen modeller genel olarak farklı aşamalarda tutarlı bir doğruluk sergilemiştir. Özellikle, geçitli mekanizmalara sahip modeller CPI tahmininde diğerlerinden sürekli olarak daha iyi performans göstererek zamansal ve mekansal bağımlılıkların ele alınmasındaki dayanıklılıklarını öne çıkarmışlardır.



Şekil 45. Bursa veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.


Çalışmada geliştirilen mekansal-zamansal modellerin Bursa projesi için SPI tahmininde gösterdikleri doğruluk performans göstergeleri Şekil 46’da verilmektedir. Şekil

46 modellerin sekiz zaman penceresi boyunca sergiledikleri doğruluk performanslarını göstermektedir. SPI tahmini için modellerin en iyi performans gösterdikleri pencere, 7. pencere olup, RNN-GatedGNN ve RNN-GatedGAT gibi geçitli mekanizmaları içeren modeller en yüksek doğruluk seviyelerine ulaşarak 0,85'e yaklaşmıştır. En kötü performans gösterilen pencere ise 1. pencere olup, GatedGNN-LSTM ve RNN-GatedGNN gibi modeller erken aşama SPI tahmininde daha yüksek doğruluk sergilemiştir.




Şekil 46. Bursa veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları.

Şekil 47 ve 48 sırası ile mekansal-zamansal modellerin Elazığ projesindeki farklı dögüsel pencerelerde CPI ve SPI tahminlerinde gösterdikleri doğruluk performanslarını göstermektedir. Modellerin, Elazığ veri seti için sergiledikleri düşük CPI ve SPI tahmin performans doğruluklarının Adana projesinde de gözlemlendiği gibi zamanlama farkları ve veri kalitesinden kaynaklandığı düşünülmektedir.




Şekil 47. Elazığ veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları.




Şekil 48. Elazığ veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları

Şekil 49 ve 50’de Yozgat projesi veri seti özelinde mekansal-zamansal modellerin farklı döngüsel pencerelerde sırası ile CPI ve SPI tahminleri için gösterdikleri doğruluk performansları verilmektedir. İlk pencere, projenin başlangıç koşullarının daha öngörülebilir olduğunu veya daha az değişken olması nedeniyle önemli ölçüde daha iyi doğruluk sergilediğini göstermiştir.



Şekil 49. Yozgat veri seti için geliştirilen mekansal-zamansal modellerin CPI tahminindeki doğruluk performansları


Şekil 49 ve 50’de sunulduğu üzere modellerin CPI ve SPI tahminlerinde erken pencerelerde gösterdikleri yüksek performans, başlangıç zamanlama tahminlerinin güvenilir ve tahmin edilmesinin daha kolay olduğunu göstermektedir.



Şekil 50. Yozgat veri seti için geliştirilen mekansal-zamansal modellerin SPI tahminindeki doğruluk performansları

Mekansal-zamansal modellerin çalışmada dikkate alınan projeler için sergiledikleri CPI ve SPI tahmin performanslarının farklı performans metriklerine göre değerlendirmesi toplu olarak ilgili şekillerde verilmektedir. Şekil 51 modellerin, değerlendirilen bu metrikler için CPI tahmin performanslarını gösterirken, Şekil 52 SPI tahmin performanslarını göstermektedir. Daha önceki bölümlerde detaylıca anlatıldığı üzere; Doğruluk, modelin tüm tahminler boyunca genel doğruluğunu, Kesinlik, pozitif tahminlerin doğruluğunu (yani, verimli veya zamanında olarak tahmin edilenlerin gerçekten verimli veya zamanında olup olmadığını), Geri çağırma, modelin bir veri kümesi içindeki tüm ilgili vakaları bulma yeteneğini, F1 skoru, kesinlik ve geri çağırma metriklerinin harmonik ortalamasını


ölçmektedir. AUC, modelin rastgele seçilen bir pozitif örneği rastgele bir negatif örnekten daha yüksek sıraya yerleştirme olasılığını temsil eder.



Şekil 51. Mekansal-zamansal modellerin proje veri setinin farklı pencereleri içinde çeşitli performans metriklerine göre CPI tahminine yönelik performansları.

Şekil 51'den görülebileceği üzere mekansal-zamansal modeller, dört inşaat projesi veri kümesi genelinde tahmin yapmada güçlü bir genel performans sergilemişlerdir. Modellerin çoğu %80'in üzerinde bir doğruluk oranı göstermiş ve bazı durumlarda bu oran %90'ın üzerine çıkmıştır. Bu yüksek doğruluk değerleri, modellerin bir projenin verimli kalıp kalmayacağını veya verimsiz duruma düşüp düşmeyeceğini etkili bir şekilde tahmin etme yeteneklerini yansıtmaktadır. Adana, Bursa ve Elazığ veri setlerinde, modeller sürekli olarak yüksek doğruluk oranlarına ulaşmış ve AUC dahil olmak üzere performans metriklerinde minimum varyans sergilemiştir. AUC'deki küçük değişiklikler, modellerin pozitif örnekleri (maliyet aşımaları) doğru sıralama yeteneğindeki farklılıklara işaret etmektedir. Bununla birlikte, kesinlik, geri çağırma ve F1 skoru metriklerinin genel kararlılığı, modellerin Adana'daki projeye dair maliyet aşımalarını güvenilir bir şekilde tahmin ettiğini ve hem verimli hem de verimsiz durumları tanımlamada etkili olduklarını göstermektedir.

Yozgat projesine ait veri seti diğer veri setlerine kıyasla özellikle geri çağırma ve F1 skoru açısından büyük bir değişkenlik göstermiştir. Bu önemli değişkenlik, modellerin birçok örneği doğru sınıflandırabilmesine rağmen, verimsiz durumları tespit etme ile yanlış tespitler arasında denge kurmakta zorlandığını göstermektedir. Bu tutarsızlığın, daha küçük veri seti boyutundan, eksik kayıtların varlığından ve ilerleme haftalarının kısa sıralarından (15'ten az) ileri gelebilir. Bu sınırlamalarla birlikte sınıf dengesizliğinin varlığı, modellerin özellikle azınlık sınıfı (verimsiz durumlar) için etkili bir şekilde genelleme yapma yeteneğini azaltmıştır.




Şekil 52. Mekansal-zamansal modellerin proje veri setinin farklı pencereleri içinde çeşitli performans metriklerine göre SPI tahminine yönelik performansları

Şekil 52'den görülebileceği üzere mekansal-zamansal modellerin SPI tahmini içinki performans göstergeleri CPI tahmin performanslarına kıyasla genellikle daha düşük olmuştur. Örneğin, doğruluk Adana, Bursa ve Elazığ gibi projelerde önemli ölçüde düşerek %80 civarına gerilemiştir. Daha düşük doğruluğa rağmen, modeller hala F1 skoru, kesinlik ve geri çağırma açısından karşılaştırılabilir gösterge seviyelerini korumuştur. Bu durum tahmin hatalarının pozitif ve negatif sınıflar arasında daha eşit dağıldığını göstermektedir. Yozgat projesinde, SPI tahmini için genel doğruluk CPI'a göre daha düşük olmasına rağmen F1 skoru ile doğruluk arasında önemli bir fark görülmemiştir. Bu gözlem, modellerin doğruluklarının daha düşük olmasına rağmen kesinlik ve geri çağırma metrikleri arasında bir denge sağlamayı başardığını göstermektedir. Böylelikle, modellerin veri setinin sınırlamalarına rağmen (Yozgat ilinde gerçekleştirilen yapım projesinin daha küçük veri seti boyutu ve daha az ilerleme haftası içermesi gibi) hala genelleme yapabildiğini göstermektedir.


Modellerin, özellikle GatedGNN ve dikkat mekanizmalarını içeren modellerin, projelerin hem CPI (Şekil 51) hem de SPI (Şekil 52) tahmini için sergiledikleri performansları inşaat verilerindeki zamansal değişkenlik ve sınıf dengesizliğiyle başa çıkmada büyük ölçüde etkili olduğunu göstermektedir. GatedGNN ve dikkat mekanizmalarını içeren modeller farklı veri setleri üzerinde iyi bir tahmin performansı göstermiş ve kesinlik, geri çağırma, F1 skoru, doğruluk ve AUC metrikleri değerleri nispeten birbirine yakın kalarak dengeli bir tahmin performansı sergilediği gözlemlenmiştir.

Projelere ait CPI ve SPI veri setlerinde gözlemlenen sınıf dengesizliği göz önüne alındığında, sonraki değerlendirmelerde modellerin performanslarını değerlendirmek için birincil metrik olarak F1 skoru kullanılmıştır. Dengesiz veri setlerinde yanıltıcı olabilecek doğruluk metriğinin aksine, F1 skoru hem kesinlik hem de geri çağırma metriklerini dikkate alarak dengeli bir bakış açısı sunmaktadır. F1 skorunun birincil metrik olarak kullanılması modellerin, yalnızca çoğunluk sınıfı performansına (örneğin, verimli CPI veya zamanında SPI vakaları) göre optimize edilmediğini, aynı zamanda daha kritik olan azınlık sınıfı olaylarını, yani verimsizlik veya program gecikmeleri gibi durumları da etkili bir şekilde tanımlayabildiklerini göstermelerini garanti altına almıştır. Bu tür olayların doğru bir şekilde tahmin edilmesi, proje yöneticilerinin farklı inşaat aktivitelerinin planlanan detaylarındaki tutarsızlıkları işaretlemelerine, buna uygun düzeltici önlemler almalarına ve riskleri hafifletmelerine olanak tanıyacaktır. Bu yaklaşım, özellikle inşaat proje yönetiminde büyük önem taşıyan ve bu tez çalışmasının ana amacı olarak verilen bu tür durumların görüldüğü

yapım projeleri verilerini işleyerek yüksek performanslı ML tabanlı model geliştirilmesi ile tutarlılık göstermektedir. CPI ve SPI ilerleme tahmin modellerinin ardışık öğreniminde geçit ve dikkat mekanizmalarının etkisini bu tez çalışmasında özellikle incelemiştir. İncelemeye dair sonuçlar Şekil 53 ve 54'te verilmiştir. Burada, kutu grafikleri kullanımı, modellerin farklı yapılandırmalar arasındaki performansını net bir şekilde görselleştirmeye olanak tanıdığından tercih edilmiştir. Böylelikle, performans skorlarının dağılımını ve yoğunluğunu değerlendirmek mümkün olmuştur. Kutu grafiğinin altı alt çeyreği (25. yüzdilik dilim), performans skorlarının %25'inin altında kaldığı noktayı temsil eder ve model performansının alt aralığı hakkında bilgi verir. Kutu grafiğinin ortasındaki çizgi medyanı (50. yüzdilik dilim) gösterir ve model yapılandırmaları için ortalama performans skorunu vurgulayan güvenilir bir merkezi eğilim ölçüsüdür. Kutu grafiğinin üstü üst çeyreği (75. yüzdilik dilim), performans skorlarının %75'inin altında kaldığı noktayı gösterir ve daha yüksek performans gösteren yapılandırmaları belirlemede yardımcı olmaktadır. Ayrıca, kutu grafiğindeki uç değerler (Outliers), bireysel noktalar olarak temsil edilmekte olup, beklentilerin dışında kalan performans skorlarını (grafiklerde alt ve üst kuyrukların ötesinde) ifade eder. Bu uç değerler, değişkenliği anlamak ve belirli yapılandırmaların ya olağanüstü başarı ya da zorluk yaşadığı aşırı durumları belirlemek için önemlidir. Bunun yanı sıra, alt kuyruk (minimum skor), uç değerler hariç tutulduğunda minimum skoru gösterir ve değerlendirilen mekanizmanın en kötü performansını ortaya koyar. Üst kuyruk (maksimum skor), uç değerler hariç tutulduğunda maksimum performans skorunu gösterir ve bu her mekanizma tarafından elde edilen en iyi performans olarak bilinir. Çeyrekler arası aralığı temsil eden kutunun uzunluğu, modellerin performanslarının ne kadar yoğunlaştığını veya yayıldığını göstermektedir. Kısa kutu uzunluğu, modelin performansının daha tutarlı olduğunu ve %25 ile %75 yüzdilikler arasında daha az değişkenlik bulunduğunu ifade eder. Buna karşılık, daha uzun bir kutu, yapılandırma içinde bazı modellerin diğerlerine göre önemli ölçüde daha iyi veya daha kötü performans gösterdiğini, diğer bir deyişle daha fazla değişkenlik olduğunu belirtir.




Şekil 53. Mekansal-zamansal CPI tahmin modellerinde dikkat ve geçit mekanizmaları arasındaki F1 skoru performans karşılaştırması.




Şekil 54. Mekansal-zamansal SPI tahmin modellerinde dikkat ve geçit mekanizmaları arasındaki F1 skoru performans karşılaştırması.

Şekil 53 ile 54 incelendiğinde, dikkat ve geçit mekanizmalarına sahip modellerin, projelerin 25 kaydırma penceresi boyunca CPI ve SPI tahminleri için elde edilen F1 skorlarının bu geliştirmeleri içermeyen salt evrimsel yaklaşımlara göre üstün olduğunu açıkça göstermektedir. Geçit mekanizması olmaksızın dikkat mekanizmaları GCN'e göre daha iyi sonuçlar vermektedir. Bu bulgu, inşaat sahası güvenliği veri setlerinde yapılan

önceki araştırmalarla (F. Mostofi & Toğan, 2023b) benzerlik göstermektedir. Bu gözlemi daha da pekiştirmek amacıyla, Şekil 55 ve Şekil 56'da geçit mekanizmasına sahip modellerin performansları hem geçit hem de dikkat mekanizmasına sahip olanlarda dahil olmak üzere diğerlerinden izole edilerek F1 skoru performans karşılaştırmaları verilmiştir.




Şekil 55. Geçit mekanizmasına sahip mekansal-zamansal inşaat ilerleme CPI tahmin modellerinin F1 skoru performans karşılaştırması.




Şekil 56. Geçit mekanizmasına sahip mekansal-zamansal inşaat ilerleme SPI tahmin modellerinin F1 skoru performans karşılaştırması.

Şekil 55 ve Şekil 56'dan da görülebileceği üzere, geçitli modeller genel olarak veri setleri boyunca geçitsiz modellerin üzerinde performans sergilemiştir. Bu durum, modellere geçit mekanizmasının eklenmesinin inşaat ilerleme verilerindeki zamansal bağımlılıkları ve incelikleri etkili bir şekilde yakalayarak modellerin daha doğru tahminler yapmasına olanak sağladığını göstermektedir. Bu tür mekanizmaların geliştirilmesi yönündeki ilerlemeler,

inşaat proje yönetiminde daha güvenilir tahmin araçlarının geliştirilmesi açısından hayati önem taşımakta ve dinamik proje ortamlarında tahmin doğruluğunu ve güvenilirliğini artırmada katkıda bulunacaktır. Proje verilerindeki zamansal bileşenleri kapsamlı bir şekilde değerlendirmek için, Şekil 57 ve 58’de CPI ve SPI tahmininde kullanılan modellerdeki RNN, LSTM ve GRU mimarilerinin etkinliği incelenmiştir.



Şekil 57. Mekansal-zamansal CPI tahmin modellerinde RNN, LSTM ve GRU mekanizmaları arasındaki F1 skoru performans karşılaştırması.




Şekil 58. Mekansal-zamansal SPI tahmin modellerinde RNN, LSTM ve GRU mekanizmaları arasındaki F1 skoru performans karşılaştırması.


RNN, LSTM ve GRU mekanizmalarının CPI ve SPI tahminleri için yapılan değerlendirmesinde sonuçlar farklı zaman dilimlerinde değişkenlik göstermiştir. Dört proje genelinde hem CPI hem de SPI tahmini için hiçbir tekil zamansal mekanizma, tüm 25 zaman dilimi boyunca diğerlerinden tutarlı bir şekilde daha iyi performans sergilememiştir. Bu gözlem, RNN, LSTM ve GRU modellerinin farklı veri setlerinde başarılı olduğunu, ancak

bu avantajın mutlak olmadığını ve proje aşamasına ve temel verilerin istikrarına bağılı olarak değişebileceğini ortaya koymaktadır. Bu nedenle, bu mekanizmaların performansı, diğer mekanizmalarla kombinasyon halinde değerlendirilmelidir. Bu maksatla dikkate alınan bir sonraki faktör yönsellik olmuştur. Yönsellik etkisinin incelendiği durumlarda (Şekil 59 ve 60), tek yönlü mekanizmalara sahip modeller, çoğu pencere boyunca çift yönlü modellere kıyasla daha iyi performans sergilemiştir.





Şekil 59. Tek yönlü ve çift yönlü mekansal-zamansal CPI ilerleme tahmin modelleri arasında F1 skoru performans karşılaştırması.





Şekil 60. Tek yönlü ve çift yönlü mekansal-zamansal SPI ilerleme tahmin modelleri arasında F1 skoru performans karşılaştırması.

Şekil 59 ve 60'tan görülebileceği üzere, çift yönlü modeller, proje zaman çizelgelerinin özellikle ilk ve orta pencerelerinde tek yönlü modellere kıyasla daha yüksek F1 skorları sergilemektedir. Bu iyileşme, çift yönlü modellerin daha bilgilendirici tahminler yapmak için geçmiş ve gelecekteki veri noktalarını kullanabilme yeteneğini vurgulamaktadır. Bu

durum, inşaat görevlerinin genellikle ileriye ve geriye dönük zamana bakma ihtiyacından çok daha net bir bağımlılık sırasına sahip olmasıyla açıklanabilir. Bu özellik, olaylar arasındaki sıranın anlaşılmasının önemli olduğu inşaat yönetimindeki karar alma süreçlerini ve proje sonuçlarını önemli ölçüde etkileyebilir.

2.6.3. Mekansal-Zamansal Modellerin Seçimi

Sonuç olarak, GatedGNN mekanizmasına sahip tek yönlü mekansal-zamansal modeller, ileri yapılandırmalar için tercih edilmiştir. GatedGNN'nin yönlü mekanizmalarla birlikte seçilmesi, inşaat projelerindeki ilerleme tahmini açısından en uygun çözüm olarak gözükmemektedir. İnşaat aktivitelerinin genellikle düşük zamansal sıra karmaşıklığına sahip olması nedeniyle bu yaklaşım, inşaat ilerleme tahmininde verimli olmuştur. GatedGNN'nin yönlü mekanizmalarla olan birlikteliği, inşaat aktivitelerinin mekansal-zamansal bir ağda düğümler olarak saklandığı ve ortak WBS kategorileri ile haftalık teslimat zaman çizelgeleriyle birbirine bağlandığı veri setinin yapısıyla iyi bir uyum göstermektedir. Dinamik modeller (örneğin, GatedGNN'nin RNN, LSTM, GRU ile kombinasyonu), statik mekansal-zamansal modellere göre F1 skoru açısından önemli bir performans artışı sağlamış ve inşaat ilerleme tahmininde zamansal dinamiklerin dahil edilmesinin önemini vurgulamıştır. Bu bulguyu daha da doğrulamak amacıyla, Şekil 61 CPI ve SPI tahminleri için 25 pencere boyunca 36 mekansal-zamansal modelin frekans analizlerini sunmaktadır.




Şekil 61. En yüksek doğruluk ve F1 skoruna sahip en iyi performans gösteren model sıklığı.

Şekil 61'den elde edilen gözlemler, geçit mekanizması içeren modellerin en iyi performans gösteren modeller olarak daha sık rastlanıldığını açıkça göstermektedir. Bu modeller, özellikle F1 skoru açısından, statik mekansal-zamansal modeller (örneğin, GCN) ile karşılaştırıldığında sürekli olarak üstün performans sergilemiştir. Geçit mekanizmalarına sahip modeller, 60'tan fazla durumda en yüksek doğruluk oranına ulaşarak yalnızca 16

durumda öne çıkabilen geçitsiz modelleri geride bırakmıştır. Kesinlik ve geri çağırma arasındaki dengeyi sağlayan F1 skoru açısından değerlendirildiğinde de geçitli modeller geçitsiz modellere kıyasla daha fazla durumda en iyi olabilmektedir. Bu tutarlı eğilim geçitli mekansal-zamansal modellerin, farklı veri setleri ve proje koşulları boyunca dengeli ve doğru performansı gösterme konusundaki sağlamlığına ve güvenilirliğine vurgu yapmaktadır.


Genel olarak hem doğruluk hem de F1 skoru performansını dikkate alındığında, Şekil 61'den elde edilen gözlemler, geçit mekanizmalarının dahil edilmesinin modelin proje sonuçlarını doğru bir şekilde tahmin etme yeteneğini önemli ölçüde artırdığını açıkça göstermektedir. Bu iyileşme, geçitli modellerin ardışık veri bağımlılıklarını yönetme konusundaki üstün kapasitesinden ve veri setindeki düzensizliklere karşı dayanıklılıklarından kaynaklanmaktadır. Statik modeller zaman zaman rekabetçi doğruluk oranlarına ulaşmış olsalar da bu durumun nadir görülmesi (50 senaryo boyunca beşten az) dinamik modellerin, özellikle RNN, LSTM ve GRU gibi zamansal bileşenler içeren modellerin, üstün güvenilirliğini doğrulamaktadır. İlginç bir şekilde, statik GatedGNN modeli de belirli senaryolarda güçlü bir performans sergilemiştir; bu da belirli koşullar altında statik modellerin hala kullanılabilir olabileceklerini düşündürmektedir.

Bu bulguyu pekiştirmek amacıyla, Şekil 62 ve Şekil 63 çeşitli mekansal-zamansal CPI tahmin modellerinin performansına ilişkin daha kapsamlı bir analiz sunmaktadır. Bu analiz, en yüksek doğruluk ve en yüksek F1 skoru gibi iki kritik metrik temelinde en iyi performans gösteren modellerin sıklığını karşılaştırmaktadır. Analiz, geçitli mekanizmalarla entegre edilen modellerin doğruluk ve F1 skoru performanslarına odaklanarak Adana, Bursa, Elazığ ve Yozgat gibi farklı projelerin veri setlerinde çeşitli pencereler boyunca bu modelleri incelemektedir. İncelemede, modeller geçitli mekanizmalara sahip mekansal-zamansal modeller ve bu mekanizmalara sahip olmayan modeller olarak renk kodlarıyla ayrılmıştır.



Şekil 62. Geçitli mekanizmalara sahip mekansal-zamansal modeller ile bu mekanizmalara sahip olmayan modellerin farklı pencerelerde CPI tahmin performansları karşılaştırması.

Şekil 62'de verilen sonuçlar, GatedGNN-RNN ve GatedGNN-GRU gibi geçitli mimarilere sahip modellerin, çoğu pencerede hem doğruluk hem de F1 skoru açısından diğer mekansal-zamansal modelleri sürekli olarak geride bıraktığını açıkça göstermektedir. Örneğin, GatedGNN-RNN modeli çoğu veri setinde üstün performans göstermiş ve tüm projelerde erken pencerelerde (W1'den W3'e kadar) en yüksek doğruluk oranına (%85 ila %90 civarında) ulaşmıştır. Bu performans, özellikle projelerin erken aşamalarında verilerin daha tamamlanmış olduğu durumlarda modellerin CPI tahminindeki dayanıklılığını vurgulamaktadır.




Şekil 63. Geçitli mekanizmalara sahip mekansal-zamansal modeller ile bu mekanizmalara sahip olmayan modellerin farklı pencerelerde SPI tahmin performansları karşılaştırması.


Şekil 63'ten görülebileceği üzere , özellikle GatedGNN-LSTM ve GatedGNN-RNN modelleri çoğu pencerede %80 ile %85 arasında değişen daha yüksek doğruluk ve F1 skoru değerlerine tutarlı bir şekilde ulaşmıştır. Bi-GRU-GCN gibi geçitsiz modeller ise farklı pencerelerde performans dalgalanmaları sergilemiştir. Bu değişkenlik, geçitli mekanizmaların mekansal-zamansal modellerin inşaat ilerleme kayıtlarını öğrenme konusundaki öngörücü yeteneklerini artırmada dayanıklı olduklarını işaret etmektedir.

Şekil 61 aracılığı ile verilen en iyi performans gösteren modellerin sıklığına ilişkin gözlemlere benzer şekilde, Şekil 62 ve Şekil 63'te mekansal-zamansal modellerin CPI ve SPI tahmin performansları için yapılan değerlendirmelerinde, 25 kaydırma penceresi boyunca GatedGNN mekanizmalarını kullanan modellerin daha iyi bir performans ortaya koydukları görülmektedir.

Şekil 64 ve 65 projelerin veri setleri üzerinde statik ve dinamik CPI ve SPI tahmin modellerinin performans karşılaştırmasını sunmaktadırlar.



Şekil 64. Statik ve dinamik mekansal-zamansal modellerin CPI tahmininde F1 skoru performansları karşılaştırması.



Şekil 65. Statik ve dinamik mekansal-zamansal modellerin SPI tahmininde F1 skoru performansları karşılaştırması.

Dinamik ve statik mekansal-zamansal modellerin CPI ve SPI tahmin performansları karşılaştırmalarında, dinamik modeller, statik modellere kıyasla çoğu pencerede üstün performans sergileyerek zamansal dizilerin karmaşıklıklarını daha iyi yönetebilmişlerdir. Neredeyse tüm pencerelerde, dinamik modeller genellikle daha yüksek F1 skorlarına

ulaşmış, bu da zamansal öğrenme mekanizmalarının dahil edilmesinin farklı zaman dilimlerinde CPI tahmini için net bir avantaj sağlamaktadır. Ancak, statik modeller bazı pencerelerde dinamik modelleri geride bırakabilmiştir. Örneğin, Elazığ projesinin 9. penceresi gibi projenin daha stabil olduğu verinin zamansal boyutunun daha az önemli olabileceği durumlarda statik modeller, dinamik modellerle karşılaştırılabilir veya hatta daha iyi performans sergileyebilmiştir.

Sonuç olarak, özellikle mekansal ve zamansal bileşenleri entegre eden dinamik modeller, inşaat projelerinin verilerinde yer alan karmaşık ilişkileri daha iyi yakalayabilmiştir. Çalışmada sunulan sonuçlar göz önüne alındığında, CPI ve SPI açısından inşaat ilerlemesini tahmin etmek için yönlü mekanizmalara sahip GatedGNN kullanımının en uygun model yapılandırması olarak önerilebileceği görülmektedir. Bu modellerdeki yönsellik, inşaat aktivitelerinin ardışık doğasını etkili bir şekilde yönetmelerine olanak tanımış, görevlerin belirli haftalarda teslim edilip WBS ve bağımlılıklar aracılığıyla birbirine bağlandığı yerlerde büyük önem taşımıştır.

İleriye dönük olarak, GatedGNN mekanizmasına sahip mekansal-zamansal ilerleme tahmin modelleri farklı proje aşamaları, veri kalitesi koşulları ve olası siber saldırı simülasyonları boyunca daha fazla değerlendirilecek ve gerçek dünya uygulamalarında sağlamlıkları ve güvenilirlikleri test edilecektir.

2.7. Üretici Modellerle Hibrit Veri Setleri Oluşturma

Bu çalışmada incelenen projelere ait veri setlerindeki azınlık sınıfları için , özellikle mekanik, elektrik ve yalıtım veri setlerinin alt kümelerine, veri üretmek amacıyla ilk olarak VAE kullanılmıştır. Bu kullanımdaki amaç, sınıf dengesizliğinin tahminleri çoğunluk sınıflara kaydırma eğilimini dengeleyerek mekansal-zamansal modellerin performansını artırmaktır. VAE modeli, sınıf dengesizliği probleminin çözümü için dikkate alınan diğer SMOTE, düşük örnekleme ve fazla örnekleme gibi mevcut sınıf dengesizliği yöntemlerinden daha iyi performans göstererek, GAT gibi modeller için farklı veri setlerinde tahmin doğruluğunda %6'lık bir artış sağlamıştır (Mostofi vd., 2024). Ancak, bu başarıya rağmen, VAE son değerlendirme aşamalarında daha büyük veri setlerine uygulandığında hatalar ile karşılaşmıştır. Özellikle daha karmaşık veri yapılarının ölçeklenmesi sırasında meydana gelen kaybolan gradyan sorunu, eğitim sırasında NaN (Not a Number) hatalarının

oluşmasına yol açmıştır (Mostofi vd., 2024). Bu sınırlama, azınlık sınıfları için veri üretiminde VAE'den GAN'lara geçilmesini zorunlu kılmıştır.

GAN'ların kullanılmasında iki yaklaşım benimsenmiştir. İlk yaklaşımda projelere ait veri setinin her birinde azınlık sınıfları için sentetik veri üretmek amacıyla GAN mimarileri geliştirilmiştir; bu süreçte daha güçlü üreticilere ve daha zayıf ayırt edicilere sahip farklı mimariler kullanılmıştır. Bu yaklaşım verileri başarılı bir şekilde üretmiş olsa da orijinal veri setiyle eğitilen modellere kıyasla tahmin doğruluğunu önemli ölçüde artırmamıştır. İkinci yaklaşımda ise veri setinin 25 kaydırma penceresi boyunca GAN'lar eğitilerek her penceredeki CPI ve SPI tahminleri için azınlık sınıflarına yönelik veri üretilmesi hedeflenmiştir. Toplamda 50 GAN modeli geliştirilmiş ve eğitilmiştir. Ancak bu yöntem de orijinal veri setiyle eğitilen mekansal-zamansal modellerin performansını aşmayı başaramamıştır.

Azınlık sınıfları için veri üretiminde hem VAE hem de GAN kullanımında karşılaşılan en büyük zorluklardan biri, inşaat ilerleme veri setlerinin ayrıntılı ve karmaşık yapısı göz önüne alındığında üretilen veri noktaları arasında anlamlı kenarlar ve zamansal ilişkiler yaratmanın zorlu olarak öne çıkmaktadır. GAN modelleri sentetik veriler üretmeyi başarmış olsalar da etkili tahminler için gerekli mekansal ve zamansal bütünlüğü korumakta zorlanmışlardır. Bu devam eden zorluk, mekansal-zamansal modellerde sınıf dengesizliğinin ele alınmasının ne kadar karmaşık olduğunu göstermekte ve mekansal ve zamansal ilişkilerin doğru bir şekilde temsil edilmesinin gerektiği büyük ölçekli veri setlerinde bu zorluk daha da artmaktadır.

. İnşaat ilerleme kayıtları genellikle zaman ve görevler arasında birden fazla bağımlılık içeren karmaşık verilerdir. Bu nedenle üretilecek olan modelin hem mekansal bağımlılıkları hem de zamansal sıralamayı yönetebilen ve doğru tahmin sonuçları için gerekli olan tutarlılığı kaybetmeden işleyebilen daha sofistike bir üretici model entegrasyonu gerektireceği öngörülmektedir.

3. MODEL DEĞERLENDİRMESİ BULGULAR VE TARTIŞMA

Bu tez çalışmasının birincil amacı inşaat görevlerinin hem mekansal hem de zamansal boyutlarını yakalayarak CPI ve SPI'yi daha güvenilir bir şekilde tahmin eden mekansal-zamansal makine öğrenimi modelleri geliştirmektir. Böylelikle, inşaat yöneticilerine daha iyi proje yönetimi sağlayacak eyleme geçirilebilir bilgiler sunabilen modeller üretilmesi hedeflenmiştir. Bu hedefin gerçekleştirilebilmesi için çalışmada yapılandırılan modellerin ayrıca, sınıf dengesizliği ve eksik veri gibi veri kalitesi sorunlarına karşı dayanıklı kalmaları; veri zehirlenme ve etiket manipülasyonu gibi çeşitli saldırılara karşı da güçlü olmalarını sağlayacak simülasyonlar yapılmıştır.


CPI ve SPI tahmininde kullanılan geçitli mekanizmalarla entegre mekansal-zamansal modeller daha üstün performans göstermeleri nedeni ile in daha geniş bir bağlamda değerlendirilmiştir. 2. bölümde ayrıntılı olarak açıklanan GatedGNN mimarisine sahip mekansal-zamansal modeller, geçitli mekanizmalara sahip olmayan diğer modellere kıyasla tahmin performansında önemli bir üstünlük ortaya koymuştur. Bu değerlendirme, özellikle GatedGNN ile entegre edilen yönlü modellerin, çift yönlü modellere ve geçitli bileşenlere sahip olmayan diğer mekansal-zamansal modellere göre nasıl bir performans gösterdiğini anlamayı içermektedir. Toplamda 13 dinamik mekansal-zamansal model ve bir statik model (GatedGNN mekansal-zamansal) değerlendirilmiştir.

Yapılan incelemeler RNN ve GRU modellerinin, LSTM modellerine göre göreceli bir performans üstünlüğü sergilediğini göstermiştir. Bu nedenle, beş model üzerinde durulmuştur: GatedGNN, GatedGAT-RNN, GatedGNN-GRU, RNN-GatedGNN ve GRU-GatedGNN. Bu modellerin performansı, LSTM veya dikkat mekanizmalarıyla birleştirilen diğer geçitli yönlü modellerle karşılaştırılmıştır.

Çalışmada yapılandırılan 36 mekansal-zamansal modelin değerlendirilmesi sırasında, ardışık modellerin zamansal ML modellerine göre önceliklendirilmesinde kesin bir avantaj olmadığı gözlemlenmiştir. Bu nedenle, sonuçlar bölümünde, GNN tabanlı bileşenleri önceliklendiren (örneğin, GatedGNN-RNN) ve ardından RNN, LSTM veya GRU bileşenlerini kullanan mekansal-zamansal modeller ile mekansal öğrenmeye kıyasla ardışık öğrenmeyi önceliklendiren modeller (örneğin, RNN-GatedGNN) incelenmiştir. Ardından, seçilen GatedGNN tabanlı yapılandırmaların performansı 25 farklı pencere boyunca analiz edilmiştir.; Her bir pencere 14 hafta eğitim, 3 hafta doğrulama ve 4 hafta test döneminden

oluşmaktadır. Modeller veri bütünlüğü ve pencere boyutları açısından farklılık gösteren dört projeden elde edilen verileri kullanarak projelere ait CPI'yi 0 (verimsiz) veya 1 (verimli) ve SPI'yi 0 (gecikmiş) veya 1 (zamanında) olarak sınıflandırmıştır.

Şekil 66 farklı inşaat projeleri veri setlerinde (Adana, Bursa, Elazığ ve Yozgat) çeşitli zaman dilimlerinde (pencerelerde) değerlendirilen CPI ve SPI tahmin modellerinin doğruluk performansını sunmaktadır. Modeller, veri setine bağlı olarak altı ile dokuz arasında değişen pencereler boyunca takip edilmiştir ve her bir pencere modellerin eğitildiği, doğrulandığı ve test edildiği belirli bir zaman dilimini temsil etmektedir.



Şekil 66. Farklı veri setlerinde CPI ve SPI tahmin modellerinin farklı pencerelerde doğruluk performansı.


Adana, Bursa, Elazığ ve Yozgat'tan elde edilen veriler, mekansal-zamansal modelleri etkili bir şekilde eğitmek için tutarlı ve eksiksiz verilere sahip olmanın önemine işaret etmektedir. Tahmin modellerinin Adana veri seti üzerindeki performansı, ilk iki pencerede 0,9 civarında zirveye ulaşan yüksek başlangıç doğruluk eğilimi sergilemiştir. Ancak, 3. pencereden itibaren model doğruluğunda keskin bir düşüş gözlemlenmiştir. Bu düşüş,

doğrudan 27. hafta ile 37. hafta arasındaki dönem boyunca büyük ölçüde eksik kayıtların bulunmasına bağlanabilir. Bu dönem Pencere 3 ve 4 tarafından temsil edilmektedir. Bu kritik aşamada verilerdeki boşluk tutarsızlıklar yaratmış ve modellerin doğru tahminler yapma yeteneğini olumsuz etkilemiştir. Eksik kayıtlar, büyük olasılıkla eğitim verilerinin zamansal sürekliliğini bozmuş ve modellerin gerekli desenleri yakalayıp genelleme yapmasını zorlaştırmıştır. Sonuç olarak, bu pencerelerde tahminlerin güvenilirliği önemli ölçüde düşmüştür.

Bursa ve Elazığ veri setlerinde, tahmin modelleri tüm pencereler boyunca sürekli olarak yüksek bir doğruluk seviyesi göstererek doğruluk genellikle 0,9 civarında seyretmiştir. Bu veri setinde önemli veri boşluklarının veya tutarsızlıklarının olmaması modellerin sürekli olarak iyi performans göstermesini sağlamış ve bu modellerin, eksiksiz ve sağlam veri setlerine sahip projelerde sonuçları ele alma ve tahmin etme yeteneklerini ortaya koymuştur. Sekiz pencerede incelenen Bursa ve dokuz pencerede incelenen Elazığ veri setleri özelinde, zamansal sürekliliğin ve veri bütünlüğünün korunduğu veri setlerinde modeller yüksek doğruluk performansı sergilemektedir.

Yozgat veri seti, küçük kayıt boyutu ve özellikle 1. haftadan 10. haftaya ayrıca 27. haftadan 37. haftaya kadar eksik veri içermesine ile öne çıkmaktadır. Bu özellikler, değerlendirilen pencerelerde gözlemlenen tahmin doğruluğundaki değişkenliğe neden olarak gösterilebilir. Örneğin, 1. pencerede modeller orta düzeyde bir doğruluk seviyesine ulaşırken eksik ve daha kısa kayıt dizileri nedeniyle sonraki pencerelerde bu doğruluk düzeyi sürdürülememiştir. Veri setinin kısa dizi uzunluğuna ve eksik verilere sahip olması, modeller için zorluklar yaratarak Bursa ve Elazığ gibi daha geniş ve eksiksiz kayıtlara sahip veri setlerine kıyasla modellerin daha düşük doğruluk ve daha az güvenilir tahminler ortaya çıkarmasına yol açmıştır. Veri bütünlüğü ve kalitesinin model performansı üzerindeki etkisini, farklı seviyelerde veri bütünlüğüne sahip veri setleri arasında yapılan bu değerlendirmeler açıkça ortaya koymaktadır.

Şekil 67 Adana, Bursa, Elazığ ve Yozgat veri setlerinin dikkate alınan pencereleri boyunca modellerin CPI ve SPI tahmin performanslarının en yüksek doğruluk oranını göstermektedir.



Şekil 67. Farklı veri setlerinde ele alınan pencereler boyunca CPI ve SPI tahmin modellerinin en yüksek doğruluk performansı.

Şekil 67, Şekil 66 aracılığıyla gösterilen veri seti özelliklerine göre model performanslarının değişkenlik sergilemesi şeklinde özetlenecek bulguyu desteklemektedir. Şekil 67, özellikle GatedGNN'nin RNN, LSTM ve GRU gibi yinelemeli mimarilerle entegrasyonunun Adana ve Yozgat veri seti ile temsil edilen eksik veri içirme ve Bursa ve Elazığ veri seti ile temsil edilen boyut büyüklüğü ve veri bütünlüğü durumlarını ele almada diğer modellere kıyasla daha etkin olduğunu göstermektedir.


Adana veri setinde, GatedGNN modeli, GatedGNN-RNN, GatedGNN-LSTM ve GatedGNN-GRU gibi çeşitli mimarilerle entegre edilerek CPI tahminlerinde yüksek performans göstermiştir. Bu hibrit yaklaşım hem mekansal hem de zamansal veri özelliklerinden etkili bir şekilde yararlanarak CPI tahminlerinde yaklaşık 0,85 doğruluğa ulaşılmasına ön ayak olmuştur. Bununla birlikte, SPI tahmin görevlerinde GatedGNN-RNN ve RNN-GatedGNN modelleri optimal performansı sergilemiştir; bu da SPI tahminlerinde zamansal dinamiklerin önemini vurgulamaktadır.

Bursa veri seti, büyük miktarda kayıt içermesi ile öne çıkmakta olup GatedGNN-RNN ve GatedGNN yapılandırmasına sahip modeller bu veri setinde üstün performans sergileyerek en iyi tahmin doğruluğu performansı sergilemişlerdir. Hem CPI hem de SPI tahminlerinde sergilenen bu tutarlı yüksek performans, GatedGNN mimarisinin, özellikle RNN ile birleştirildiğinde, karmaşık ve geniş zamansal diziler üzerinde etkili öğrenme ve genelleme yeteneğine atfedilebilir.

Elazığ veri seti de Bursa veri seti gibi nitelikli veriler içermekte olup GatedGNN modeli hem CPI hem de SPI tahmin görevlerinde sürekli olarak yüksek performans sergileyerek Elazığ veri setinin karmaşıklığını ele almada dayanıklı olduğunu göstermiştir. GRU ve LSTM ile entegre edilen GatedGNN kombinasyonları (örneğin, GatedGNN-GRU, LSTM-GatedGNN), CPI veya SPI tahminlerinde en iyi performans gösteren model yapılandırmaları olarak öne çıkmaktadır.

Yozgat veri seti önemli ölçüde daha az veri içirme özelliğine sahip olup GRU-GatedGNN yapılandırması bu veri seti üzerinde gerçekleştirilen hem CPI hem de SPI tahminlerinde en iyi performansı göstererek sınırlı veri setlerini ele almada diğer modellere göre olan etkinliğini ortaya koymuştur. Bu durum, GRU bileşeninin, daha küçük veri setlerinden ilgili özellikleri çıkarmada özellikle etkili olabileceğini düşündürmektedir. GatedGNN ve GatedGNN-RNN modelleri, bu veri setinde GRU-GatedGNN modelinden sonraki en iyi tahmin doğruluğu performansı sergileyen modeller olarak gözükmemektedir. Bu modellerin hem mekansal bağımlılıkları (GNN'ler tarafından yakalanan) hem de zamansal desenleri (RNN'ler, GRU'lar ve LSTM'ler tarafından yakalanan) öğrenme yetenekleri, başarılarının anahtarı olmuştur. Tahmin modeline hem mekansal hem de zamansal boyutları entegre etmek, daha bütünsel ve güvenilir bir ilerleme tahmini yaklaşımı sunmaktadır.


Şekil 68 Adana veri setinin ilk pencere üzerinde eğitilen modellerin CPI ve SPI tahminleri için elde edilen AUC performansını göstermektedir.



Şekil 68. Adana veri setinin ilk penceresinde eğitilen GatedGNN mekanizmasına sahip mekansal-zamansal modellerin ROC performansları.

Şekil 68'den de görülebileceği üzere GatedGNN-GRU modeli, CPI tahmini için en yüksek AUC skorunu (0,95) sergilemiştir. Bu durum modelin verimli ve verimsiz sınıfları ayırt etme konusunda üstün performans gösterdiğini ortaya koymaktadır. Buna karşılık, modeller genel olarak SPI tahminlerinde daha düşük AUC skorları göstermişlerdir. GRU-GatedGNN modeli, 0,83 gibi bir AUC değeri elde etmesine rağmen modellerin program

ilerleme uyumuna ilişkin zamansal dinamikleri yakalamada daha fazla zorluk yaşandıklarını göstermektedir. Şekil 69 Adana projesinin ilk penceresinde eğitilen modellere ait eğitim ve doğrulama doğruluk performans değerlerini göstermektedir.




Şekil 69. Adana veri setinin ilk penceresinde eğitilen GatedGNN mekanizmasına sahip mekansal-zamansal modellerin doğruluk performansları.

Şekil 69 aracılığıyla verilen sonuçlardan elde edilen gözlemler önerilen GatedGNN mekanizmasına sahip mekansal-zamansal ilerleme tahmin modellerinin, artan epochlar

boyunca eğitim ve doğrulama doğruluğunu yakın seviyelerde tutarak güçlü genelleme yetenekleri gösterdiğini ortaya koymaktadır. Bu durum, modellerin uzun epochlarr boyunca eğitildiğinde dahi aşırı öğrenmeden kaçındığını ve performanslarının dengeli kaldığını göstermektedir.

Çalışmada yapılandırılan mekansal-zamansal modeller, GatedGNN mekanizması ile entegre edildiğinde veri setlerine ait çoğu pencerede yüksek doğruluk performansı ve iyi genelleme yeteneği elde etmiştir. Geliştirilen modellerin CPI ve SPI tahminlerinde gösterdikleri bu yüksek doğruluk performansları , geliştirilen modellerin inşaat yöneticilerinin kaynak tahsisi, proje takvimi ve maliyet yönetimi hakkında daha bilinçli kararlar almalarını sağlayacağı anlamına gelmektedir. Bu durumun, daha verimli proje yürütülmesine olanak tanıyarak kamu harcamalarını azaltma potansiyelini ve büyük ölçekli inşaat projelerinin finansal sürdürülebilirliğini artırması beklenilmektedir. Ayrıca, modellerin olası riskleri kritik sorunlar haline gelmeden önce işaret edebilme yeteneği, proje hızının korunmasına ve pahalı gecikmelerin önlenmesine yardımcı olma bakımından büyük değer taşımaktadır. Mekansal-zamansal modellerin dinamik yapısı—yeni verilerle sürekli öğrenme ve uyum sağlama yeteneği—bu modellerin gerçek zamanlı proje izleme için kullanılabileceği anlamına gelmektedir. Bu yetenek, şartlar değiştikçe projelerin rotasında kalmasını sağlarken yöneticilerin ortaya çıkan zorluklara proaktif olarak yanıt vermesine yardımcı olmaktadır. Ayrıca, çalışmanın öngörü analizine risk faktörlerini dahil etmesi, yapılandırılan modellerin gerçek dünya senaryolarına uygulanabilirliğini daha da güçlendirmekte ve onların inşaat proje yönetimi için kullanılabilecek değerli bir araç haline getirmektedir.

Sınıf dengesizliği, çalışmada ele alınan bir diğer önemli konudur. İnşaat projeleri tek bir zaman diliminde (örneğin bir hafta) fazla sayıda aktiviteyi içerebilmekte ve bu aktivitelerin her biri projeye farklı katkılar sağlamaktadır. Sonuç olarak, yapım projesine ait veri setinde özellikle verimsizlik veya gecikmelerle ilişkilendirilen bazı sınıflar veri setinde az sayıda temsil edilebilmektedir. Bu dengesizlik, modellerin öğrenmesi için yeterli çeşitliliğin sağlanmadığı özellikle küçük veri seti boyutu ve sıra uzunluğuna sahip Yozgat gibi projelerde etkili zamansal modellerin geliştirilmesini zorlaştırmıştır. Şekil 70 farklı veri setlerinde çeşitli pencereler boyunca CPI ve SPI tahmin modellerinin F1 skoru performansını göstermektedir. Bu gösterimde, F1 skorlarını izlemek için bir çizgi grafiği kullanılmakta ve modellerin kesinlik ve geri çağırma oranları birden fazla pencere boyunca takip edilmektedir.




Şekil 70. Farklı veri setlerinde çeşitli pencereler boyunca CPI ve SPI tahmin modellerinin F1 skoru performansları.

Şekil 70’te Adana veri setinde, F1 skoru 3. pencereden sonra keskin bir düşüş sergilemiş olup bu düşüş bu noktadan itibaren bu veri setinde görülen önemli ölçüdeki eksiklikten kaynaklanmıştır. Erken pencerelerde kaydedilen en yüksek F1 skoru yaklaşık 0,82 iken, sonraki pencerelerde yaklaşık 0,6 olmuştur. Geniş veri boyutuna sahip Bursa veri seti, dikkate alınan sekiz pencere boyunca 0,75 ile 0,88 arasında değişen kararlı F1 skoru değerini korumuştur. Daha büyük ve tutarlı veri seti, daha yüksek ve daha istikrarlı F1 skorlarının elde edilmesini sağlamıştır. Dokuz pencereye sahip olan Elazığ veri setinde, özellikle proje ilerledikçe ve veri hacmi azaldıkça F1 skoru değeri değişkenlikler göstermiştir. F1 skorları, erken pencerelerde 0,7, proje orta aşamalarında yaklaşık 0,78 olup ardından hafif bir düşüş göstermiştir. En az pencereye(iki) sahip Yozgat veri setinde, en düşük F1 skorları elde edilmiş olup bu skorlar 0,7’nin altında kalmıştır. Bu durum, bu veri setinin eğitim ve test için sınırlı pencere sayısına sahip olmasından kaynaklanmıştır.

F1 skoru analizi, farklı inşaat ilerleme veri setlerinin farklı zaman dilimlerinde eğitilen modellerin genel F1 skoru değerlerinin tahmin doğruluğuna kıyasla daha düşük kaldığını

göstermektedir. Bu gözlemi doğrulamak amacıyla, GatedGNN mekanizmalarına sahip incelenen mekansal-zamansal ilerleme tahmin modellerinin en yüksek F1 skoru performansları Şekil 71'de gösterilmektedir.



Şekil 71. Farklı veri setlerinde CPI ve SPI tahmin modellerinin sergiledikleri en yüksek F1 skoru performansları.

Şekil 71'de verilen sonuçlardan hareketle CPI tahminlerine kıyasla SPI tahminlerinin genellikle daha düşük doğruluk skorlarına sahip olduğu ifade edilebilir. Bu durum, süreye bağlı sonuçları tahmin etmenin, maliyetle ilgili tahminlerde bulunmaya kıyasla daha zor olduğuna veya süre performansını etkileyen veri ve faktörlerin çeşitliliğine işaret etmektedir. İncelenen veri setlerinin erken pencerelerinde modellerin SPI tahminindeki nispeten düşük performanslar, erken proje aşamalarında görülebilecek potansiyel değişkenliğe ve belirsizliğe işaret etmektedir.

Adana veri setinde, modeller hem CPI hem de SPI tahmin görevlerinde farklı performanslar sergilemiştir. GatedGNN-RNN modeli, her iki tahmin görevinde de en yüksek

F1 skorlarına ulaşarak öne çıkan bir model olmuştur. Bu durum, GatedGNN-RNN mimarisinin veri setindeki zamansal ve mekansal bağımlılıkları yakalamada son derece uygun olduğunu tekrar teyit etmektedir. Bununla birlikte, GRU-GatedGNN ve RNN-GatedGNN gibi diğer modeller de özellikle SPI tahmininde iyi performans göstermiştir. Bu modeller, önce RNN veya GRU aracılığıyla mekansal-zamansal verinin sırasını öğrenmenin ve ardından GatedGNN aracılığıyla mekansal bağımlılıklara odaklanmanın etkinliğini ortaya koymuştur. CPI tahmininde mekansal öğrenmeyi önceliklendiren GatedGNN-LSTM ve GatedGNN-GRU gibi modeller yüksek F1 skorları sergilemiş ve mekansal bileşenin bu veri seti için maliyet performansını tahmin etmede takvim performansına kıyasla daha önemli bir rol oynayabileceğini düşündürmüştür.

Modeller Bursa veri setinde hem CPI hem de SPI tahmin görevlerinde en istikrarlı ve yüksek F1 skoru performansını sergilemiştir. GatedGNN-RNN ve GatedGNN modelleri her iki tahmin görevinde de sürekli olarak 0,85'in üzerinde F1 skoru elde ederek en yüksek performans gösteren modeller olmuşlardır. Bursa veri setinin bütünlüğü ve güvenilirliği geniş kapsamlı olması ile birleştiğinde, modellerin hem CPI hem de SPI tahminlerinde iyi bir genelleme yapabilme yeteneklerine büyük katkıda bulunmuştur. Bu veri seti, mekansal-zamansal modellerin başarılı olması için ihtiyaç duyulan ideal veri seti olma koşullarını sağlayarak GatedGNN ve GatedGNN-RNN mimarilerinin veri setinde bulunan karmaşık mekansal ve zamansal bağımlılıkları etkili bir şekilde yakalama yetenekleri sayesinde güçlü bir performans sergilemelerine yol açmıştır. Dikkat çekici bir şekilde, GatedGNN ile LSTM ve GRU kombinasyonları da gösterdikleri performanslar ile geçitli mekanizmaların F1 skoru performansını artırmadaki önemini bir kez daha vurgulamıştır.

Şekil 72 Adana projesinde GatedGNN modellerinin, RNN ve GRU mekanizmalarıyla birleştirilmiş ve birleştirilmemiş versiyonlarının en iyi ve en düşük performans gösteren pencerelerindeki CPI sınıf tahmin performanslarını sergilemektedir. Şekil 72'de karışıklık matrisi üzerinde gösterilen CPI sınıf tahmin performanslarında; doğru sınıflandırmalar verimli sınıf için sağ altta TP ve verimsiz sınıf için sol üstte TN, yanlış tahminler ise modelin verimsiz aktiviteleri yanlışlıkla verimli olarak sınıflandırdığı senaryoları FP sağ üstte veya verimli aktiviteleri verimsiz olarak sınıflandırdığı senaryoları FN sol altta temsil edilmektedir. İlk pencere 21 haftalık zaman dilimini kapsarken sonraki pencereler 4 haftalık adımlarla kaydırılmış pencerelerdeki 21 haftalık zaman diliminin ilk 14 haftası eğitim, sonraki 3 haftası doğrulama ve son 4 haftası test için dikkate alınmıştır.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN		
Pencere 1	Gerçekleşen	Verimsiz	92.5%	7.5%	90.2%	9.8%	81.6%	18.4%	89.8%	10.2%	78.1%	21.9%
	Verimli	492	40	3796	414	434	98	3780	430	3286	924	
	Gerçekleşen	Verimli	19.4%	80.6%	10.8%	89.2%	7.9%	92.1%	12.6%	87.4%	7.5%	92.5%
	Verimsiz	259	1074	982	8081	105	1228	1143	7920	679	8384	
En Yüksek F1 Skoru Performansına Sahip Pencere												
Pencere 2	Gerçekleşen	Verimsiz	88.5%	11.5%	82.3%	17.7%	92.3%	7.7%	86.9%	13.1%	87.2%	12.8%
	Verimli	2116	274	1967	423	2206	184	2077	313	2085	305	
	Gerçekleşen	Verimli	19.2%	80.8%	11.4%	88.6%	20.9%	79.1%	18.2%	81.8%	17.7%	82.3%
	Verimsiz	697	2930	412	3215	758	2869	660	2967	643	2984	
Pencere 3	Gerçekleşen	Verimsiz	57.6%	42.4%	54.0%	46.0%	54.4%	45.6%	46.6%	53.4%	56.6%	43.4%
	Verimli	1198	881	1123	956	1131	948	969	1110	1176	903	
	Gerçekleşen	Verimli	15.4%	84.6%	11.7%	88.3%	12.3%	87.7%	11.4%	88.6%	14.9%	85.1%
	Verimsiz	294	1616	223	1687	235	1675	218	1692	285	1625	
En Düşük F1 Skoru Performansına Sahip Pencere												
Pencere 4	Gerçekleşen	Verimsiz	75.2%	24.8%	75.8%	24.2%	75.3%	24.7%	52.1%	47.9%	52.3%	47.7%
	Verimli	3438	1134	3464	1108	3444	1128	2383	2189	2389	2183	
	Gerçekleşen	Verimli	11.9%	88.1%	14.4%	85.6%	16.0%	84.0%	25.1%	74.9%	25.0%	75.0%
	Verimsiz	621	4614	756	4479	836	4399	1314	3921	1311	3924	
Pencere 5	Gerçekleşen	Verimsiz	62.5%	37.5%	86.5%	13.5%	91.7%	8.3%	65.3%	34.6%	87.3%	12.7%
	Verimli	5003	2997	6921	1079	7339	661	5228	2772	6987	1013	
	Gerçekleşen	Verimli	6.7%	93.3%	6.1%	93.9%	5.3%	94.7%	5.9%	94.1%	22.1%	77.9%
	Verimsiz	480	6718	438	6760	383	6815	423	6775	1591	5607	
Pencere 6	Gerçekleşen	Verimsiz	91.4%	8.6%	87.8%	12.2%	91.7%	8.3%	89.5%	10.5%	90.3%	9.7%
	Verimli	5768	541	5540	769	5788	521	5646	663	5694	615	
	Gerçekleşen	Verimli	28.7%	71.3%	25.7%	74.3%	31.7%	68.3%	20.4%	79.6%	31.2%	68.8%
	Verimsiz	1014	2514	908	2620	1120	2408	720	2808	1101	2427	
		Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	
		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		

Şekil 72. Adana projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.

Adana veri setinde önemli sayıda eksik kayıt bulunmaktadır. Verilerin kaybolması veya eksikliği, gizlilik kaygıları, insan hataları veya inşaat projesinin duraksaması gibi

durumlar nedeniyle verilerde eksiklikler olabilmektedir. Modellerin bu koşullara dayanıklılığını test edilmelidir. Böylelikle, modellerin hem ideal hem de zorlu gerçek dünya durumlarını ele alma performanslarına dair içgörüler sunulabilir. Adana veri setinde dikkate alınan pencereler, tam veri setlerinin (Pencere 1 ve 2), önemli eğitim ve test verileri arasındaki boşlukların (Pencere 3 ve 4) ve hatta eğitim verilerinde bile boşlukların bulunduğu senaryoları (Pencere 5 ve 6) temsil etmektedir.

İlk iki Pencerede (Pencere 1 ve 2) veri seti eksiksiz olup bu durum, modellerin yüksek performans sergilemesine olanak tanımıştır. Bu ideal koşullar altında, tüm modeller hem verimli hem de verimsiz sınıflar için yüksek tahmin doğruluğu elde etmiştir. GatedGNN ve GatedGNN-RNN özellikle Pencere 1'de en iyi performansı sergileyen modeller olarak öne çıkmıştır. GatedGNN verimsiz sınıf için %92,5, verimli sınıf için %80,6 doğruluk oranı elde etmiştir. GatedGNN-RNN ise dengeli bir performans sergileyerek verimsiz sınıf için %90,2, verimli sınıf için %89,2 doğruluk oranı yakalamıştır. Bu dengeli performans, GatedGNN-RNN'nin her iki sınıfı da eşit derecede etkili bir şekilde işleyebildiğini göstermektedir. GatedGNN-GRU, GatedGNN'ye kıyasla ters bir performans sergilemiştir. Bu modelin verimli sınıf için ki doğruluğu %92,1 iken verimsiz sınıf için doğruluk biraz daha düşük olmuştur. RNN-GatedGNN ve GRU-GatedGNN modelleri de her iki sınıf için %80 ila %90 arasında değişen doğruluk oranlarına ulaşmıştır. Ayrıca, aynı veri seti içinde birden fazla Pencerede modellerin CPI sınıf tahminindeki performansları, veri zaman dilimindeki küçük değişimlerin bile tahmin doğruluğunu etkileyebileceğini göstermektedir.

Pencere 3'ten itibaren veri setinde eksik kayıtlar ortaya çıkmaya başlamakta olup doğrulama ve test verileri arasında 15 haftadan fazla bir boşluk bulunmaktadır (Şekil 24). Bu durum, önerilen mekansal-zamansal modeller için ele alınacak zorlu bir senaryo olup sürekli veri eksikliği modellerin tahmin yeteneklerini olumsuz etkilemiştir. Pencere 3'te, tüm modellerde belirgin bir performans düşüşü yaşanırken GatedGNN ve GatedGNN-RNN sırası ile verimli sınıf için sadece %57,6 ve %54 doğruluk oranlarına ulaşabilmiştir.

Pencere 4'te eksik verilerin varlığına rağmen modellerin performansında doğrulama ve test verileri arasında Pencere 3'ün aksine bir boşluğun bulunmaması nedeniyle bir toparlanma gözlemlenmiştir. Buna bağlı olarak GatedGNN ve GatedGNN-RNN modelleri verimli ve verimsiz sınıflar için sırasıyla %85 ve %75'in üzerinde doğruluk oranları performanslarına ulaşmıştır.

Pencere 5 ve 6'da modeller eğitim setlerinde devam eden eksik verilere rağmen boşluğun eğitim setinde nedeniyle performansta güçlü bir toparlanma sergilemiştir (Şekil

24). GatedGNN-GRU ve RNN-GatedGNN sırasıyla Pencere 5 ve 6'da öne çıkan performansa sahip modeller olmuşlardır. Pencere 5'te GatedGNN-GRU verimli ve verimsiz sınıflar için sırasıyla %94,7 ve %91,7 doğruluk oranlarına ulaşmıştır. Pencere 6'da RNN-GatedGNN verimli sınıf için %89,5 ve verimsiz sınıf için ise %79,6 doğruluk oranlarına ulaşan performans göstermiştir. Pencere 5 ve 6'da her iki sınıf tahmini için yüksek doğruluğu koruyarak iyi performans gösteren model GatedGNN-RNN olmuştur. GatedGNN-RNN sırası ile Pencere 5 ve 6'da verimli sınıf için %86,5 ve %87,8, verimsiz sınıf için ise %93,9 ve %74,3 doğruluk oranlarına ulaşmıştır. Pencere 5 ve 6'ya dair bu bulgular eğitim setlerindeki eksik verilerin bir zorluk oluşturmalarına rağmen GatedGNN mekanizmalarına sahip seçili mekansal-zamansal modellerin her iki sınıf için de doğru tahminler sağlayabildiğini göstermektedir.

Adana veri setinin farklı pencerelerinden elde edilen bulgular modellerin eksik verilere karşı hassasiyetini özellikle eksik verilerin eğitim ve test setleri arasında büyük boşluklar oluşturduğunda öne çıkarmaktadır. Ancak bu bulgular aynı zamanda modellerin bu tür zorlu koşullara uyum sağlama ve özellikle çoğunluk sınıfı için makul bir performans sürdürme yeteneklerini de göstermektedir. Sınıf dengesizliği (Şekil 22) ve eksik veri sorunlarına (Şekil 24) rağmen, GatedGNN ve GatedGNN-RNN modelleri çoğunluk (verimli) ve azınlık sınıfını (verimsiz) sırasıyla %80'in ve %50'nin üzerinde doğruluk oranlarıyla tahmin etmeyi başarmıştır. Özellikle, Pencere 4'te gözlemlenen iyileşme kısmen doğrulama setinin test sırasına zaman dilimi açısından daha yakın olmasıyla açıklanabilir. Bu durum modellerin eksik verilerle daha iyi performans göstermesine olanak tanımıştır (Şekil 24). Ayrıca, GatedGNN-RNN modelinin hem verimsiz hem de verimli sınıflar için Pencere 5 ve 6 arasında gösterdiği tahmin kararlılığı bu modelin özellikle veri değişkenliğine karşı dirençli olduğunu göstermektedir. Model farklı pencereler ve bu pencerelerde karşılaşılan farklı koşullar altında sürekli olarak iyi performans göstermiştir. Modelin bu özelliği eksik veri ve tutarsızlıkların yaygın olduğu gerçek dünya uygulamaları için kullanım potansiyelini vurgulamaktadır. CPI tahmin performansından elde edilen öngörüler üzerine inşa edilen ve yukarıda sunulan değerlendirmeler bu modellerin Şekil 73'te verilen SPI tahmin performanslarına odaklanarak aşağıdaki bölümlerde tekrarlanmaktadır.

	GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 1 Gerçekleşen Zamanında Geride	98.4%	1.6%	95.5%	4.5%	81.7%	18.3%	98.5%	1.5%	91.3%	8.7%
	1610	26	1562	74	8707	1949	10499	157	9734	922
	83.6%	16.4%	67.1%	32.9%	51.1%	48.9%	92.6%	7.4%	67.1%	32.9%
	295	58	237	116	1559	1493	2825	227	2049	1003
Pencere 2 Gerçekleşen Zamanında Geride	99.2%	0.8%	59.8%	40.2%	92.0%	8.0%	96.2%	3.8%	95.5%	4.5%
	5174	44	286	192	4803	415	5020	198	4984	234
	94.2%	5.8%	36.0%	64.0%	72.7%	27.3%	79.8%	20.2%	82.8%	17.2%
	1063	65	253	449	820	308	900	228	934	194
Pencere 3 Gerçekleşen Zamanında Geride	85.2%	14.8%	85.1%	14.9%	96.5%	3.5%	93.6%	6.4%	60.6%	39.4%
	565	98	1774	311	2013	72	1952	133	1263	822
	56.6%	43.4%	67.5%	32.5%	84.6%	15.4%	82.5%	17.5%	63.2%	36.8%
	1272	974	1345	647	1685	307	1643	349	1258	734
En Düşük F1 Skoru Performansına Sahip Pencere										
Pencere 4 Gerçekleşen Zamanında Geride	82.0%	18.0%	76.0%	24.0%	75.8%	24.2%	81.1%	18.9%	65.6%	34.4%
	5622	1234	5212	1644	5196	1660	5558	1298	4497	2359
	61.1%	38.9%	55.1%	44.9%	56.1%	43.9%	74.3%	25.7%	48.5%	51.5%
	1893	1206	1709	1390	1740	1359	2303	796	1504	1595
Pencere 5 Gerçekleşen Zamanında Geride	54.9%	45.1%	45.3%	54.7%	58.4%	41.6%	46.4%	53.6%	50.1%	49.9%
	2143	1760	1769	2134	2278	1625	1811	2092	1954	1949
	15.7%	84.3%	9.1%	90.9%	17.4%	82.6%	11.7%	88.3%	19.1%	80.9%
	995	5340	577	5758	1101	5234	741	5594	1210	5125
Pencere 6 Gerçekleşen Zamanında Geride	73.0%	27.0%	78.9%	21.1%	86.0%	14.0%	83.9%	16.1%	83.2%	16.8%
	4231	1565	4571	1225	4987	809	4861	935	4821	975
	21.8%	78.2%	27.1%	72.9%	36.3%	63.7%	32.7%	67.3%	32.2%	67.8%
	898	3229	1118	3009	1500	2627	1351	2776	1329	2798
En Yüksek F1 Skoru Performansına Sahip Pencere										
	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında
	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen	Tahmin edilen

Şekil 73. Adana projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.

Şekil 73 SPI tahmininde GatedGNN tabanlı modellerin farklı pencereler ve değişen koşullar altında gösterdiği performansı vurgulamaktadır. İlk iki Pencerde (Pencere 1 ve 2),

veri seti tam ve eksiksiz olduğunda, modellerin güçlü performans sergilediği görülmektedir; bu durum, CPI tahmininde elde edilen sonuçlarla paralellik göstermektedir. GatedGNN, RNN-GatedGNN ve GRU-GatedGNN modelleri hem geride kalan hem de zamanında tamamlanan aktiviteleri tahmin etmede yüksek doğruluk oranlarına ulaşarak bu pencerelerde en iyi performans gösteren modeller olarak öne çıkmaktadır.

Pencere 1'de GatedGNN ve RNN-GatedGNN modelleri geride kalan aktiviteler için %98,0'in üzerinde doğruluk oranlarına ulaşırken zamanında tamamlanan aktiviteler için çok düşük doğruluk oranları elde etmişlerdir. GRU-GatedGNN sınıflar arasında biraz daha dengeli bir performans sergileyerek geride kalan aktiviteler için %91,3 zamanında tamamlanan aktiviteler için ise %32,9 doğruluk oranına ulaşmıştır. İlginç bir şekilde GatedGNN-GRU, Şekil 72'de verilen CPI sonuçlarında onun için gözlemlenen eğilime benzer şekilde SPI sınıf tahmini için de ters bir eğilim göstermiştir. Bu model geride kalan aktiviteler için diğer modellerden daha düşük %81,7 doğruluk oranı elde ederken zamanında tamamlanan aktiviteler için diğer modellerden daha yüksek bir doğruluk oranı olan %48,9'a ulaşmıştır.

CPI tahminine (Şekil 72) kıyasla, GatedGNN, RNN-GatedGNN ve GRU-GatedGNN modelleri Pencere 2'de zamanında tamamlanan aktiviteleri tahmin etmede düşük performans göstermişlerdir (%5,8, %20,2 ve %17,2) ancak geride kalan aktiviteleri tahmin etmede %95,0'in üzerinde doğruluk oranları elde etmişlerdir. GatedGNN-RNN ise geride kalan aktiviteler için %59,8 zamanında tamamlanan aktiviteler için ise %64,0 doğruluk oranına ulaşmıştır.

Şekil 73'te Adana projesi veri setinde farklı pencereler boyunca modeller için gösterilen SPI sınıf tahmini performansları arasında modellerin en düşük performans gösterdiği Pencere, 3. Pencere olmuştur. CPI tahmin sonuçlarının (Şekil 72) aksine modeller eksik kayıtların (Şekil 24) oluşturduğu zorlu senaryoya rağmen geride kalan sınıf tahminini iyileştirirken az temsil edilen zamanında tamamlanan (Şekil 22) sınıf üzerinde düşük performanslar göstermelerini sürdürmüşlerdir. GatedGNN geride kalan aktiviteler için %85,2 zamanında tamamlanan aktiviteler için ise %43,4 doğruluk oranlarına ulaşmıştır. GatedGNN-RNN biraz daha iyi performans göstererek geride kalan aktiviteler için %85,1 zamanında tamamlanan aktiviteler için ise %32,5 doğruluk oranına ulaşmıştır.

Pencere 6 modellerin her iki SPI sınıf tahmini için de önemli bir doğruluk artışı ile en yüksek performans gösterdikleri Pencere olarak öne çıkmaktadır. GatedGNN geride kalan aktiviteler için %73 zamanında tamamlanan aktiviteler için ise %78,2 doğruluk oranlarına

ulaşarak tüm pencereler arasında en iyi performansını sergilemiştir. GatedGNN-RNN geride kalan aktiviteler için %78,9 ve zamanında tamamlanan aktiviteler için %72,9 doğruluk oranlarına ulaşmıştır. GRU-GatedGNN geride kalan aktiviteler için %83,9 doğruluk oranına ulaşırken bu doğruluk oranı zamanında tamamlanan aktiviteler için %67,3 olmuştur.

Adana veri setinin elde edilen ilerleme raporlarına bağlı proje ilerleme durumlarının temsil edildiği farklı pencereler boyunca hem CPI hem de SPI tahmin modelleri, eksik verilere karşı duyarlılık göstermiştir, ancak SPI modelleri, özellikle zamanında tamamlanan aktiviteleri tahmin etmede veri setindeki boşlukların etkilerine karşı daha savunmasız görünmektedir. SPI modelleri genel olarak iki sınıf (zamanında tamamlanan vs. geride kalan) arasında daha belirgin bir performans farkı gösterirken, CPI modelleri (verimli vs. verimsiz) sınıflar arasında daha dengeli bir performans sergilemektedir. Bu durum, özellikle eksik verilerin bulunduğu pencerelerde belirgin olup modellerin SPI tahmin performanslarının veri setinde veri boşlukları varlığında performans bozulmasına daha yatkın olabileceğini düşündürmektedir. GatedGNN-RNN hem CPI hem de SPI tahmin görevleri için farklı pencerelerde yüksek doğruluk oranlarına ulaşarak en tutarlı ve güvenilir modellerden biri olarak öne çıkmaktadır. GatedGNN-GRU özellikle en yüksek performans gösterilen pencerelerde iyi performans sergilemektedir ancak veri yapısına bağlı olarak performansında daha büyük dalgalanmalar görülmektedir.

RNN ve GRU mekanizmaları ile birleştirilmiş ve birleştirilmemiş GatedGNN modellerinin Bursa veri setinin temsil edildiği farklı pencereler boyunca CPI ve SPI sınıf tahminlerinde gösterdikleri performansları sırası ile Şekil 74 ve 75'te verilmektedir.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN		
Pencere 1	Gerçekleşen	Verimsiz	93.6%	6.4%	92.1%	7.9%	94.1%	5.9%	92.4%	7.6%	91.8%	8.2%
	Verimli	16301	1123	16046	1378	16393	1031	16107	1317	15998	1426	
	Gerçekleşen	Verimli	45.7%	54.3%	34.3%	65.7%	39.1%	60.9%	31.5%	68.5%	40.3%	59.7%
			3329	3956	2497	4788	2848	4437	2295	4990	2937	4348
Pencere 2	Gerçekleşen	Verimsiz	94.7%	5.3%	93.4%	6.6%	94.2%	5.8%	96.0%	4.0%	94.1%	5.9%
	Verimli	10226	568	10085	709	10168	626	10363	431	10154	640	
	Gerçekleşen	Verimli	25.0%	75.0%	22.8%	77.2%	21.7%	78.3%	26.1%	73.9%	23.6%	76.4%
			1234	3710	1129	3815	1071	3873	1288	3656	1165	3779
Pencere 3	Gerçekleşen	Verimsiz	95.6%	4.4%	98.4%	1.6%	99.0%	1.0%	99.4%	0.6%	94.9%	5.1%
	Verimli	13043	600	13420	223	13512	131	13565	78	12948	695	
	Gerçekleşen	Verimli	23.2%	76.8%	25.6%	74.4%	33.4%	66.6%	33.0%	67.0%	22.8%	77.2%
			1142	3783	1262	3663	1643	3282	1623	3302	1124	3801
En Yüksek F1 Skoru Performansına Sahip Pencere												
Pencere 4	Gerçekleşen	Verimsiz	95.8%	4.2%	93.2%	6.8%	94.6%	5.4%	95.8%	4.2%	94.9%	5.1%
	Verimli	12789	557	12445	901	12620	726	12791	555	12667	679	
	Gerçekleşen	Verimli	37.1%	62.9%	25.9%	74.1%	32.5%	67.5%	34.2%	65.8%	29.8%	70.2%
			1578	2672	1102	3148	1381	2869	1452	2798	1267	2983
Pencere 5	Gerçekleşen	Verimsiz	91.0%	9.0%	91.4%	8.6%	92.7%	7.3%	90.2%	9.8%	85.2%	14.8%
	Verimli	7574	750	7605	719	7719	605	7512	812	7088	1236	
	Gerçekleşen	Verimli	28.8%	71.2%	32.0%	68.0%	39.3%	60.7%	37.8%	62.2%	23.6%	76.4%
			841	2079	934	1986	1147	1773	1103	1817	689	2231
Pencere 6	Gerçekleşen	Verimsiz	94.5%	5.5%	95.0%	5.0%	91.6%	8.4%	98.1%	1.9%	96.2%	3.8%
	Verimli	9907	576	9957	526	9602	881	10286	197	10086	397	
	Gerçekleşen	Verimli	38.4%	61.6%	29.9%	70.1%	30.7%	69.3%	53.2%	46.8%	58.1%	41.9%
			1722	2757	1337	3142	1375	3104	2382	2097	2601	1878
Verimsiz Verimli												
Tahmin edilen												
En Düşük F1 Skoru Performansına Sahip Pencere												

Şekil 74. Bursa projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.

Bursa veri seti sekiz farklı Pencere boyunca temsil edilmiş olup Şekil 74 ve 75'te bu sekiz Pencerenin içlerinde en iyi ve kötü performansların sergilendiği pencerelerde olmak

üzere altı Pencere boyunca GatedGNN tabanlı mimarilerin CPI ve SPI tahmin performansı değerlendirmesini sunmaktadır. Veri seti verimli aktiviteleri çoğunlukta olduğu güçlü bir sınıf dengesizliği sergilemektedir (Şekil 22): 184392 verimli aktivite ($CPI = 1$) ve 83371 verimsiz aktivite ($CPI = 0$). Bu dengesizliğe rağmen modeller Şekil 74'te verilen çeşitli pencerelerde çoğunlukla azınlık olan verimsiz sınıfı tahmin etmede daha yüksek doğruluk elde etmiştir.

Şekil 74'te verilen Pencere 3 sekiz farklı Pencere boyunca incelenen Bursa veri setinde CPI sınıf tahmini görevinde tüm modellerin en yüksek performans gösterdiği Pencere olmuştur. GatedGNN verimli ve verimsiz sınıflar için sırasıyla %76,8 ve %95,6 doğruluk oranlarına ulaşarak 17000'in üzerinde doğru tahmin gerçekleştirmiştir. GatedGNN-RNN verimli ve verimsiz sınıf tahmin performansı birlikte değerlendirildiğinde en iyi F1 skor performansını elde ederek verimli ve verimsiz kayıtların sırasıyla %74,4 ve %98,4'ünü doğru bir şekilde tahmin etmiştir. GatedGNN-GRU ve RNN-GatedGNN verimsiz sınıf tahmininde sırasıyla %99 ve %99,4 doğruluk oranlarına ulaşarak öne çıkarken verimli sınıf için ise sırasıyla %66,6 ve %67 doğruluk oranlarına ulaşmışlardır. GRU-GatedGNN verimli ve verimsiz sınıflar için sırasıyla %77,2 ve %94,9 doğruluk oranlarıyla iyi bir performans sergilemiştir. Pencere 3'te grafiksel olarak verilen sonuçlar modellerin verimli aktivitelerin hakim olduğu bir veri setinde bile verimsiz sınıfı etkili bir şekilde tahmin edebilme yeteneklerini ortaya koymaktadır.

Genel olarak önerilen mekansal-zamansal modellerin tüm pencerelerde CPI sınıfları arasındaki tahmin performans farkları tutarlı kalmıştır. Örneğin, Pencere 4'te modeller güçlü performanslarını korumuş ancak hafif düşüşler göstermiştir. Tüm modeller bu pencerede verimsiz sınıfı tahmin etmede %93'ün üzerinde doğruluk oranlarına ulaşırken verimli sınıf için doğruluk oranları %62,9 ile %77,10 arasında değişmiştir. GRU-GatedGNN verimli ve verimsiz sınıflar için %70,2 ve %94,9 doğruluk oranlarıyla en iyi F1 skor performansını elde etmiştir.

Şekil 74'te Pencere 6 tüm pencereler arasında modellerin CPI sınıfı tahmin görevinde sergiledikleri en düşük performansları temsil etmektedir. Önerilen mekansal-zamansal modellerin tamamı bu pencerede verimsiz sınıfı tahmin etmede %91'in üzerinde doğruluk oranlarına ulaşırken verimli sınıf için ise değişen performanslar göstermişlerdir. GatedGNN-RNN verimsiz sınıf için %95 doğruluk oranıyla 9957 doğru tahmin yaparken verimli sınıf için ise %70,1 doğruluk oranıyla 3142 doğru tahmin gerçekleştirmiştir.

Modellerin Bursa veri setindeki performanslarıyla Adana veri setindeki performansları karşılaştırıldığında ilginç farklılıklar gözlemlenmiştir. İlk olarak, modeller büyük ölçüde verimli aktivitelerden oluşmasına rağmen Bursa veri setinde azınlık olan verimsiz sınıfı tahmin etmede daha iyi performans göstermiştir. Bu durum modellerin eksik veri ve sınıf dengesizliği ile karşılaştığında sık sık zorlandığı Adana veri setiyle tezat oluşturmaktadır. Ayrıca, Bursa veri setinde pencereler boyunca özellikle verimsiz sınıf için performans nispeten istikrarlı kalırken Adana'da eksik verilerin bulunduğu pencerelerde modellerin performansında daha belirgin düşüşler yaşanmıştır. Bu durum, Bursa veri setindeki daha tutarlı kayıt tutma ve daha büyük veri boyutunun, modellerin daha yüksek ve daha istikrarlı doğruluk seviyelerini korumasına olanak sağladığını düşündürmektedir. GatedGNN-RNN yine en iyi performansı gösteren modellerden biri olarak öne çıkmış ve sınıf dengesizliğine rağmen pencereler boyunca yüksek doğruluğu korumuştur. Diğer modeller de farklı pencerelerde iyi performanslar sergilemişler ancak performanslarındaki düşüş gerçek dünya inşaat projelerindeki değişken veri koşullarında dayanıklılıklarının az olacağına işaret etmiştir.

Şekil 75, Bursa veri setindeki farklı pencerelerde GatedGNN tabanlı mimariler kullanan SPI tahmin modellerinin değerlendirmesini sunmakta ve en iyi ile en düşük performans gösteren pencerelere vurgu yapmaktadır.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 1	Gerçekleşen Zamanında Geride	42.8%	57.2%	57.8%	42.2%	49.2%	50.8%	41.0%	59.0%	34.8%	65.2%
		4060	5433	5486	4007	4674	4819	3889	5604	3299	6194
		11.9%	88.1%	17.8%	82.2%	16.6%	83.4%	12.1%	87.9%	9.7%	90.3%
		2287	16938	3417	15808	3183	16042	2334	16891	1872	17353
En Düşük F1 Skoru Performansına Sahip Pencere											
Pencere 2	Gerçekleşen Zamanında Geride	59.3%	40.7%	66.5%	33.5%	59.2%	40.8%	54.1%	45.9%	51.6%	48.4%
		3487	2394	3911	1970	3479	2402	3179	2702	3032	2849
		21.3%	78.7%	19.2%	80.8%	20.5%	79.5%	14.4%	85.6%	14.1%	85.9%
		2807	10350	2524	10633	2693	10464	1894	11263	1857	11300
Pencere 3	Gerçekleşen Zamanında Geride	56.2%	43.8%	66.2%	33.8%	59.3%	40.7%	50.1%	49.9%	53.6%	46.4%
		4231	3297	4984	2544	4462	3066	3773	3755	4032	3496
		17.1%	82.9%	14.2%	85.8%	14.1%	85.9%	12.8%	87.2%	14.4%	85.6%
		2508	12189	2091	12606	2076	12621	1883	12814	2111	12586
Pencere 4	Gerçekleşen Zamanında Geride	50.2%	49.8%	57.5%	42.5%	57.8%	42.2%	44.4%	55.6%	51.3%	48.7%
		2931	2910	3359	2482	3376	2465	2594	3247	2995	2846
		5.8%	94.2%	4.6%	95.4%	6.3%	93.7%	5.3%	94.7%	7.9%	92.1%
		838	13688	663	13863	917	13609	764	13762	1148	13378
Pencere 5	Gerçekleşen Zamanında Geride	57.3%	42.7%	66.7%	33.3%	55.7%	44.3%	66.6%	33.4%	65.0%	35.0%
		1916	1426	2230	1112	1861	1481	2226	1116	2171	1171
		6.8%	93.2%	8.8%	91.2%	5.8%	94.2%	9.8%	90.2%	11.0%	89.0%
		653	8921	838	8736	558	9016	937	8637	1049	8525
Pencere 9	Gerçekleşen Zamanında Geride	65.9%	34.1%	71.6%	28.4%	69.6%	30.4%	68.0%	32.0%	64.3%	35.7%
		2084	1080	2264	900	2203	961	2150	1014	2033	1131
		7.4%	92.6%	6.5%	93.5%	8.6%	91.4%	8.3%	91.7%	6.9%	93.1%
		633	7956	556	8033	736	7853	710	7879	596	7993
		Geride	Zamanında Tahmin edilen	Geride	Zamanında Tahmin edilen	Geride	Zamanında Tahmin edilen	Geride	Zamanında Tahmin edilen	Geride	Zamanında Tahmin edilen
En Yüksek F1 Skoru Performansına Sahip Pencere											

Şekil 75. Bursa projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.

Şekil 75'te Bursa veri setinde gecikmiş aktivitelerin (geride) büyük bir ağırlığa sahip olarak sınıf dengesizliğine oluşturmasına rağmen modellerin zamanında tamamlanan

aktiviteleri dikkat çekici bir doğrulukla tahmin etmeyi başarmış oldukları görülmektedir. Bursa veri setinden elde edilen bulgular GatedGNN-RNN'nin büyük veri setlerinde sınıf dengesizliği sorununu ele almada öne çıkan model olduğu göstermektedir. Gecikmiş etiketlere önemli bir eğilim olmasına rağmen bu modeller daha az sık karşılaşılan zamanında tamamlanan aktiviteleri (zamanında) de dikkate değer bir doğrulukla tahmin etmeyi başarmıştır. Bu sonuç özellikle Pencere 4'te dikkat çekicidir; burada GatedGNN-RNN zamanında tamamlanan aktiviteleri belirleme konusunda olağanüstü bir performans sergilemiştir (L. Zhou & Wang, 2024).

Araştırmalar büyük verilerde sınıf dengesizliği ile başa çıkmanın ML'de süregelen bir zorluk olduğunu ve bu durumun zaman açısından kritik tahmin görevleri üzerinde önemli etkileri olduğunu göstermektedir. Bu tür durumlarda GatedGNN-RNN gibi modeller sınıf dengesizliği içeren veri setindeki tahmin zorluğunu hafifletmek için kullanılabilecek stratejilere dair değerli bilgiler sunmaktadır. Çünkü RNN'nin GNN mimarileri ile entegrasyonunun dinamik gerçek dünya veri setlerinde tahmin doğruluğunu önemli ölçüde artırabileceği belirtilmektedir (L. Zhou & Wang, 2024).

Şekil 76 ve Şekil 77, Elazığ projesinde eğitilen modellerin en yüksek ve en düşük performans gösteren pencerelerinde GatedGNN modellerinin RNN ve GRU mekanizmaları ve bu mekanizmalar olmaksızın Elazığ veri setinin farklı pencerelerinde elde ettiği performansları CPI sınıfı tahmin görevi için Şekil 76'da SPI sınıfı tahmin görevi için ise Şekil 77'da verilmektedir.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN		
Pencere 1	Gerçekleşen	Verimsiz	72.1%	27.9%	83.5%	16.5%	82.4%	17.6%	79.6%	20.4%	44.4%	55.6%
			7804	3024	9045	1783	8918	1910	8619	2209	4810	6018
	Verimli	Tahmin edilen	10.2%	89.8%	14.0%	86.0%	12.9%	87.1%	10.7%	89.3%	34.1%	65.9%
			1498	13156	2055	12599	1888	12766	1563	13091	4997	9657
Pencere 2	Gerçekleşen	Verimsiz	74.9%	25.1%	75.1%	24.9%	82.0%	18.0%	65.7%	34.3%	64.3%	35.7%
			5983	2005	6000	1988	6551	1437	5250	2738	5140	2848
	Verimli	Tahmin edilen	10.0%	90.0%	10.3%	89.7%	14.6%	85.4%	6.2%	93.8%	11.4%	88.6%
			977	8812	1004	8785	1429	8360	610	9179	1117	8672
Pencere 3	Gerçekleşen	Verimsiz	75.8%	24.2%	84.7%	15.3%	80.2%	19.8%	91.5%	8.5%	68.1%	31.9%
			2234	714	2496	452	2365	583	2697	251	2009	939
	Verimli	Tahmin edilen	6.1%	93.9%	14.9%	85.1%	8.1%	91.9%	26.9%	73.1%	4.5%	95.5%
			260	3980	630	3610	345	3895	1140	3100	189	4051
Pencere 4	Gerçekleşen	Verimsiz	80.9%	19.1%	49.5%	50.5%	52.1%	47.9%	61.4%	38.6%	44.6%	55.4%
			1402	330	857	875	902	830	1063	669	773	959
	Verimli	Tahmin edilen	27.3%	72.7%	24.3%	75.7%	20.4%	79.6%	9.6%	90.4%	13.7%	86.3%
			543	1447	483	1507	405	1585	191	1799	272	1718
En Düşük F1 Skoru Performansına Sahip Pencere												
Pencere 5	Gerçekleşen	Verimsiz	84.8%	15.2%	81.4%	18.6%	52.9%	47.1%	82.6%	17.4%	76.7%	23.3%
			1850	332	1777	405	1155	1027	1803	379	1673	509
	Verimli	Tahmin edilen	6.3%	93.7%	13.8%	86.2%	2.3%	97.7%	7.0%	93.0%	3.3%	96.7%
			161	2385	351	2195	59	2487	179	2367	83	2463
En Yüksek F1 Skoru Performansına Sahip Pencere												
Pencere 6	Gerçekleşen	Verimsiz	87.3%	12.7%	89.8%	10.2%	67.3%	32.7%	90.5%	9.5%	79.8%	20.2%
			2514	366	2587	293	1938	942	2607	273	2299	581
	Verimli	Tahmin edilen	12.9%	87.1%	34.3%	65.7%	20.3%	79.7%	21.9%	78.1%	11.5%	88.5%
			582	3921	1546	2957	916	3587	986	3517	516	3987
		Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	
		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		

Şekil 76. Elazığ projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.

Elazığ veri seti dokuz farklı pencere boyunca temsil edilmiş olup Şekil 76 ve 77’de bu dokuz pencerenin içlerinde en iyi ve kötü performansların sergilendiği pencerelerde olmak

üzere altı pencere boyunca GatedGNN tabanlı mimarilerin CPI ve SPI tahmin performansı değerlendirmesini sunmaktadır. Bursa veri setinde gözlemlenmiş olan hem CPI hem de SPI sınıflarının dengesiz yapısı daha az kayıt bulunmasına rağmen büyük bir veri seti olarak kabul edilen Elazığ veri setinde de gözlenilmiştir. Pencere 1'de GatedGNN-RNN ve GatedGNN-GRU her iki CPI sınıf tahmini için de başarılı bir performans göstermiştir.

Pencere 2'de GatedGNN-GRU en iyi performansı sergileyen model olarak öne çıkmış ve verimli sınıf için %85,4 verimsiz sınıf için ise %82 doğruluk oranına ulaşmıştır.

Pencere 3'te GatedGNN-GRU verimli sınıf için %91,9 ve verimsiz sınıf için %80,2 doğruluk oranıyla üstün performans sergilemeye devam etmiştir. Benzer şekilde, GatedGNN-RNN %84,7 doğruluk oranı ile verimli sınıfta, %85,1 doğruluk oranı ile de verimsiz sınıfta başarılı bir performans göstermiştir. GatedGNN-RNN'nin verimli sınıfta gösterdiği performans düşüşünün GatedGNN-GRU'nun bu pencerede verimli sınıfı daha iyi yönettiğini düşündürmektedir.

Pencere 4 haftada 5000'den fazla aktivite kaydına sahip Bursa veri setinin eğitim seti, test seti ve doğrulama setinde 1000'den az aktivite kaydının bulunduğu benzersiz bir senaryoyu (Şekil 22) temsil etmektedir. Eğitim ve test veri setleri arasındaki bu fark inşaat projelerinde yoğun aktivite dönemlerinin ardından finansal veya operasyonel değişikliklerden kaynaklanan durgunlukların gözlenildiği dönemlerde görülebilir. Bu zorluğa rağmen GatedGNN dikkate değer bir performans sergileyerek verimli sınıf için %72,7 verimsiz sınıf için ise %80,9 doğruluk oranlarına ulaşmıştır. Eğitim ve test veri dağılımları arasındaki belirgin farklılığa rağmen elde edilen bu sonuçlar GatedGNN'nin veri dağılımında önemli değişikliklerle karşılaştığında bile iyi genelleme yapabildiğini göstermektedir.

Bu durum, gelecekteki çalışmalar için önemli bir soruyu gündeme getirmektedir: Modeller eğitim verileri ile gerçek dağıtım koşulları arasındaki benzerliğe dayanarak en iyi yaklaşımı otomatik olarak nasıl ayarlayabilir veya seçebilir? Bu tür durumlarda projede ani bir duraklama yaşanırsa, modelin eğitim sırasında daha aktif dönemlere güvenmek yerine benzer durumları temsil eden verilere odaklanmasının potansiyel olarak fayda sağlayabileceği düşünülebilir. Bu da gerçek zamanlı veri koşullarına dayalı adaptif model dağıtım stratejilerinin potansiyelini ortaya koymaktadır.

Pencere 5'te, GatedGNN bir kez daha öne çıkarak verimsiz sınıf için %84,8 verimli sınıf için ise %93,7 doğruluk oranlarına ulaşmıştır. Bu pencere genel olarak modellerin CPI

sınıf tahmininde sergiledikleri en iyi performansları göstermekte olup GatedGNN'nin bu senaryoda sınıf dengesizliğini etkili bir şekilde ele alabilmiştir.

	GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 1 Gerçekleşen Zamanında Geride	91.2%	8.8%	100.0%	0.0%	82.6%	17.4%	100.0%	0.0%	79.7%	20.3%
	7388	711	14670	0	12113	2557	14666	4	11689	2981
	20.8%	79.2%	100.0%	0.0%	15.9%	84.1%	99.9%	0.1%	13.5%	86.5%
	1155	4406	13164	0	2096	11068	13154	10	1780	11384
En Düşük F1 Skoru Performansına Sahip Pencere										
Pencere 2 Gerçekleşen Zamanında Geride	88.7%	11.3%	86.4%	13.6%	89.8%	10.2%	96.6%	3.4%	89.9%	10.1%
	10468	1333	10200	1601	10602	1199	11396	405	10614	1187
	25.4%	74.6%	57.9%	42.1%	16.5%	83.5%	90.4%	9.6%	18.5%	81.5%
	2221	6516	5056	3681	1438	7299	7902	835	1618	7119
Pencere 3 Gerçekleşen Zamanında Geride	94.7%	5.3%	68.8%	31.2%	91.9%	8.1%	69.0%	31.0%	95.1%	4.9%
	5074	286	3689	1671	4926	434	3699	1661	5097	263
	31.9%	68.1%	30.3%	69.7%	19.2%	80.8%	33.2%	66.8%	24.2%	75.8%
	974	2081	926	2129	587	2468	1015	2040	738	2317
En Yüksek F1 Skoru Performansına Sahip Pencere										
Pencere 4 Gerçekleşen Zamanında Geride	87.8%	12.2%	99.7%	0.3%	91.1%	8.9%	99.6%	0.4%	96.7%	3.3%
	2377	329	2698	8	2466	240	2696	10	2618	88
	45.5%	54.5%	70.2%	29.8%	53.9%	46.1%	68.2%	31.8%	57.1%	42.9%
	474	567	731	310	561	480	710	331	594	447
Pencere 5 Gerçekleşen Zamanında Geride	92.9%	7.1%	96.1%	3.9%	91.7%	8.3%	91.7%	8.3%	93.2%	6.8%
	6163	472	3245	133	3099	279	3097	281	3149	229
	42.4%	57.6%	69.1%	30.9%	59.7%	40.3%	63.6%	36.4%	61.0%	39.0%
	1472	1998	990	443	856	577	912	521	874	559
Pencere 6 Gerçekleşen Zamanında Geride	87.2%	12.8%	98.1%	1.9%	82.8%	17.2%	95.2%	4.8%	86.2%	13.8%
	4069	597	4874	96	4114	856	4729	241	4282	688
	21.5%	78.5%	65.5%	34.5%	50.0%	50.0%	66.9%	33.1%	48.8%	51.2%
	694	2534	1799	947	1372	1374	1838	908	1339	1407
	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında	Geride	Zamanında
	Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen	

Şekil 77. Elazığ projesinin farklı pencerelerinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.

Şekil 77'de Elazığ projesinde GatedGNN tabanlı mimarilerin çeşitli pencereler boyunca SPI tahminine yönelik performans göstergeleri sunulmaktadır. Modellerin tahmin görevlerinde en kötü performans metriklerine sahip olduğu Pencere 1'de, GatedGNN-GRU gecikmiş sınıf için %82,6 ve zamanında tamamlanan sınıf için %84,1 ile dengeli bir performans göstermiştir. GRU-GatedGNN ise zamanında tamamlanan sınıf için %86,5 doğrulukla öne çıkarak zamanında tamamlanan aktivitelerin tahmininde etkili olduğunu göstermiştir.

Pencere 3'te GRU-GatedGNN gecikmiş tahminlerde etkileyici bir şekilde %95,1 doğruluk oranına sahip olmuştur. GatedGNN-GRU ise gecikmiş tahminlerde %91,9 ve zamanında tamamlanan tahminlerde %80,8 ile her iki sınıf tahmininde dengeli bir doğruluk oranına sahip olarak öne çıkmıştır. Pencere 3 modellerin tahmin görevlerinde en iyi performans metriklerine sahip olduğu penceredir.

Elazığ veri setinde genel olarak GatedGNN mimarileri farklı pencereler boyunca gecikmiş ve zamanında tamamlanan sınıfların tahmininde kabul edilebilir bir performans yeteneği sergilemişlerdir. Ancak bu yetenek belirli model konfigürasyonlarına ve pencerelere göre değişkenlik göstermiştir. GRU tabanlı kombinasyonların öne çıkma eğilimi bu modellerin sınıf dağılımlarının dalgalandığı ve karmaşık zamansal dinamiklerin olduğu veri setlerinde uygun olduğunu düşündürmektedir. Bunun muhtemel nedeninin bu modellerin ardışık bağımlılıkları daha etkili bir şekilde yakalayabilme yeteneklerinin olduğu düşünülmektedir. Pencereler arasındaki performans farklılıkları model ayarlarının yapılması ve projeye özgü veri setinin belirli aşamaları veya özelliklerine göre mimarinin ya da eğitim yaklaşımının özelleştirilmesi gerekliliğini vurgulamaktadır. Bu adaptif yaklaşım, özellikle veri seti özelliklerinin ve gereksinimlerinin zamanla önemli ölçüde değiştiği gerçek dünya senaryolarında tahmin doğruluğunu optimize etmeye yardımcı olabilir.

Şekil 78 ve 79 RNN ve GRU mekanizmaları ile birleştirilmiş ve bu mekanizmalar olmadan çalışan GatedGNN modellerinin Yozgat projesi için dikkate alınan iki farklı pencerede sırası ile CPI ve SPI sınıfı tahmin performanslarını göstermektedir. Yozgat projesi veri seti iki farklı pencere boyunca bütünüyle temsil edilebilinmiştir.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 1	Gerçekleşen	Verimsiz		Verimsiz		Verimsiz		Verimsiz		Verimsiz	
	Verimli	Verimli		Verimli		Verimli		Verimli		Verimli	
	Gerçekleşen	Verimsiz		Verimsiz		Verimsiz		Verimsiz		Verimsiz	
	Verimli	Verimli		Verimli		Verimli		Verimli		Verimli	
		Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli
		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen	

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 2	Gerçekleşen	Verimsiz		Verimsiz		Verimsiz		Verimsiz		Verimsiz	
	Verimli	Verimli		Verimli		Verimli		Verimli		Verimli	
	Gerçekleşen	Verimsiz		Verimsiz		Verimsiz		Verimsiz		Verimsiz	
	Verimli	Verimli		Verimli		Verimli		Verimli		Verimli	
		Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli	Verimsiz	Verimli
		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen		Tahmin edilen	

Şekil 78. Yozgat projesinin iki farklı penceresinde GatedGNN tabanlı mekansal-zamansal modellerin CPI sınıf tahmin performansları.

Şekil 78'de modellerin CPI tahminlerine yönelik olarak verilen performans analizi göstergeleri farklı pencereler boyunca modellerin değişen başarı seviyelerini vurgulamaktadır. Pencere 1'de, RNN-GatedGNN verimsiz sınıf tahminlerinde %61,7 ile GRU-GatedGNN ise verimli sınıf tahminlerinde %95,3 ile en iyi performansı sergileyen modeller olmuşlardır. Hem verimli hem de verimsiz tahminlerdeki doğruluk oranları birlikte değerlendirildiğinde bu pencerede öne çıkan model RNN-GatedGNN olmaktadır.

Pencere1'de verimli sınıf tahminlerinde GRU-GatedGNN için gözlemlenen performans başarısı Pencere 2'de de devam etmiştir. Ancak hem verimli hem de verimsiz tahminlerdeki doğruluk oranları birlikte değerlendirildiğinde bu pencerede Pencere 1'in aksine öne çıkan model GatedGNN olmuştur. Bu sonuçlar, GRU bileşenleriyle entegre edilen modellerin (GatedGNN-GRU veya GRU-GatedGNN) verimli sınıfları tahmin etmede daha iyi performans gösterme eğiliminde olduğunu ve bu modellerin veri setinin zorluklarını yansıtan senaryoları yönetmede güçlü olduğunu göstermektedir.

		GatedGNN		GatedGNN-RNN		GatedGNN-GRU		RNN-GatedGNN		GRU-GatedGNN	
Pencere 1	Geride	53.1%	46.9%	64.4%	35.6%	53.2%	46.8%	55.8%	44.2%	49.5%	50.5%
	Gerçekleşen	1254	1108	1520	842	1256	1106	1317	1045	1170	1192
	Zamanında	23.5%	76.5%	32.9%	67.1%	23.2%	76.8%	24.9%	75.1%	19.7%	80.3%
	Tahmin edilen	904	2950	1267	2587	893	2961	959	2895	760	3094
Pencere 2	Geride	39.4%	60.6%	45.9%	54.1%	32.8%	67.2%	36.8%	63.2%	29.1%	70.9%
	Gerçekleşen	994	1532	1160	1366	828	1698	930	1596	736	1790
	Zamanında	33.0%	67.0%	32.7%	67.3%	22.0%	78.0%	23.6%	76.4%	23.7%	76.3%
	Tahmin edilen	2013	4087	1993	4107	1341	4759	1438	4662	1447	4653

Şekil 79. Yozgat projesinin iki farklı penceresinde GatedGNN tabanlı mekansal-zamansal modellerin SPI sınıf tahmin performansları.

Yozgat veri setinin iki farklı penceresinde GatedGNN tabanlı modellerin SPI sınıfı tahmin görevlerinde sergiledikleri performanslarını gösteren Şekil 79'a göre modeller SPI sınıf tahmini görevinde, özellikle gecikmiş aktivitelerin tahmininde farklı zorluklarla karşılaşmışlardır. Pencere 1'de GatedGNN ve GatedGNN-GRU gecikmiş sınıf tahminlerinde benzer performans göstermiş ancak zamanında tamamlanan tahminlerde GatedGNN-GRU biraz daha iyi performans sergilemiştir. GatedGNN-RNN gecikmiş aktiviteleri %64,4 doğrulukla tahmin etmede daha güçlü bir yetenek göstermiş ancak zamanında sınıfı tahminlerde daha düşük bir performans sergilemiştir. GRU-GatedGNN ise zamanında tamamlanan aktiviteleri tahmin etmede üstün bir performans sergileyerek öne çıkmıştır.

Pencere 2'de tüm modellerde gecikmiş tahminler için performans düşüşü gözlemlenmiş ve hiçbir model %46 doğruluk oranını aşamamıştır. Ancak, zamanında tamamlanan tahminler için tüm modeller %67'nin üzerinde bir doğruluk oranı sergilemiş olup bu durum Pencere 2'de modellerin olumlu sonuçları etkili bir şekilde tahmin etme eğiliminde olduklarını göstermektedir.

Yozgat veri setinde mekansal-zamansal modellerin sınıf tahmin performansları, modellerin veri setlerinde daha az sıklıkla görülen olumsuz sınıfları ele almak için bu yönde geliştirilmiş tekniklere ihtiyaç duyduklarını göstermiştir.


Mekansal-zamansal modellerin performansları Adana, Bursa, Elazığ ve Yozgat illerinde gerçekleştirilen dört yapım projesinden elde edilen veri setlerinin özelliklerinden etkilenmiştir. Veri setleri boyut, tamlik ve sınıf dengesizliği açısından farklılık göstermiş ve bu da doğrudan model doğruluğunu etkilemiştir. Elazığ ve Bursa veri setleri en eksiksiz veri setleri olup modellerin CPI ve SPI tahminlerinde yüksek doğruluk elde etmelerini sağlamıştır. Bu veri setleri kayda değer eksik veri olmadan büyük hacimli kayıtlar sunarak modellerin ideal bir senaryoda en iyi şekilde performans göstermesini simüle etmiştir. Bu durumlarda modeller inşaat ilerlemesini yüksek doğrulukla tahmin etme potansiyellerini göstererek proje yönetiminde karar alma süreci için kullanılabilir güvenilirlikte olduklarını göstermişlerdir. Ancak Adana ve Yozgat veri setleri modellerin bu veri setlerindeki veri eksikliği, kayıt boşlukları gibi zorluklarla başa çıkabilme yeteneklerini ortaya koymuştur. Örneğin, Adana veri setinde özellikle aktivite takibi ve performans ölçümlerinde önemli miktarda eksik kayıt bulunmaktaydı; bu da model eğitimi, değerlendirme ve test süreçlerinde zorluklar yaratmıştır. Bu durum mekansal-zamansal modellerde orta düzeyde bir doğruluğa yol açmış ve veri boşlukları modellerin projenin tam zamansal ve mekansal dinamiklerini yakalama yeteneğini engellemiştir. Yozgat projesi veri seti daha az eksik kayıt içermesine rağmen daha küçük bir aktivite dizisine sahipti; bu da zamansal modellerin etkinliğini azaltmıştır. Sınırlı veri seti GNN tabanlı modellerin öğrenme kapasitesini kısıtlamış ve performanslarını Elazığ ve Bursa veri setleri gibi daha eksiksiz veri setlerine kıyasla olumsuz etkilemiştir.

Bu sorunu çözmek amacıyla çalışmada GAN ve VAE gibi üretici ML modelleri kullanılarak hibrit veri setleri oluşturulmaya yönelik çabalar gösterilmiş olsa da sonuçlar orijinal veri setleri üzerinde eğitilen mekansal-zamansal modellerin performansını aşamamıştır. Veri setlerinin daha küçük alt kümelerine uygulandığında VAE'ler bazı umut verici sonuçlar göstermiştir. Örneğin, GAT'nin tahmin doğruluğunu yaklaşık %6 oranında artırabilmişlerdir. Ancak, bu iyileşme yalnızca küçük veri setleriyle sınırlı kalmış ve tam veri setine uygulandığında etkili bir şekilde ölçeklenememiştir. VAE veya büyük verilere dayanan diğer ardışık modelleme teknikleri kullanıldığında, özellikle veri boyutu ve karmaşıklığı arttıkça daha belirgin hale gelen iyi bilinen bir sorun olan kaybolan gradyan (Vanishing Gradient) problemi bu görevi daha da zorlaştırmıştır. Mekansal-zamansal inşaat ilerleme veri setleri bağlamında, ardışık ve mekansal bağımlılıkların etkileşimi bu sorunu şiddetlendirmekte ve modelin güvenilir veri, anlamlı bağlantı kenarları ve zamansal diziler üretme yeteneğini engellemektedir. Buna karşılık, eksik temsil edilen sınıflar için sentetik

veri üretmek amacıyla kullanılan bir diğer üretici olan GAN'dır. GAN'nın kullanımı için çalışmada iki farklı yaklaşım araştırılmıştır: 1) her proje için eksik temsil edilen sınıf verileri üzerinde GAN'ların özel olarak eğitilmesi, 2) daha dengeli sınıf dağılımları oluşturmak amacıyla belirli zamansal pencereler içinde GAN'ların eğitilmesi. Ancak bu çabalara rağmen, her iki yaklaşım da orijinal veri setleri üzerinde eğitilen mekansal-zamansal modellere göre önemli bir iyileşme sağlamamıştır. GAN modelleri inşaat ilerleme veri setlerinde bulunan karmaşık zamansal dinamikleri ve çeşitli aktivite dizilerini yakalamakta zorlanmıştır. Bu da tahmin doğruluğunu artırabilecek faydalı sentetik veriler üretme yeteneklerini sınırlamıştır.

Bu çalışmanın teknik literatüre olan en önemli katkılarından biri potansiyel veri kalitesi sorunlarını ve siber saldırı senaryolarını simüle etmeye yönelik çabaların gösterilmesidir. Model geliştirme sürecine siber saldırı proxy'lerinin entegrasyonu, etiket veya özellik manipülasyonu gibi farklı veri manipülasyon tekniklerinin mekansal-zamansal modellerin performansını nasıl etkileyeceğini test olanak tanımıştır. Çalışmanın bu yönü ile öne çıkmaktadır. Çünkü inşaat süreçlerinin dijitalleştirilmesi için gün geçtikçe artan uğraşlar bulunmaktadır. Bu dijitalleşmeye bağlı olarak siber tehditlerin yükselmesi, bu tür zorlukların öngörülmesini kritik hale getirmektedir. Bu zorluklar öngörülerek geliştirilen modeller kasıtlı veya kasıtsız veri kalitesi bozulmalarının simüle edildiği senaryolara karşı sağlamlık göstermiştir. Simüle edilen bu senaryolar Bursa ve Elazığ gibi daha eksiksiz veri setlerine uygulandığında modeller bu simüle edilmiş saldırılara rağmen iyi performans göstermiş ve doğruluğunu korumuştur. Buna karşılık, zaten doğasında veri kalitesi sorunları barındıran Adana gibi veri setlerinde simüle edilmiş siber saldırılar daha belirgin etkiler göstermiş ve eğitim ile tahmin süreçlerini daha da karmaşık hale getirmiştir. Bu bulgu, model performansını artırmada ve güvenilir tahminler sağlamada yüksek kaliteli, eksiksiz veri setlerinin önemini vurgulamaktadır.

Şekil 80 Adana veri seti üzerinde eğitilen modellerin bu veri seti üzerinde gerçekleştirilen farklı saldırı türlerine karşı GatedGNN mimarisi ile geliştirilen mekansal-zamansal modellerin bu tür saldırılara karşı sergiledikleri CPI ve SPI tahmin görevi performanslarını göstermektedir.



Şekil 80. Adana veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.

Şekil 80 Adana veri seti üzerinde eğitilen GatedGNN mekanizmalarına sahip mekansal-zamansal modellerin, bu veri setinin FGSM gibi çekişmeli saldırılar ve veri zehirlleme saldırıları da dahil olmak üzere çeşitli saldırı senaryolarına maruz kaldığında nasıl performans gösterdiklerini grafiksel olarak sunmaktadır. Saldırıları arasında, FGSM en ciddi saldırı tipi olanı olup hem CPI hem de SPI tahminlerinde doğruluk ve F1 skorlarında önemli

düşüşlere neden olmuştur. Örneğin, orijinal veri setinde başlangıçta CPI için %93 ve SPI için %81 doğruluk elde eden GatedGNN-GRU modeli, FGSM saldırıları altında sırasıyla %44 ve %33'e kadar dramatik bir düşüş yaşamıştır. Benzer şekilde, GatedGNN-RNN'nin doğruluğu, CPI'de %90'dan %41'e, SPI'de ise %84'ten %31'e düşmüştür. Bu büyük düşüşler modellerin özellikle veri kalitesi sorunlarına yatkın olan veri setlerinde-Adana veri seti gibi-çekışmeli saldırılara karşı savunmasız olduğunu ortaya koymaktadır.

Hem CPI hem de SPI tahminlerinde simüle edilen saldırılara karşı en dayanıklı modeller, RNN ile GatedGAT'yi birleştiren modeller olmuştur. Bu modeller, çekışmeli koşullara karşı en yüksek direnç seviyesini göstermiştir. Hem geçitli hem de dikkat mekanizmalarını entegre eden bu mimariler diğer mimarilere kıyasla performanslarını daha etkili bir şekilde sürdürmeyi başarmış ve veri manipölasyonlarının etkisini azaltma yeteneklerini sergilemişlerdir.


Etiket değıştirme saldırılarını içeren zehirlenme senaryolarında da modellerin performansları etkilenmiştir. Bu saldırılar verimli olan aktiviteleri verimsiz olarak veya zamanında tamamlanan aktiviteleri gecikmiş olarak işaretleme gibi etiketlerin kasıtlı veya kasıtsız olarak değıştirilmesini simüle etmektedir. Bu tür saldırılar, özellikle alt yüklenici veya yüklenici performansını değıerlendirirken modelin yanıltılmasına neden olabilecek gerçek dünya durumlarını taklit etmektedir. Modeller bu saldırılara karşı hassas olmasına rağmen, performans düşüşleri FGSM kadar ciddi olmamıştır. Bu durum, etiket zehirlenmenin modelleri yanıltabileceğini ancak mekansal-zamansal mimarilerin bu tür saldırılara karşı hala bir dereceye kadar dirençli olduğunu göstermektedir.

Modeller özellik manipölasyonu saldırılarına karşı oldukça dayanıklı kalmışlardır. Bu tür saldırılar miktar ölçümleri veya görev yerleri gibi özelliklerin değıştirilmesini içermektedir. Bu saldırılar hem CPI hem de SPI tahminlerinde doğruluk ve F1 skorlarında küçük düşüşlere neden olmuştur. Örneğin, GatedGNN-RNN doğrulukta yaklaşık %5'lik bir düşüş yaşamıştır. Bu küçük düşüş modellerin özellik verilerindeki bozulmalarla yeterince başa çıkabildiğini göstermektedir.

Bununla birlikte Adana veri setinde gözlemlenen eksik verilere sahip olma durumunun (15 haftadan fazla eksik kayıt) çekışmeli saldırıların etkisini artırmış olabileceğini belirtmek önemlidir. Bursa ve Elazığ gibi daha tutarlı ve eksiksiz veri toplama protokollerine sahip veri setlerinde, modeller doğruluklarını ve güvenilirliklerini daha iyi koruyabilmişlerdir. Bu da veri toplama mekanizmalarının iyileştirilmesinin ve daha yüksek kaliteli protokollerle

uyumlu hale getirilmesinin modellerin potansiyel siber tehditlere veya veri kalitesi sorunlarına karşı dayanıklılığını artırabileceğini göstermektedir.

GatedGNN mekanizmalarına sahip ve Bursa veri seti üzerinde eğitilen mekansal-zamansal modellerin, bu veri setine yapılan çeşitli saldırı senaryolarına karşı sergiledikleri performansları Şekil 81’de verilmektedir.



Şekil 81. Bursa veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.

Şekil 81 incelendiğinde GatedGNN mimarisine sahip mekansal-zamansal modellerin, Bursa veri setinin çeşitli çekişmeli saldırılara maruz kalması durumunda dahi dayanıklılıklarını koruduklarını söylemek mümkün olmaktadır. FGSM saldırısı, simüle edilen tüm saldırı senaryoları arasında en ciddi saldırı olarak kalmış ancak bazı modeller bu tür saldırıya karşı daha iyi direnç göstermiştir. Örneğin, LSTM-GatedGNN modeli SPI tahminlerinde önemli bir dayanıklılık sergileyerek orijinal veri setinde %85 olan doğruluk bu saldırı altında %72'ye kadar düşmüştür. Ancak, aynı model CPI tahminlerinde aynı dayanıklılığı sergileyememiş ve orijinal veri setinde %91 olan doğruluğu FGSM saldırısı altında %28'e kadar düşmüştür. ResGatedGNN modeli çoğu senaryoda en iyi performansı göstermemiş olup bu durum, ResGatedGNN'nin normal koşullarda diğer mekansal-zamansal modellere kıyasla üstün olmasa da daha seyrek fakat oldukça yıkıcı olan FGSM gibi siber saldırılara karşı daha fazla koruma gerektiren sistemler için uygun bir model seçeneği sunduğunu göstermektedir.


Etiket değiştirme saldırıları dikkate alındığında, ki bu saldırılar etiket atamalarındaki kasıtlı veya kasıtsız hataları (örneğin, verimli olanın verimsiz olarak yanlış etiketlenmesi) simüle etmektedir, modeller güçlü bir direnç sergilemiştir. Özellikle GatedGNN, GatedGNN-RNN, GatedGNN-GRU, RNN-GatedGNN ve GatedGNN-LSTM gibi modeller saldırının ciddiyetine rağmen CPI'de %81 ve SPI'de %78 doğruluk oranlarını koruyarak yüksek performans seviyelerini sürdürmüştür. Bu dayanıklılık seviyesi bu mimarilerin etiket bozulmalarını büyük performans düşüşleri yaşamadan yönetebileceğini ve hatta veri koşulları tehlikeye girdiğinde bile proje performansının güvenilir bir şekilde değerlendirilmesini sağlayabileceklerini göstermektedir.

Modeller rastgele etiket saldırılarına ve özellik manipülasyonu saldırılarına karşı daha da güçlü bir performans sergilemiştir. Örneğin, rastgele etiket zehirleme saldırısı doğruluğu, CPI için %86 ve SPI için %82 seviyesinde kalırken özellik manipülasyonu zehirleme saldırısı doğruluğu ise biraz daha iyi olup CPI için %87 ve SPI için %84 seviyelerine ulaşmıştır. Bu bulgular, özellikle RNN, GRU ve LSTM bileşenleri ile entegre edilen GatedGNN tabanlı modellerin yalnızca normal koşullar altında etkili olmadığını, aynı zamanda özellik değerleriyle oynayan ya da etiketleri rastgele manipüle eden saldırılara karşı da önemli bir dayanıklılığa sahip olduğunu ortaya koymaktadır.

Sonuç olarak Bursa veri seti üzerinde eğitilen modeller, siber saldırılara ve veri kalitesi sorunlarına karşı genellikle daha dirençli olmuş, özellikle Adana gibi doğasında kalite sorunları olan veri setlerinde eğitilen modellere kıyasla daha iyi performans göstermiştir. Bu

dayanıklılık, siber güvenlik ve veri bütünlüğünün kritik önem taşıdığı gerçek dünya uygulamaları için bu modelleri uygun adaylar haline getirmektedir.


Şekil 82 Elazığ veri seti üzerinde eğitilen GatedGNN mimarisine sahip mekansal-zamansal modellerin farklı saldırı türlerine karşı sergiledikleri performanslarını göstermektedir.



Şekil 82. Elazığ veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.

Şekil 82'de görüldüğü üzere, GatedGNN mekanizmalarına sahip mekansal-zamansal modellerin Elazığ veri setinde gerçekleştirilen çeşitli saldırı türleri karşısındaki CPI ve SPI tahmin performansları önemli bir dayanıklılık sergilemiştir. Modeller etiket değiştirme zehirlleme saldırısı, rastgele etiket zehirlleme saldırısı ve özellik manipülasyonu saldırıları altında bile CPI için sırasıyla %81, %86 ve %85; SPI için ise sırasıyla %81, %86 ve %88 doğruluk oranlarını korumuşlardır. Modeller ayrıca yüksek F1 skorları sergileyerek veri manipülasyonu saldırıları altında tahmin güvenilirliğini koruma yeteneklerini pekiştirmiştir. GatedGNN-GRU ve GatedGNN modelleri yine bu saldırılar karşısında öne çıkmış, performans açısından LSTM-GatedGNN'yi yakından takip etmişlerdir. Ancak önceki veri setlerinde olduğu gibi bu modeller FGSM saldırısına karşı belirgin şekilde savunmasız kalmış ve doğruluk oranları önemli ölçüde düşmüştür.

Yozgat veri seti üzerinde eğitilen GatedGNN mimarisi ile geliştirilen mekansal-zamansal modellerin, bu veri setinde yapılan farklı saldırı türlerine karşı gösterdikleri CPI ve SPI tahmin performansları Şekil 83 verilmektedir. Şekil 83'ten görülebildiği üzere Yozgat veri setinde GatedGNN mekanizmalarına sahip mekansal-zamansal modeller FGSM dahil olmak üzere tüm saldırı türlerinde minimum performans düşüşü sergilemişlerdir. Bu durum, sadece model mimarisinin dayanıklılığı etkilemediğini aynı zamanda veri seti kalitesinin de öngörücü modellerin sağlamlığını belirlemede kritik bir rol oynadığını göstermektedir.



Şekil 83. Yozgat veri setinde GatedGNN bileşeni ile mekansal-zamansal CPI ve SPI tahmin modellerinin farklı saldırılar karşısındaki doğruluk ve F1 skorları.

Yozgat veri seti doğasında daha az veri kalitesi sorunu barındırmakta olup bu da modellerin siber saldırılara karşı daha etkili bir şekilde direnç göstermesini sağlamıştır. Bu gözlemler, dayanıklı öngörücü modellerin güvence altına alınmasında hem model mimarisinin hem de veri kalitesinin önemini vurgulamaktadır.

4. SONUÇLAR

Bu çalışmanın gerekliliği inşaat yönetiminde kullanılan mevcut proje ilerleme tahmin modellerindeki bir boşluktan doğmuştur. CPM ve PERT gibi teknikler genellikle proje ilerlemesini planlamak ve izlemek amaçlı kullanılır. İnşaat yönetiminde kullanılan çoğu proje ilerleme tahmin ML modeli, proje planlamasında yer alan bu ağ tabanlı yapıları entegre etmemektedir. GNN gibi mekansal ML modelleri bu durumu ele alabilse de aktivitelerin zaman içindeki ilerlemesini göz ardı ederek zamansal boyutu dikkate almamaktadır. İnşaat aktivitelerinin kısa süreli ve yüksek ayrıntı seviyeleri ile temsil edilmeleri zamansal modelleme sürecini daha da karmaşık hale getirmektedir. Ağ bağımlılıklarını ve ayrıntılı görev ilerlemelerini bir tahmin çerçevesinde birleştirememesi yapılandırılmış tahmin modelinin temsil edilebilirliği ve güvenilirliği açısından önemli bir zorluk teşkil etmektedir. Bu çalışma ağ tabanlı ve kısa dizili modellemeyi mekansal-zamansal tahmin modellerine entegre eden yeni bir yaklaşım ile bu sınırlamaları ele almayı amaçlamıştır.

Bu çalışma inşaat ilerleme tahmininde mekansal-zamansal modellerin ilk uygulamasını temsil etmekte olup aynı zamanda model performansını etkileyen farklı veri kalitesi sorunlarını çeşitli saldırılar olarak dikkate alan ilk çalışmadır. 36 farklı mekansal-zamansal model yapılandırılmış, değerlendirilmiş ve seçilmiştir. Bu modeller arasında GatedGNN tabanlı 14 adet model doğruluk ve dayanıklılık açısından öne çıkmıştır. Bu çalışmada, risk odaklı mekansal-zamansal inşaat ilerleme tahmin modellerini yapılandırmak, değerlendirmek ve seçmek için detaylı bir çerçeve takip edilmiştir. GatedGNN ve GatedGNN-RNN gibi ileri seviye makine öğrenimi mekanizmalarıyla desteklenen bu modeller, CPI ve SPI gibi kilit performans göstergelerini tahmin etmede doğruluğu, güvenilirliği ve dayanıklılığı artırarak inşaat proje yönetimini sürecini iyileştirmek amacıyla özel olarak tasarlanmıştır.

Çalışmada gerçekleştirilen değerlendirmeler sonucunda elde edilen temel sonuçlar aşağıdaki gibidir:

1. İlgili projeye ait WBS ve haftalık teslimat programlarına dayanan veri setleri burada yer alan mekansal ve zamansal bağımlılıklar birleştirilerek mekansal-zamansal modeller için yenilikçi bir giriş veri seti ağına dönüştürülmüştür. Bu yenilik modellerin inşaat ilerlemesinin statik temsillerinin ötesine geçerek görev yürütme ve bağımlılıkların dinamik ve ilişkisel yönlerini yakalamasını sağlamıştır.

2. Geleneksel mimarilerden (RNN, LSTM ve GRU gibi) daha ileri düzeyde grafik tabanlı modellere (GCN ve GAT gibi) kadar 36 farklı ML modeli yapılandırılmış ve değerlendirilmiştir. Bu modeller mekansal ve zamansal önceliğin tahmin doğruluğunu nasıl etkileyebileceğine dair esnek ve kapsamlı bir inceleme sunarak yönlü ve çift yönlü geçitli varyantlar halinde yapılandırılmıştır. Değerlendirilen modeller arasında GatedGNN, GatedGNN-RNN, GatedGNN-GRU, RNN-GatedGNN ve GRU-GatedGNN yapılandırmaları öne çıkarak planlanan ve gerçek CPI ve SPI arasındaki farklılıkları sırasıyla %90 ve %80 üzerinde bir doğrulukla tespit edebilmişlerdir.
3. Dört farklı ilde gerçekleştirilen mega projelere ait 175 haftalık inşaat ilerleme raporundan derlenen iki milyondan fazla kayıttan oluşan büyük bir veri seti oluşturulmuştur. Bu kayıtlar geniş bir proje türü ve veri senaryosu temsili sağlamıştır. Daha büyük ve daha eksiksiz veri setlerine sahip projelerde, örneğin Bursa ve Elazığ'da, modeller en yüksek verimlilikle çalışmış ve CPI tahmin doğrulukları %95'e ulaşmıştır. Buna karşılık, Yozgat gibi daha küçük veri setlerinde, veri eksikliği sorunları yaşandığı için SPI tahmin doğruluğunda %60-%70 aralığında belirgin bir düşüş gözlemlenmiştir. Bu performans farklılıkları veri bütünlüğünün tahmin doğruluğunu sağlamadaki kritik rolünü vurgulamaktadır. Ek olarak modeller proje ilerleme sürecine yönelik veri bütünlüğünün en yüksek olduğu dönemlere ait raporlamalarda en iyi performansı sergilemiştir. Örneğin Bursa ve Elazığ'da erken proje pencereleri %95'e kadar CPI tahmin doğruluğu elde etmiştir. Ancak projeler ilerledikçe ve veri setleri daha parçalı hale geldikçe—özellikle Adana ve Yozgat'ta—performans dalgalanmaları daha belirgin hale gelmiştir. Bu durum bir projenin yaşam döngüsü boyunca veri kalitesi yönetiminin sürekliliğini ve önemini pekiştirmektedir.
4. Geleneksel performans metrikleri olan doğruluk, F1 skoru ve AUC'un ötesine geçen titiz bir değerlendirme gerçekleştirilmiştir. Bu değerlendirme modellerin performanslarını, siber saldırılara karşı dayanıklılıklarını ve sağlamlıklarını ölçmeyi amaçlamıştır. Modeller özellikle veri zehirlleme, etiket değiştirme, rastgele etiket manipülasyonu, özellik manipülasyonu ve FGSM saldırıları gibi çekişmeli saldırılara karşı test edilmiştir. Bu çok boyutlu değerlendirme, modellerin gerçek dünyadaki uygulanabilirliği ve dayanıklılığı hakkında daha derin bir anlayış sağlamıştır. GatedGNN tabanlı modeller—özellikle GatedGNN, GatedGNN-RNN ve GRU-GatedGNN—çekişmeli saldırılara karşı etkileyici bir dayanıklılık sergilemiştir. Bu modeller etiket değiştirme, rastgele etiket değiştirme, özellik manipülasyonu gibi veri zehirlleme saldırılarına karşı test edildiğinde,

modeller %80'in üzerinde doğruluk seviyelerini korumuşlardır. Bununla birlikte, FGSM saldırıları özellikle Adana gibi daha küçük veri setlerinde model performansını %91 doğruluktan %28'e kadar düşürerek daha büyük bir zorluk oluşturmuştur. Bu bulgu, inşaat yönetiminde kullanılan tahmin modelleri için siber savunma mekanizmalarının sürekli olarak geliştirilmesi gerektiğini göstermektedir.

5. Sınıf dengesizliği ve eksik veriler gibi yapım projeleri ilerleme verilerinde bilinen ve görülen zorluklar göz önünde bulundurularak bu zorluğun giderilmesi amacıyla GAN ve VAE kullanılarak hibrit bir veri seti oluşturulmuştur. Bu stratejinin veri setini dengeleyerek ve potansiyel yanlılıkları azaltarak daha zorlu senaryolarda modellerin performanslarını artırması beklenmiş olsa da bu hibrit veri seti kullanılarak elde edilen model performansları sınıf dengesizliği sorununun tamamen çözülemediğini göstermektedir.

Bu tez çalışması sonucunda elde edilen bulgular yapım yönetimi için doğrudan pratik sonuçlar taşımaktadır. Çalışmada denenen ağ tabanlı bağımlılıkları ve ayrıntılı görev dizilerini doğru ve daha güvenilir mekansal-zamansal ML modellerine entegre etme düşüncesi inşaat profesyonellerine riskleri azaltma, gecikmelerden kaçınma ve maliyet aşımalarını en aza indirme gibi yapım yönetimi süreci temel alanlarının yönetimi için güçlü bir araç sunmaktadır. Ayrıca, modellerin veri kalitesi sorunlarına ve çekişmeli saldırılara karşı test edilmiş olan dayanıklılıkları onların gerçek dünya proje ortamlarında güvenle uygulanabileceğini göstermektedir. Bu çalışmada geliştirilen tahmin modelleri, operasyonel karar alma süreçlerini geliştirmenin yanı sıra stratejik planlamayı da kolaylaştırarak proje sonuçlarının daha doğru ve güvenilir bir şekilde öngörülmesini sağlayabilecektir.

4.1. Katkılar


Önerilen modellerin farklı veri setlerinde test edilen dayanıklılık değerlendirmeleri dikkate alındığında bu çalışmada geliştirilen mekansal-zamansal modeller yine çalışmada dikkate alınan saldırılara karşı güçlü bir direnç göstermiş ve kullanım güvenliğini artıran risk odaklı bir çerçeve sunmuştur. Bu dayanıklılık, yalnızca kasıtlı siber saldırılara karşı değil aynı zamanda önyargılı kayıt tutma, veri toplama protokollerindeki ihlaller veya kasıtsız insan hatalarından kaynaklanan potansiyel sorunları da ele almaktadır. GatedGNN, GatedGNN-RNN ve GatedGAT-GRU gibi modellerin hem doğruluk hem de F1 skorları açısından tutarlı performansları onların güvenilirliklerini vurgulamaktadır. Bu modeller,

FGSM saldırılarına karşı savunmasız olmakla birlikte daha yaygın veri bütünlüğü tehditlerine karşı güvenilirliğini sürdürmektedir. Ancak bu modellerin FGSM gibi ciddi koşullar altında sınırlarını bilmek geliştiricilerin ve inşaat firmalarının sistem güvenliğini artırmaya ve bu modelleri kullanırken ek önlemler uygulamaya odaklanmalarına olanak tanımaktadır. İnşaat sektörü giderek öngörücü analizlere daha fazla bağımlı hale gelmekte ve bu durum bu amaçla geliştirilen modellerin siber dayanıklılıklarının sağlanması özellikle veri ihlalleri veya manipülasyonlarının önemli olabileceği büyük ölçekli projelerde hayati bir önem kazanmaktadır.

İnşaat yönetimi üzerine yapılan önceki çalışmalar genellikle proje performansının maliyet veya program tahmini yönlerine odaklanmış, büyük ölçekli inşaat projelerini karakterize eden mekansal ve zamansal bağımlılıkları sıklıkla ihmal etmiştir. Bu çalışmada mekansal ve zamansal nitelikleri entegre eden mekansal-zamansal modeller yapılandırılmış ve bu modellerin performans değerlendirmeleri yapılarak ilerleme tahminine daha kapsamlı bir yaklaşım sunulmaktadır. Amer ve Golparvar-Fard (2019) çalışmasında, geçmiş inşaat projelerinden elde edilen program verilerini kullanarak LSTM-RNN ile inşaat sıralama bilgilerini otomatik olarak öğrenmiş ve dinamik yöntem şablonları oluşturmuştur. Bu yaklaşım, inşaat sıralamasının otomatikleştirilmesi ve şirket bazında özelleştirilmiş en iyi uygulamaların çıkarılması açısından önemli bir adım olmuştur. Florez-Perez vd. (2022) ise çeşitli ML algoritmalarını kullanarak işçi uyumu, dışsal koşullar ve işçi karakteristikleri gibi faktörlerin iş verimliliği üzerindeki etkilerini analiz etmiş ve tahmin modelleri geliştirmiştir. Alikhani vd. (2023) tarafından yapılan araştırmada, günlük iş raporlarından elde edilen verilerle LSTM modelleri kullanılarak faaliyet sıraları ve örtüşmeleri tahmin edilmiş, bu da zamansal bağımlılıkların inşaat süreçlerindeki kritik rolünü vurgulamıştır. Leon vd. (2018) ise sistem dinamiği modeli aracılığıyla maliyet, takvim, kalite, kârlılık, güvenlik, çevre, ekip ve müşteri memnuniyeti gibi performans göstergeleri arasındaki etkileşimleri simüle ederek kapsamlı bir performans tahmin aracı geliştirmiştir. Bu çalışma, bu dört çalışmanın sunduğu yöntemleri bir adım öteye taşıyarak, GCN, GAT ve GatedGNN ile RNN, LSTM ve GRU kombinasyonlarını kullanarak mekansal ve zamansal bağımlılıkları aynı anda modelleyen mekansal-zamansal ML modelleri geliştirildi. Bu modeller, WBS tabanlı yapılandırılmış ilerleme verilerini kullanarak CPI ve SPI'nin daha doğru tahmin edilmesini sağlamaktadır.

Ayrıca, çalışmada veri kalitesi sorunlarını ele almak için siber saldırı simülasyonlarının kullanılması inşaat yönetimi araştırmalarına yeni bir boyut kazandırmakta ve dijital çağda siber güvenliğin artan önemini vurgulamaktadır. Zaman serisi modeliyle

entegre edilmiş GNN'ler kullanarak yapılandırılan bir mekansal-zamansal modelin SPI ve CPI'yi doğru bir şekilde öngören daha güvenilir bir ilerleme tahmin modeli sağladığı söylenebilir. İnşaat yöneticileri bu tahminlerden yararlanarak en iyi teklifi seçebilir, karlılığı artırabilir ve projeyi zamanında ve bütçe dahilinde teslim ederek projenin itibarını koruyabilirler. Şekil 84 bu çalışma aracılığıyla mevcut literatüre yapılan katkıları ve elde edilen gözlemler ışığında gelecekteki çalışmalar için ele alınabilecek araştırma boşluklarını göstermektedir.



Şekil 84. Bu çalışmada mevcut literatüre yapılan katkıları ve gelecekteki çalışmalar için ele alınabilecek araştırma boşlukları.

Şekil 84'te sunulan veri hazırlama ile başlayıp model testi ve hesap verebilirlik aşamalarına kadar ilerleyen çok adımlı bir yaklaşım içeren yapılandırılmış süreçte gösterildiği gibi bu süreç modelin, veri kalitesindeki değişkenlikler ve eksik değerlerin varlığı gibi inşaat verilerinin içerebileceği doğal zorluklara karşı hem dayanıklı hem de uyumlu olmasını sağlamıştır. Veri toplama, veri çıkarma, dönüştürme ve kalite kontrol süreçleri modelin çalışabileceği güvenilir girdilere sahip olmasını sağlamak için entegre edilmiştir ve nihayetinde CPI ve SPI tahminlerinin daha doğru bir şekilde yapılmasına olanak tanımıştır. Çalışmanın en önemli katkılarından biri güvenlik ve dayanıklılık

konularına çektiği dikkat olmuştur. Yapılandırılmış süreçte yansıtıldığı gibi güvenlik, özellikle veri kalitesi sorunları ve tahminlerin güvenilirliğini tehlikeye atabilecek siber saldırılar ışığında öncelikli bir konu olarak ele alınmıştır. Çalışmada modellerin çeşitli saldırı senaryoları altında bile doğruluğunu koruma yeteneğini değerlendirmek için veri bozulmalarının simülasyonlarını da içermektedir. Bu senaryolar arasında veri zehirlenme veya manipülasyon saldırıları da yer almıştır. Bu ek güvenlik testi katmanı, dijital çağda inşaat proje yönetiminin giderek daha fazla güvenilir veri odaklı içgörülere dayanması nedeniyle son derece önemlidir.

Dayanıklılık, çalışmanın bir diğer temel temalarından biri olmuştur. Modeller, eksik veya gürültülü verilerle başa çıkabilecek şekilde tasarlanmış ve eksik kayıtlar veya sınıf dengesizliği sorunları olmasına rağmen tahminlerin etkili bir şekilde yapılabilmesini sağlamıştır. Örneğin, Adana ve Yozgat veri setlerinde önemli miktarda eksik değerler ve dengesiz sınıf dağılımları bulunmasına rağmen modeller CPI ve SPI tahminlerini üretme konusunda kayda değer bir direnç sergilemiştir. Bu dayanıklılık, veri toplamanın nadiren mükemmel olduğu ve öngörülemeyen sorunların sıklıkla ortaya çıktığı gerçek dünya uygulamaları için kritik öneme sahiptir.

Tahmin doğruluğu ve dayanıklılığın ötesinde inşaat yönetimi profesyonelleri için karar destek aracı olarak kapsamlı bir tahmin modeli geliştirirken modelin temsil edilebilirliğini sağlamak da çok önemlidir. Bu bağlamda, F. Mostofi vd. (2024) ve H. Zhang vd. (2024) geliştirilen karar destek aracı modeline olan güvenin artırılması ve bu amaçla kullanımının kolaylaştırılması için tahmin modelinin temsil edilebilirliği, yorumlanabilirliği ve doğruluğunun önemini vurgulamaktadırlar. Temsil edilebilirlik, “bir şeyin başka bir şeyi—bir örnekleme bir popülasyon için, bir örneği bir kategori için—temsil etme yeteneği” olarak tanımlanabilir (Chasalow & Levy, 2021). Bu tür modellerin temsil edilebilirliği kullanıcıların kendi uzmanlıklarını model girdileriyle bağdaştırmasına olanak tanıyarak tahminlerin anlamlılığını artırır (F. Mostofi vd., 2024). Ulusal Standartlar ve Teknoloji Enstitüsü (NIST, 2022), “AI Risk Yönetim Çerçevesi: İkinci Taslak” raporunda güvenilir ML sistemlerinin inşa edilmesi ve veri setlerinin hedef popülasyonu gerçekten yansıttığından emin olunması gerekliliğini vurgulamıştır. Güvenilir bir tahmin modeli geliştirmenin bir yolu hem modelin yorumlanabilirliğini hem de kullanıcı güvenini artıran temsil edici veriler seçmektir (Ribeiro vd., 2016). ML tabanlı sistemlerde güven, tahminlerin arkasındaki nedenlerin anlaşılmasına bağlıdır (Ribeiro vd., 2016).

4.2. Araştırma Önerileri

Şekil 84 aynı zamanda çalışmada elde edilen bilgiler ışığında gelecekteki çalışmalar için araştırma konusu olabilecek alanları vurgulamaktadır. Geliştirilen modellerin temel sınırlamalarından biri olan ML modellerinde açıklanabilirlik eksikliği, özellikle inşaat ilerleme tahminleri gibi yüksek riskli uygulamalarda önemli bir sorun teşkil etmektedir. Açıklanabilir ML modeli, insanların model tahminlerinin arkasındaki mantığı anlamalarına olanak tanıyan algoritma ve tekniklere işaret eder. Ibarra-Vazquez vd. (2024) açıklanamayan ML'yi kara kutu (Black-box) model olarak değerlendirmiştir. Açıklanabilir ML modelleri, şeffaf bir arayüz aracılığıyla modellerin nasıl karar verdiğini anlamayı sağlar; bu da güven inşa etmek, hata ayıklamayı kolaylaştırmak ve etik kullanım sağlamak açısından kritik öneme sahiptir. Tahmin doğruluğunun ötesinde, ML modelinin uygulanması için gerekli olan bir başka gereklilik, modelin tahmin yapma biçimini anlamak amacıyla modele güven kazandırmak olup bu modelin insan gözlemcisine sunduğu karar arkasındaki mantığı şeffaf ve kapsamlı bir şekilde ortaya koymasıdır (Ibarra-Vazquez vd., 2024; Wells & Bednarz, 2021). İnşaat proje profesyonelleri için açıklanabilirlik modellerin karar alma süreçlerine entegrasyonunu teşvik etmek açısından özellikle önemli olabilmektedir. Bu durum, etkin risk yönetimi ve projenin zamanında tamamlanması açısından kritik öneme sahip CPI ve SPI gibi metriklerin tahmin edilmesinde hayati önem taşımaktadır.

Bir diğer sınırlama, incelenen mekansal-zamansal inşaat ilerleme performans tahmin modellerinin transdüktif öğrenmeyi (Transductive Learning) benimsemesidir. Bu öğrenme türünde model, eğitim verilerinden görülmeyen örneklerle genelleme yapmaz; bunun yerine, eğitim aşamasında etiketlenmemiş verileri içeren belirli örnekler üzerinden tahmin yapar (Rossi vd., 2018). Geliştirilen transdüktif mekansal-zamansal ML modelleri, genellikle grafik yapılarında somutlaşan veri noktaları arasındaki ilişkilerden yararlanarak gördüğü örneklerden yola çıkarak yeni veri noktaları hakkında tahminlerde bulunur (Rossi vd., 2018). Buna karşılık indüktif öğrenme mekansal-zamansal modellerinde algoritma, eğitim seti içindeki belirli örneklerden genel bir kural çıkarır ve ardından bu kuralı görülmeyen verilere uygulayarak tahminlerde bulunur (Rossi vd., 2018). Pratikte kapsamlı bir mekansal-zamansal model grafik biçiminde temsil edilen verileri işlemek için hem indüktif hem de transdüktif öğrenme metodolojilerinden yararlanır. Bu, eğitim verileriyle tam olarak eşleşmeyen ancak benzer özellikler taşıyan farklı türdeki inşaat projelerini ele almak için kritik öneme sahiptir. Hem indüktif hem de transdüktif yaklaşımları kullanan mekansal-

zamansal ML modelleri her iki yöntemin güçlü yönlerini en üst düzeye çıkaran hibrit bir öğrenme şeması kullanabilir. Örneğin, inşaat yönetimi tahmin modellerinde genel kural oluşturma için indüktif öğrenmeden ve mekansal ve ilişkisel verilerden yararlanmak için transdüktif yöntemlerden faydalanmak modelin eğitim sonrası yeni proje verilerini etkin bir şekilde işlemlerini sağlayabilir. Bu ikili yaklaşım inşaat proje yönetimi alanındaki karar destek araçları için oldukça etkili olup eğitim seti içindeki ilişkiler ve yakınlıklar temel alınarak hem etiketlenmiş hem de etiketlenmemiş verileri kullanarak yeni örnekleri doğrudan sınıflandırabilir. Farklı GNN modellerinin farklı uygulamalar için uygun olduğu dikkate alındığında (Khemani vd., 2024) gelecekteki çalışmalarda inşaat ilerleme performans tahmini için farklı transdüktif ve indüktif mekansal-zamansal ML modellerini araştırmanın öğrenilen kuralları uygulayarak yeni ve görülmemiş proje verilerine uyum sağlayarak modellerin farklı inşaat projelerini etkili bir şekilde ele almasını sağlaması ve modellerin çeşitli senaryolardaki uygulanabilirliğini ve etkinliğini artırması beklenmektedir. Bunun yanı sıra modellerin güvenilirliği girdi verilerinin niteliğine bağlı olarak değişmekte olup müşteri talepleriyle yapılan değişiklik emirleri gibi faktörler eğitim verilerinde yer almıyorsa modellerin tahminleri güvenilir olmayabilmektedir. Bu durum, veri setlerinin eksiksiz ve doğru bir şekilde oluşturulmasının önemini bir kez daha gözler önüne sermektedir.

5. KAYNAKLAR

- Abo Mhady, A., Budayan, C., & Gurgun, A. P. (2024). Estimate-at-completion (EAC) prediction using Archimedes optimization with adaptive fuzzy and neural networks. *Automation in Construction*, 166, 105653.
- Abu-El-Haija, S., Kapoor, A., Perozzi, B., & Lee, J. (2019). N-GCN: Multi-scale graph convolution for semi-supervised node classification. 35th Conference on Uncertainty in Artificial Intelligence, UAI 2019, 1-9.
- Agarap, A. F. (2018). Deep Learning using Rectified Linear Units (ReLU). <http://arxiv.org/abs/1803.08375>
- Ahuja, V., & Thiruvengadam, V. (2004). Project scheduling and monitoring: Current research status. *Construction Innovation*, 4(1), 19–31.
- Al Jassmi, H., Ahmed, S., Philip, B., Al Mughairbi, F., & Al Ahmad, M. (2019). E-happiness physiological indicators of construction workers' productivity: A machine learning approach. *Journal of Asian Architecture and Building Engineering*, 18(6), 517–526.
- Aladag, M., Catak, F. O., & Gul, E. (2019). Preventing Data Poisoning Attacks By Using Generative Models. 2019 1st International Informatics and Software Engineering Conference (UBMYK), 1–5.
- Alaloul, W. S., Liew, M. S., Wan Zawawi, N. A., Mohammed, B. S., & Adamu, M. (2018). An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors. *Cogent Engineering*, 5(1), 1–18.
- Alikhani, H., Le, C., Jeong, H. D., & Damjanovic, I. (2023). Sequential Machine Learning for Activity Sequence Prediction from Daily Work Report Data. *Journal of Construction Engineering and Management*, 149(9).
- AlMunifi, A. A., & Almutairi, S. (2021). Lessons Learned Framework for Efficient Delivery of Construction Projects in Saudi Arabia. *Construction Economics and Building*, 21(4).
- Alpaslan, E., Hacıfendioğlu, K., Yılmaz, M. F., Demir, G., Mostofi, F., & Toğan, V. (2024). Structural Modal Calibration of Historical Masonry Arch Bridge by Using a Novel Deep Neural Network Approach. *Iranian Journal of Science and Technology - Transactions of Civil Engineering*, 48(1).
- Amer, F., & Golparvar-Fard, M. (2019). Formalizing Construction Sequencing Knowledge and Mining Company-Specific Best Practices from Past Project Schedules. Computing in Civil Engineering 2019: Visualization, Information Modeling, and Simulation - Selected Papers from the ASCE International Conference on Computing in Civil Engineering 2019, 215–223.

- Amer, F., Jung, Y., & Golparvar-Fard, M. (2023). Construction schedule augmentation with implicit dependency constraints and automated generation of lookahead plan revisions. *Automation in Construction*, 152.
- Asiedu, R. O., Frempong, N. K., & Nani, G. (2016). Parametric time overrun estimation of building projects. *Journal of Financial Management of Property and Construction*, 21(3), 253–268.
- Avci, H. F. (2024). The Bid/no-bid Framework Utilizing Node2vec for International Contractors, Master Thesis, Istanbul.
- Bahadır, Ü., Mostofi, F., & Toğan, V. (2022). Analysis of Parameters Affecting Decision Making to Retrofit of Existing School Buildings Using Ensemble Machine Learning Methods. 7th International Project and Construction Management Conference (IPCMC 2022), 480-492.
- Balda, E. R., Behboodi, A., & Mathar, R. (2019). Perturbation Analysis of Learning Algorithms: Generation of Adversarial Examples From Classification to Regression. *IEEE Transactions on Signal Processing*, 67(23), 6078–6091.
- Berglund, E. Z., Monroe, J. G., Ahmed, I., Noghabaei, M., Do, J., Pesantez, J. E., Khaksar Fasaee, M. A., Bardaka, E., Han, K., Proestos, G. T., & Levis, J. (2020). Smart Infrastructure: A Vision for the Role of the Civil Engineering Profession in Smart Cities. *Journal of Infrastructure Systems*, 26(2), 03120001.
- Berglund, M., Raiko, T., Honkala, M., Kärkkäinen, L., Vetek, A., & Karhunen, J. (2015). Bidirectional Recurrent Neural Networks as Generative Models - Reconstructing Gaps in Time Series. <http://arxiv.org/abs/1504.01575>
- Biswas, A., Ghosh, A., Kar, A., Mondal, T., Ghosh, B., & Bardhan, P. K. (2021). The impact of COVID-19 in the construction sector and its remedial measures. *Journal of Physics: Conference Series*, 1797(1), 012054.
- Bosché, F., Ahmed, M., Turkan, Y., Haas, C. T., & Haas, R. (2015). The value of integrating Scan-to-BIM and Scan-vs-BIM techniques for construction monitoring using laser scanning and BIM: The case of cylindrical MEP components. *Automation in Construction*, 49, 201–213.
- Bottaccioli, L., Aliberti, A., Ugliotti, F., Patti, E., Osello, A., Macii, E., & Acquaviva, A. (2017). Building Energy Modelling and Monitoring by Integration of IoT Devices and Building Information Models. Proceedings - International Computer Software and Applications Conference, 1, 914–922.
- Bresson, X., & Laurent, T. (2017). Residual Gated Graph ConvNets. <https://doi.org/10.48550/arXiv.1711.07553>
- Byung Cheol Kim, by. (2007). Forecasting Project Progress and Early Warning Of Project Overruns With Probabilistic Methods, PhD Thesis, Texas.

- Candaş, A. B., & Tokdemir, O. B. (2022a). Automated Identification of Vagueness in the FIDIC Silver Book Conditions of Contract. *Journal of Construction Engineering and Management*, 148(4).
- Candaş, A. B., & Tokdemir, O. B. (2022b). Automating Coordination Efforts for Reviewing Construction Contracts with Multilabel Text Classification. *Journal of Construction Engineering and Management*, 148(6).
- Capanema, C. G. S., de Oliveira, G. S., Silva, F. A., Silva, T. R. M. B., & Loureiro, A. A. F. (2023). Combining recurrent and Graph Neural Networks to predict the next place's category. *Ad Hoc Networks*, 138, 103016.
- Chao, L.-C., & Chien, C.-F. (2009). Estimating Project S-Curves Using Polynomial Function and Neural Networks. *Journal of Construction Engineering and Management*, 135(3), 169–177.
- Chasalow, K., & Levy, K. (2021). Representativeness in statistics, politics, and machine learning. FAccT 2021 - Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, 77–89.
- Chassiakos, A. P., & Sakellariopoulos, S. P. (2005). Time-Cost Optimization of Construction Projects with Generalized Activity Constraints. *Journal of Construction Engineering and Management*, 131(10), 1115–1124.
- Chen, H., Deng, Z., Xu, Y., & Li, Z. (2021). Non-Recursive Graph Convolutional Networks. <https://doi.org/10.48550/arXiv.2105.03868>
- Chen, J., Zheng, L., Hu, Y., Wang, W., Zhang, H., & Hu, X. (2024). Traffic flow matrix-based graph neural network with attention mechanism for traffic flow prediction. *Information Fusion*, 104, 102146.
- Chen, L., Lu, Q., & Han, D. (2023). A Bayesian-driven Monte Carlo approach for managing construction schedule risks of infrastructures under uncertainty. *Expert Systems with Applications*, 212, 118810.
- Chen, L., Xie, Y., Zheng, Z., Zheng, H., & Xie, J. (2020). Friend Recommendation Based on Multi-Social Graph Convolutional Network. *IEEE Access*, 8, 43618–43629.
- Chen, T. (2023). Prediction of heart disease using graph neural networks. In Z. Xiong & R. He (Eds.), *International Conference on Artificial Intelligence and Industrial Design (AIID 2022)* (p. 42). SPIE.
- Chen, Y., Sun, M., Chu, Z., Camal, S., Kariniotakis, G., & Teng, F. (2023). Vulnerability and Impact of Machine Learning-Based Inertia Forecasting Under Cost-Oriented Data Integrity Attack. *IEEE Transactions on Smart Grid*, 14(3), 2275–2287.
- Cheng, Y.-M., Yu, C.-H., & Wang, H.-T. (2011). Short-Interval Dynamic Forecasting for Actual S-Curve in the Construction Phase. *Journal of Construction Engineering and Management*, 137(11), 933–941.

- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(1), 6.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling.
- Clevert, D.-A., Unterthiner, T., & Hochreiter, S. (2015). Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). <https://doi.org/10.48550/arXiv.1511.07289>
- Corso, G., Stark, H., Jegelka, S., Jaakkola, T., & Barzilay, R. (2024). Graph neural networks. *Nature Reviews Methods Primers*, 4(1), 17.
- Cui, L., Bai, L., Bai, X., Wang, Y., & Hancock, E. R. (2024). Learning Aligned Vertex Convolutional Networks for Graph Classification. *IEEE Transactions on Neural Networks and Learning Systems*, 35(4), 4423–4437.
- Czakon, M., Heymes, D., & Mitov, A. (2015). High-precision differential predictions for top-quark pairs at the LHC. <https://doi.org/10.1103/PhysRevLett.116.082003>
- Datta, S. D., Islam, M., Rahman Sobuz, Md. H., Ahmed, S., & Kar, M. (2024). Artificial intelligence and machine learning applications in the project lifecycle of the construction industry: A comprehensive review. *Heliyon*, 10(5), e26888.
- Ebrahimi, S., Fayek, A. R., & Sumati, V. (2021). Hybrid Artificial Intelligence HFS-RF-PSO Model for Construction Labor Productivity Prediction and Optimization. *Algorithms*, 14(7), 214.
- Eirgash, M. A., & Toğan, V. (2023). A novel oppositional teaching learning strategy based on the golden ratio to solve the Time-Cost-Environmental impact Trade-Off optimization problems. *Expert Systems with Applications*, 224, 119995.
- Elbasani, E., Njimbouom, S. N., Oh, T.-J., Kim, E.-H., Lee, H., & Kim, J.-D. (2021). GCRNN: graph convolutional recurrent neural network for compound–protein interaction prediction. *BMC Bioinformatics*, 22(S5), 616.
- Elman, J. L. (1991). Distributed representations, simple recurrent networks, and grammatical structure. *Machine Learning*, 7(2–3), 195–225.
- Eskandari, H., Imani, M., & Moghaddam, M. P. (2021). Convolutional and recurrent neural network based model for short-term load forecasting. *Electric Power Systems Research*, 195, 107173.
- Ezeldin, A. S., & Sharara, L. M. (2006). Neural Networks for Estimating the Productivity of Concreting Activities. *Journal of Construction Engineering and Management*, 132(6), 650–656.
- Feng, C.-W., & Chen, Y.-J. (2008, June 26). Using the MD CAD Model to Develop the Time-Cost Integrated Schedule for Construction Projects. <https://doi.org/10.22260/ISARC2008/0084>

- Feng, K., Chen, S., Lu, W., Wang, S., Yang, B., Sun, C., & Wang, Y. (2023). Embedding ensemble learning into simulation-based optimisation: a learning-based optimisation approach for construction planning. *Engineering, Construction and Architectural Management*, 30(1), 259–295.
- Florez-Perez, L., Song, Z., & Cortissoz, J. C. (2022). Using machine learning to analyze and predict construction task productivity. *Computer-Aided Civil and Infrastructure Engineering*, 37(12), 1602–1616.
- Flyvbjerg, B., Ansar, A., Budzier, A., Buhl, S., Cantarelli, C., Garbuio, M., Glenting, C., Holm, M. S., Lovallo, D., Lunn, D., Molin, E., Rønne, A., Stewart, A., & van Wee, B. (2018). Five things you should know about cost overrun. *Transportation Research Part A: Policy and Practice*, 118, 174–190.
- Francis, A., & Miresco, E. T. (2002). Decision support for project management using a chronographic approach. *Journal of Decision Systems*, 11(3–4), 383–404.
- Gao, Y., Chen, R., Qin, W., Wei, L., & Zhou, C. (2023). Learning from explainable data-driven tunneling graphs: A spatio-temporal graph convolutional network for clogging detection. *Automation in Construction*, 147, 104741.
- Garcia, J., Villavicencio, G., Altimiras, F., Crawford, B., Soto, R., Minatogawa, V., Franco, M., Martínez-Muñoz, D., & Yepes, V. (2022). Machine learning techniques applied to construction: A hybrid bibliometric analysis of advances and future directions. In *Automation in Construction* (Vol. 142, p. 104532). Elsevier.
- García Rodríguez, M. J., Rodríguez-Montequín, V., Ballesteros-Pérez, P., Love, P. E. D., & Signor, R. (2022). Collusion detection in public procurement auctions with machine learning algorithms. *Automation in Construction*, 133, 104047.
- Garg, R., Barpanda, S., S, G. R. S. N., & S, R. (2022). Machine Learning Algorithms for Time Series Analysis and Forecasting. <https://doi.org/10.48550/arXiv.2211.14387>
- Gholami, Y. (2023). Investigating Adoption of Digital Technologies in Construction Projects (Vol. 1954). Linköping University Electronic Press. <https://doi.org/10.3384/9789180750257>
- Gilmer, J., Schoenholz, S. S., Riley, P. F., Vinyals, O., & Dahl, G. E. (2017). Neural Message Passing for Quantum Chemistry.
- Golnaraghi, S., Zangenehmadar, Z., Moselhi, O., Alkass, S., & Vosoughi, A. R. (2019). Application of Artificial Neural Network(s) in Predicting Formwork Labour Productivity. *Advances in Civil Engineering*, 2019. <https://doi.org/10.1155/2019/5972620>
- Gong, M., Yan, C., Xu, W., Zhao, Z., Li, W., Liu, Y., & Li, S. (2023). Short-term wind power forecasting model based on temporal convolutional network and Informer. *Energy*, 283, 129171.
- Goodfellow, I. J., Shlens, J., & Szegedy, C. (2014). Explaining and Harnessing Adversarial Examples.

- Graves, A., Jaitly, N., & Mohamed, A. (2013). Hybrid speech recognition with Deep Bidirectional LSTM. 2013 IEEE Workshop on Automatic Speech Recognition and Understanding, 273–278.
- Graves, A., Mohamed, A., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 6645–6649.
- Günaydin Ünsal, A. (2022). Development Of A Monitoring System Based On Earned Value Analysis For Early Detection Of Time And Cost Variations In Public Building Construction Works, PhD Thesis, Trabzon.
- Gündüz, M., Nielsen, Y., & Özdemir, M. (2013). Quantification of Delay Factors Using the Relative Importance Index Method for Construction Projects in Turkey. *Journal of Management in Engineering*, 29(2), 133–139.
- Gunduz, M., Nielsen, Y., & Ozdemir, M. (2015). Fuzzy Assessment Model to Estimate the Probability of Delay in Turkish Construction Projects. *Journal of Management in Engineering*, 31(4).
- Guo, S. J., Chen, J. H., & Chiu, C. H. (2017). Fuzzy duration forecast model for wind turbine construction project subject to the impact of wind uncertainty. *Automation in Construction*, 81, 401–410.
- Haciefendioğlu, K., Mostofi, F., Toğan, V., & Başağa, H. B. (2022). CAM-K: a novel framework for automated estimating pixel area using K-Means algorithm integrated with deep learning based-CAM visualization techniques. *Neural Computing and Applications*, 34(20), 17741–17759.
- Hamilton, W. L. (2020). Graph Representation Learning Hamilton. Synthesis Lectures on Artificial Intelligence and Machine Learning, 14(3), 1–159.
- Hamilton, W. L., Ying, R., & Leskovec, J. (2017). Inductive Representation Learning on Large Graphs.
- Han, K. K., Cline, D., & Golparvar-Fard, M. (2015). Formalized knowledge of construction sequencing for visual monitoring of work-in-progress via incomplete point clouds and low-LoD 4D BIMs. *Advanced Engineering Informatics*, 29(4), 889–901.
- Hashemi Golpayegani, S. A., & Emamizadeh, B. (2007). Designing work breakdown structures using modular neural networks. *Decision Support Systems*, 44(1), 202–222.
- He, H., Yu, X., Zhang, J., Song, S., & Letaief, K. B. (2024). Message Passing Meets Graph Neural Networks: A New Paradigm for Massive MIMO Systems. *IEEE Transactions on Wireless Communications*, 23(5), 4709–4723.
- He, R., Zhang, C., Xiao, Y., Lu, X., Zhang, S., & Liu, Y. (2024). Deep spatio-temporal 3D dilated dense neural network for traffic flow prediction. *Expert Systems with Applications*, 237, 121394.

- Heidari, N., & Iosifidis, A. (2021). On the spatial attention in spatio-temporal graph convolutional networks for skeleton-based human action recognition. 2021 International Joint Conference on Neural Networks (IJCNN), 1–7.
- Heravi, G., & Eslamdoost, E. (2015). Applying Artificial Neural Networks for Measuring and Predicting Construction-Labor Productivity. *Journal of Construction Engineering and Management*, 141(10).
- Hu, Q., Lin, W., Tang, M., & Jiang, J. (2022). MBHAN: Motif-Based Heterogeneous Graph Attention Network. *Applied Sciences*, 12(12), 5931.
- Hu, Y., & Castro-Lacouture, D. (2019). Clash Relevance Prediction Based on Machine Learning. *Journal of Computing in Civil Engineering*, 33(2), 04018060.
- Hwang, S., & Liu, L. Y. (2010). Contemporaneous Time Series and Forecasting Methodologies for Predicting Short-Term Productivity. *Journal of Construction Engineering and Management*, 136(9), 1047–1055.
- Ibarra-Vazquez, G., Ramírez-Montoya, M. S., & Buenestado-Fernández, M. (2024). Forecasting Gender in Open Education Competencies: A Machine Learning Approach. *IEEE Transactions on Learning Technologies*, 17, 1236–1247.
- Jagielski, M., Oprea, A., Biggio, B., Liu, C., Nita-Rotaru, C., & Li, B. (2018). Manipulating Machine Learning: Poisoning Attacks and Countermeasures for Regression Learning. 2018 IEEE Symposium on Security and Privacy (SP), 19–35.
- Jia, Y., Wang, J., Shou, W., Hosseini, M. R., & Bai, Y. (2023). Graph neural networks for construction applications. *Automation in Construction*, 154, 104984.
- Jing, W., Song, X., Di, D., & Song, H. (2021). geoGAT: Graph Model Based on Attention Mechanism for Geographic Text Classification. *ACM Transactions on Asian and Low-Resource Language Information Processing*, 20(5), 1–18.
- Khemani, B., Patil, S., Kotecha, K., & Tanwar, S. (2024). A review of graph neural networks: concepts, architectures, techniques, challenges, datasets, applications, and future directions. *Journal of Big Data*, 11(1), 18.
- Kim, B.-C., & Kim, H.-J. (2014). Sensitivity of Earned Value Schedule Forecasting to S-Curve Patterns. *Journal of Construction Engineering and Management*, 140(7), 04014023.
- Kim, H., & Kim, C. (2020). Deep-Learning-Based Classification of Point Clouds for Bridge Inspection. *Remote Sensing*, 12(22), 3757.
- Kim, J., & Chi, S. (2020). Multi-camera vision-based productivity monitoring of earthmoving operations. *Automation in Construction*, 112, 103121.
- Kim, N., Park, H., Lee, J., & Choi, J. K. (2022). Short-Term Electrical Load Forecasting With Multidimensional Feature Extraction. *IEEE Transactions on Smart Grid*, 13(4), 2999–3013.

- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. <https://arxiv.org/abs/1412.6980>
- Kipf, T. N., & Welling, M. (2016). Semi-Supervised Classification with Graph Convolutional Networks. 5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings, 1–14.
- Koc, K., Ekmekcioğlu, Ö., & Gurgun, A. P. (2023). Developing a National Data-Driven Construction Safety Management Framework with Interpretable Fatal Accident Prediction. *Journal of Construction Engineering and Management*, 149(4), 04023010.
- Kumar, R., Mendes Moreira, J., & Chandra, J. (2023). DyGCN-LSTM: A dynamic GCN-LSTM based encoder-decoder framework for multistep traffic prediction. *Applied Intelligence*, 53(21), 25388–25411.
- Lee, M. (2022). An Ensemble Deep Learning Model with a Gene Attention Mechanism for Estimating the Prognosis of Low-Grade Glioma. *Biology*, 11(4), 586.
- Leon, H., Osman, H., Georgy, M., & Elsaid, M. (2018). System Dynamics Approach for Forecasting Performance of Construction Projects. *Journal of Management in Engineering*, 34(1), 04017049.
- Liao, R., Zhao, Z., Urtasun, R., & Zemel, R. S. (2019). LanczosNet: Multi-scale deep graph convo-lutional networks. 7th International Conference on Learning Representations, ICLR 2019, 1–18.
- Liu, H.-B. (2020). Predictive Spatio-Temporal Modelling With Neural Networks [PhD Thesis, James Cook University]. <https://doi.org/10.25903/fhnp%2Dg281>
- Liu, J., Luo, H., & Liu, H. (2022). Deep learning-based data analytics for safety in construction. *Automation in Construction*, 140, 104302.
- Liu, Q. hui, & Cao, Q. (2024). Dynamic control method of construction cost based on fuzzy neural network. *Automatika*, 65(4), 1339–1349.
- Liu, T., Gu, X., Li, S., Bai, Y., Wang, T., & Yang, X. (2023). Static voltage stability margin prediction considering new energy uncertainty based on graph attention networks and long short-term memory networks. *IET Renewable Power Generation*, 17(9), 2290–2301.
- Love, P. E. D. (2024). A Pragmatist Research Agenda for Employing Psychological Heuristics in Construction: Context, Design, Artificial Intelligence, and Performance Evaluation. *IEEE Transactions on Engineering Management*, 71, 11183–11197.
- Ma, Y., Xie, T., Li, J., & Maciejewski, R. (2020). Explaining Vulnerabilities to Adversarial Machine Learning through Visual Analytics. *IEEE Transactions on Visualization and Computer Graphics*, 26(1), 1075–1085.
- Manessi, F., Rozza, A., & Manzo, M. (2020). Dynamic graph convolutional networks. *Pattern Recognition*, 97, 107000.

- Mani, G. F., Feniosky, P. M., & Savarese, S. (2009). D4AR-A 4-dimensional augmented reality model for automating construction progress monitoring data collection, processing and communication. *Electronic Journal of Information Technology in Construction*, 14, 129–153. <https://www.itcon.org/paper/2009/13>
- Marcheggiani, D., & Titov, I. (2017). Encoding Sentences with Graph Convolutional Networks for Semantic Role Labeling.
- Mercieca, J., & Kadiramanathan, V. (2016). Estimation and Identification of Spatio-Temporal Models with Applications in Engineering, Healthcare and Social Science. *Annual Reviews in Control*, 42, 285–298.
- Mohammed, A., Almousa, A., Ghaithan, A., & Hadidi, L. A. (2021). The Role of Blockchain in Improving the Processes and Workflows in Construction Projects. *Applied Sciences*, 11(19), 8835.
- Momade, M. H., Shahid, S., Hainin, M. R. bin, Nashwan, M. S., & Tahir Umar, A. (2020). Modelling labour productivity using SVM and RF: a comparative study on classifiers performance. *International Journal of Construction Management*, 0(0), 1–11.
- Mostofi, F., Behzat Tokdemir, O., & Toğan, V. (2024). Generating synthetic data with variational autoencoder to address class imbalance of graph attention network prediction model for construction management. *Advanced Engineering Informatics*, 62.
- Mostofi, F., & Toğan, V. (2022a). Construction Safety Hazard Recommendation using Graph Representation Learning. 7th International Project and Construction Management Conference (IPCMC 2022), 1376–1386.
- Mostofi, F., & Toğan, V. (2022b). Predicting the Outcome of Construction Accidents Using Dual Interface Safety Network. In SSRN.
- Mostofi, F., & Toğan, V. (2023a). A Data-driven Recommendation System for Construction Safety Risk Assessment. *Journal of Construction Engineering and Management*, 149(Accepted).
- Mostofi, F., & Toğan, V. (2023b). Construction safety predictions with multi-head attention graph and sparse accident networks. *Automation in Construction*, 156.
- Mostofi, F., & Toğan, V. (2023c). Explainable Safety Risk Management in Construction With Unsupervised Learning. In *Artificial Intelligence and Machine Learning Techniques for Civil Engineering* (pp. 273–305). IGI Global.
- Mostofi, F., & Toğan, V. (2023d). Predicting Construction Accident Outcomes Using Graph Convolutional and Dual-Edge Safety Networks. *Arabian Journal for Science and Engineering*.
- Mostofi, F., Toğan, V., Ayözen, Y. E., & Tokdemir, O. B. (2022a). Construction Safety Risk Model with Construction Accident Network: A Graph Convolutional Network Approach. *Sustainability (Switzerland)*, 14(23).

- Mostofi, F., Toğan, V., Ayözen, Y. E., & Tokdemir, O. B. (2022b). Predicting the Impact of Construction Rework Cost Using an Ensemble Classifier. *Sustainability (Switzerland)*, 14(22).
- Mostofi, F., Toğan, V., & Başağa, H. B. (2021). House price prediction: A data-centric aspect approach on performance of combined principal component analysis with deep neural network model. *Journal of Construction Engineering, Management & Innovation*, 4(2), 106–116.
- Mostofi, F., Toğan, V., & Başağa, H. B. (2022). Real-estate price prediction with deep neural network and principal component analysis. *Organization, Technology and Management in Construction*, 14(1).
- Mostofi, F., Toğan, V., Başağa, H. B., Çıtıpıtıoğlu, A., & Tokdemir, O. B. (2023). Multiedge Graph Convolutional Network for House Price Prediction. *Journal of Construction Engineering and Management*, 149(11).
- Mostofi, F., Toğan, V., & Tokdemir, O. B. (2023). Enhancing construction productivity prediction through variational autoencoders and graph attention network. <https://doi.org/10.31462/icearc.2023.cme227>
- Mostofi, F., Tokdemir, O. B., & Toğan, V. (2020). Structural Performance of An Existing Building Roof Subjected to Additional PV Panel Load. 2020 2nd International Conference on Photovoltaic Science and Technologies, PVCon 2020.
- Mostofi, F., Tokdemir, O. B., & Toğan, V. (2023). Comprehensive Root Cause Analysis of Construction Defects Using Semisupervised Graph Representation Learning. *Journal of Construction Engineering and Management*, 149(9).
- Mostofi, F., Tokdemir, O. B., Toğan, V., & Ardit, D. (2024). Predicting the Cost of Rework in High-Rise Buildings Using Graph Convolutional Networks. *Journal of Construction Engineering and Management*, 150(8).
- Mostofi, S., & Altunışık, A. C. (2024a). Recent Advances in CFD-based Bridge Fire Evaluations: A Brief Review. *Civil Engineering Research Journal*, 14(4).
- Mostofi, S., & Altunışık, A. C. (2024b). Surrogate Model-Driven Estimation of Adiabatic Surface Temperature of Fire Exposed Suspension Bridge Towers. *Fire Technology*.
- Mostofi, S., Yesevi Okur, F., & Altunışık, A. C. (2023). Fire assessment of suspension bridge towers: A machine learning-based prediction of AST under varying vehicle fire conditions. Proceedings of 3rd International Civil Engineering and Architecture Congress (ICEARC'23), 1819–1827.
- MOU, X. (2019). Construction Progress Measurement Using Deep Learning. Texas A&M University.
- Mulerikkal, J., Thandassery, S., Rejathalal, V., & Kunnankody, D. M. D. (2022). Performance improvement for metro passenger flow forecast using spatio-temporal deep neural network. *Neural Computing and Applications*, 34(2), 983–994.

- Nasution, S. H. (1994). Fuzzy Critical Path Method. *IEEE Transactions on Systems, Man and Cybernetics*, 24(1), 48–57.
- Navon, R. (2007). Research in automated measurement of project performance indicators. *Automation in Construction*, 16(2), 176–188.
- Navon, R., & Goldschmidt, E. (2003). Monitoring labor inputs: Automated-data-collection model and enabling technologies. *Automation in Construction*, 12(2), 185–199.
- NIST. (2022). AI Risk Management Framework: Second Draft Notes for Reviewers: Call for comments and contributions.
- Nurhendi, R. N., Khoiry, M. A., & Hamzah, N. (2022). Conceptual Framework Factors Affecting Construction Labour Productivity. *Jurnal Kejuruteraan*, 34(1), 89–99.
- Ochieng, E. G., Price, A. D. F., Ruan, X., Egbu, C. O., & Moore, D. (2013). The effect of cross-cultural uncertainty and complexity within multicultural construction teams. *Engineering, Construction and Architectural Management*, 20(3), 307–324. <https://doi.org/10.1108/09699981311324023/FULL/PDF>
- Ogoke, F., Meidani, K., Hashemi, A., & Farimani, A. B. (2020). Graph Convolutional Neural Networks for Body Force Prediction. *Machine Learning: Science and Technology*, 2(4). <https://doi.org/10.1088/2632-2153/ac1fc9>
- Orgut, R. E., Batouli, M., Zhu, J., Mostafavi, A., & Jaselskis, E. J. (2016). Metrics That Matter: Evaluation of Metrics and Indicators for Project Progress Measurement, Performance Assessment, and Performance Forecasting during Construction. *Construction Research Congress 2016: Old and New Construction Technologies Converge in Historic San Juan - Proceedings of the 2016 Construction Research Congress*, CRC 2016, 189–198.
- Özcan, A. (2022). Applying Graph Convolution Networks to Recommender Systems based on graph topology. *DÜMF Mühendislik Dergisi*.
- Pan, X., Zhong, B., Wang, Y., & Shen, L. (2022). Identification of accident-injury type and bodypart factors from construction accident reports: A graph-based deep learning framework. *Advanced Engineering Informatics*, 54.
- Pan, Y., Fu, X., & Zhang, L. (2022). Data-driven multi-output prediction for TBM performance during tunnel excavation: An attention-based graph convolutional network approach. *Automation in Construction*, 141(June), 104386.
- Pan, Y., & Zhang, L. (2021). Roles of artificial intelligence in construction engineering and management: A critical review and future trends. *Automation in Construction*, 122(December 2020), 103517.
- Papernot, N., McDaniel, P., Goodfellow, I., Jha, S., Celik, Z. B., & Swami, A. (2017). Practical Black-Box Attacks against Machine Learning. *Proceedings of the 2017 ACM on Asia Conference on Computer and Communications Security*, 506–519.

- Papernot, N., McDaniel, P., Jha, S., Fredrikson, M., Celik, Z. B., & Swami, A. (2016). The Limitations of Deep Learning in Adversarial Settings. 2016 IEEE European Symposium on Security and Privacy (EuroS&P), 372–387.
- Patel, T., Guo, B. H. W., & Zou, Y. (2021). A scientometric review of construction progress monitoring studies. *Engineering, Construction and Architectural Management, ahead-of-p(ahead-of-print)*.
- Peña-Mora, F., & Li, M. (2001). Dynamic Planning and Control Methodology for Design/Build Fast-Track Construction Projects. *Journal of Construction Engineering and Management*, 127(1), 1–17.
- Pour Rahimian, F., Seyedzadeh, S., Oliver, S., Rodriguez, S., & Dawood, N. (2020). On-demand monitoring of construction projects through a game-like hybrid application of BIM and machine learning. *Automation in Construction*, 110.
- Project Management Institute. (2021). A Guide to the Project Management Body of Knowledge (PMBOK Guide) -- Seventh Edition and The Standard for Project Management (7th ed.).
- Rafiei, M. H., & Adeli, H. (2016). A Novel Machine Learning Model for Estimation of Sale Prices of Real Estate Units. *Journal of Construction Engineering and Management*, 142(2), 04015066.
- Ravikumar, A., & Sriraman, H. (2023). Mitigating Vanishing Gradient in SGD Optimization in Neural Networks (pp. 1–11).
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. NAACL-HLT 2016 - 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Proceedings of the Demonstrations Session, 97–101.
- Roodschild, M., Gotay Sardiñas, J., & Will, A. (2020). A new approach for the vanishing gradient problem on sigmoid activation. *Progress in Artificial Intelligence*, 9(4), 351–360.
- Rossi, A., Tiezzi, M., Dimitri, G. M., Bianchini, M., Maggini, M., & Scarselli, F. (2018). Inductive–Transductive Learning with Graph Neural Networks (pp. 201–212).
- Roy, A., Roy, K. K., Ahsan Ali, A., Amin, M. A., & Rahman, A. K. M. M. (2021). SST-GNN: Simplified Spatio-Temporal Traffic Forecasting Model Using Graph Neural Network. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: Vol. 12714 LNAI (pp. 90–102). Springer Science and Business Media Deutschland GmbH.
- Sacks, R., Navon, R., & Goldschmidt, E. (2003). Building Project Model Support for Automated Labor Monitoring. *Journal of Computing in Civil Engineering*, 17(1), 19–27.

- Sakhakarmi, S., Park, J., & Cho, C. (2019). Enhanced Machine Learning Classification Accuracy for Scaffolding Safety Using Increased Features. *Journal of Construction Engineering and Management*, 145(2).
- Santos, R. B. dos, & Jungles, A. E. (2016). Risk Level Assessment in Construction Projects Using the Schedule Performance Index. *Journal of Construction Engineering*, 2016, 1–8.
- Scarselli, F., Gori, M., Ah Chung Tsoi, Hagenbuchner, M., & Monfardini, G. (2009). The Graph Neural Network Model. *IEEE Transactions on Neural Networks*, 20(1), 61–80.
- Scherer, P. M. (2024). Distributional and relational inductive biases for graph representation learning in biomedicine [PhD Thesis, University of Cambridge]. <https://www.cl.cam.ac.uk/>
- Selim, H. (2009). Determinants of house prices in Turkey: Hedonic regression versus artificial neural network. *Expert Systems with Applications*, 36(2 PART 2), 2843–2852.
- Shi, J. J., Cheung, S. O., & Arditi, D. (2001). Construction Delay Computation Method. *Journal of Construction Engineering and Management*, 127(1), 60–65.
- Soibelman, L., Asce, M., & Kim, H. (2002). Data Preparation Process for Construction Knowledge Generation through Knowledge Discovery in Databases. *Journal of Computing in Civil Engineering*, 16(1), 39–48.
- Son, H., Kim, C., & Kim, C. (2012). Automated Color Model-Based Concrete Detection in Construction-Site Images by Using Machine Learning Algorithms. *Journal of Computing in Civil Engineering*, 26(3), 421–433.
- Son, H., Pham, V.-T., Jang, Y., & Kim, S.-E. (2021). Damage Localization and Severity Assessment of a Cable-Stayed Bridge Using a Message Passing Neural Network. *Sensors*, 21(9), 3118.
- Suhail, S. A., & Neale, R. H. (1994). CPM/LOB: New Methodology to Integrate CPM and Line of Balance. *Journal of Construction Engineering and Management*, 120(3), 667–684.
- Sukhbaatar, S., Szlam, A., & Fergus, R. (2016). Learning Multiagent Communication with Backpropagation.
- Tang, H., Ma, G., Chen, Y., Guo, L., Wang, W., Zeng, B., & Zhan, L. (2020). Adversarial Attack on Hierarchical Graph Pooling Neural Networks.
- Tang, S., & Golparvar-Fard, M. (2021). Machine Learning-Based Risk Analysis for Construction Worker Safety from Ubiquitous Site Photos and Videos. *Journal of Computing in Civil Engineering*, 35(6), 04021020.

- Teizer, J. (2015). Status quo and open challenges in vision-based sensing and tracking of temporary resources on infrastructure construction sites. *Advanced Engineering Informatics*, 29(2), 225–238.
- Theodoropoulos, T., Maroudis, A.-C., Makris, A., & Tserpes, K. (2024). WEST GCN-LSTM: Weighted Stacked Spatio-Temporal Graph Neural Networks for Regional Traffic Forecasting.
- Tian, D., Li, M., Han, S., & Shen, Y. (2022). A Novel and Intelligent Safety-Hazard Classification Method with Syntactic and Semantic Features for Large-Scale Construction Projects. *Journal of Construction Engineering and Management*, 148(10).
- Vatter, J., Mayer, R., & Jacobsen, H.-A. (2024). The Evolution of Distributed Systems for Graph Neural Networks and Their Origin in Graph Processing and Deep Learning: A Survey. *ACM Computing Surveys*, 56(1), 1–37.
- Veličković, P. (2023). Everything is connected: Graph neural networks. *Current Opinion in Structural Biology*, 79, 102538.
- Veličković, P., Casanova, A., Liò, P., Cucurull, G., Romero, A., & Bengio, Y. (2018). Graph attention networks. 6th International Conference on Learning Representations, ICLR 2018 - Conference Track Proceedings, 39–41.
- Vick, S., & Brilakis, I. (2018). Road Design Layer Detection in Point Cloud Data for Construction Progress Monitoring. *Journal of Computing in Civil Engineering*, 32(5), 04018029.
- Wang, H. J., Zhang, J. P., Chau, K. W., & Anson, M. (2004). 4D dynamic management for construction planning and resource utilization. *Automation in Construction*, 13(5 SPEC. ISS.), 575–589.
- Wang, J., Zhang, Q., & Zhao, D. (2022). Highway Lane Change Decision-Making via Attention-Based Deep Reinforcement Learning. *IEEE/CAA Journal of Automatica Sinica*, 9(3), 567–569.
- Wang, L., Cao, H., Xu, H., & Liu, H. (2022). A gated graph convolutional network with multi-sensor signals for remaining useful life prediction. *Knowledge-Based Systems*, 252, 109340.
- Wang, Y., & Chaudhuri, K. (2018). Data Poisoning Attacks against Online Learning.
- Wang, Z., Sacks, R., & Yeung, T. (2022). Exploring graph neural networks for semantic enrichment: Room type classification. *Automation in Construction*, 134, 104039.
- Wells, L., & Bednarz, T. (2021). Explainable AI and Reinforcement Learning—A Systematic Review of Current Approaches and Trends. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.550030>

- Wu, L., Sun, P., Hong, R., Fu, Y., Wang, X., & Wang, M. (2018). SocialGCN: An Efficient Graph Convolutional Network based Model for Social Recommendation. <https://arxiv.org/abs/1811.02815>
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Yu, P. S. (2021). A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1), 4–24.
- Xia, L., Zheng, P., Li, X., Gao, Robert. X., & Wang, L. (2022). Toward cognitive predictive maintenance: A survey of graph-based approaches. *Journal of Manufacturing Systems*, 64, 107–120.
- Xing, H., Chen, A., & Zhang, X. (2023). RL-GCN: Traffic flow prediction based on graph convolution and reinforcement learning for smart cities. *Displays*, 80, 102513.
- Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network.
- Yan, W., & Escamilla, E. (2019). Construction Progress Measurement Using Deep Learning, Master Thesis, Texas.
- Yan, X., Ai, T., Yang, M., & Yin, H. (2019). A graph convolutional neural network for classification of building patterns using spatial vector data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 259–273.
- Yan, X., Zhang, H., & Gao, H. (2022). Mutually coupled detection and tracking of trucks for monitoring construction material arrival delays. *Automation in Construction*, 142, 104491.
- Yang, B., Kang, Y., Zhang, L., & Li, H. (2021). GGAC: Multi-relational image gated GCN with attention convolutional binary neural tree for identifying disease with chest X-rays. *Pattern Recognition*, 120, 108113.
- Yao, L., Mao, C., & Luo, Y. (2019). Graph Convolutional Networks for Text Classification. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), 7370–7377.
- Yavan, F. (2023). Intelligent Optimization Of Steel Structures Through BIM-Based Visual Programming Platform And Tools, Master Thesis, Trabzon.
- Ying, Z., & Pheng, L. S. (2014). Project communication management in complex environments. In *Project Communication Management in Complex Environments* (Vol. 9789814560). Springer Singapore.
- Yu, B., Yin, H., & Zhu, Z. (2018). Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. *IJCAI International Joint Conference on Artificial Intelligence*, 2018-July, 3634–3640.
- Zhang, H., Wu, B., Yuan, X., Pan, S., Tong, H., & Pei, J. (2024). Trustworthy Graph Neural Networks: Aspects, Methods, and Trends. *Proceedings of the IEEE*, 112(2), 97–139.

- Zhang, J., Zheng, Y., Qi, D., Li, R., Yi, X., & Li, T. (2018). Predicting citywide crowd flows using deep spatio-temporal residual networks. *Artificial Intelligence*, 259, 147–166.
- Zhang, L., Jiang, C., Chai, Z., & He, Y. (2024). Adversarial attack and training for deep neural network based power quality disturbance classification. *Engineering Applications of Artificial Intelligence*, 127, 107245.
- Zhang, W., Yu, Y., Qi, Y., Shu, F., & Wang, Y. (2019). Short-term traffic flow prediction based on spatio-temporal analysis and CNN deep learning. *Transportmetrica A: Transport Science*, 15(2), 1688–1711.
- Zhang, X., Bakis, N., Lukins, T. C., Ibrahim, Y. M., Wu, S., Kagioglou, M., Aouad, G., Kaka, A. P., & Trucco, E. (2009). Automating progress measurement of construction projects. *Automation in Construction*, 18(3), 294–301.
- Zhang, X., & Zhang, X. (2023). An automated project carbon planning, monitoring and forecasting system integrating building information model and earned value method. *Journal of Cleaner Production*, 397.
- Zhang, X., Zhang, X., Liu, J., Wu, B., & Hu, Y. (2023). Graph features dynamic fusion learning driven by multi-head attention for large rotating machinery fault diagnosis with multi-sensor data. *Engineering Applications of Artificial Intelligence*, 125, 106601.
- Zhang, Y. (2020). Graph Deep Learning Models for Network-based Spatio-Temporal Data Forecasting: From Dense to Sparse, PhD Thesis, London.
- Zheng, H., Xie, K., Zhu, Y., Lin, J., & Wang, L. (2024). An reconstruction bidirectional recurrent neural network -based deinterleaving method for known radar signals in open-set scenarios. *IET Radar, Sonar & Navigation*, 18(6), 965–981.
- Zhong, B., Xing, X., Love, P., Wang, X., & Luo, H. (2019). Convolutional neural network: Deep learning-based classification of building quality problems. *Advanced Engineering Informatics*, 40, 46–57.
- Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C., & Sun, M. (2020). Graph neural networks: A review of methods and applications. *AI Open*, 1, 57–81.
- Zhou, L., & Wang, H. (2024). MST-GAT: A multi-perspective spatial-temporal graph attention network for multi-sensor equipment remaining useful life prediction. *Information Fusion*, 110, 102462.
- Zhou, Z. G. (2022). Research on Sentiment Analysis Model of Short Text Based on Deep Learning. *Scientific Programming*, 2022, 1–7.

6. EKLER

6.1. Ek 1. Önerilen Mekansal-zamansal Modelin Python Kodları

6.1.1. GatedGNN Modeli

Şekiller 85-89, PyTorch kullanılarak geliştirilen, önerilen beş mekansal-zamansal ML modelinin (GatedGNN, GatedGNN-RNN, GatedGNN-GRU, RNN-GatedGNN ve GRU-GatedGNN) Python kodu detaylarını göstermektedir.

```
1 import torch.nn as nn
2 import torch.nn.functional as F
3 from torch_geometric.nn import GatedGraphConv
4
5
6 class GatedGraphModel(nn.Module):
7     """
8     Gated Graph Neural Network Model.
9
10    Args:
11        input_dim (int): Dimensionality of input features.
12        hidden_dim (int): Dimensionality of hidden layers.
13        output_dim (int): Dimensionality of the output layer.
14        num_layers (int): Number of GatedGraphConv layers.
15        dropout_rate (float): Dropout rate to be applied during training.
16
17    Methods:
18        forward(x, edge_index):
19            Performs the forward pass of the model.
20    """
21
22    def __init__(self, input_dim: int, hidden_dim: int, output_dim: int, num_layers: int, dropout_rate: float):
23        """
24        Initializes the GatedGraphModel.
25        """
26        super(GatedGraphModel, self).__init__()
27        self.conv = GatedGraphConv(hidden_dim, num_layers)
28        self.fc1 = nn.Linear(input_dim, hidden_dim)
29        self.fc2 = nn.Linear(hidden_dim, output_dim)
30        self.dropout_rate = dropout_rate
31
32    def forward(self, x: torch.Tensor, edge_index: torch.Tensor) -> torch.Tensor:
33        """
34        Forward pass for the model.
35
36        Args:
37            x (torch.Tensor): Node feature matrix of shape [num_nodes, input_dim].
38            edge_index (torch.Tensor): Graph connectivity matrix (edge list) of shape [2, num_edges].
39
40        Returns:
41            torch.Tensor: Output feature matrix of shape [num_nodes, output_dim].
42        """
43        x = F.relu(self.fc1(x)) # Apply linear transformation followed by ReLU activation
44        x = self.conv(x, edge_index) # Apply the gated graph convolution
45        x = F.dropout(x, p=self.dropout_rate, training=self.training) # Apply dropout during training
46        x = self.fc2(x) # Apply final linear transformation
47        return x
48
```

Ek Şekil 1. GatedGNN modeli için kullanılan Python kodu detayları.

```

1 import torch
2 import torch.nn as nn
3 import torch.nn.functional as F
4 from torch_geometric.nn import GatedGraphConv
5
6 class GatedGNN_RNN(nn.Module):
7     """
8     Gated Graph Convolutional Network with Recurrent Neural Network.
9
10    Args:
11        input_dim (int): Dimensionality of input features.
12        hidden_dim (int): Dimensionality of hidden layers.
13        output_dim (int): Dimensionality of the output layer.
14        num_layers (int, optional): Number of GatedGraphConv layers (default=2).
15        num_rnn_layers (int, optional): Number of RNN layers (default=2).
16        dropout_rate (float, optional): Dropout rate to be applied during training (default=0.3).
17
18    Methods:
19        forward(x, edge_index):
20        """ Performs the forward pass of the model.
21    """
22
23    def __init__(self, input_dim: int, hidden_dim: int, output_dim: int, num_layers: int = 2, num_rnn_layers: int = 2,
24                 dropout_rate: float = 0.3):
25        """
26        Initializes the GatedGNN_RNN model.
27        """
28        super(GatedGNN_RNN, self).__init__()
29        self.fc1 = nn.Linear(input_dim, hidden_dim) # Initial linear transformation
30        self.gcn = GatedGraphConv(hidden_dim, num_layers) # Gated graph convolution layers
31        self.rnn = nn.RNN(hidden_dim, hidden_dim, num_rnn_layers, batch_first=True) # Recurrent neural network layers
32        self.fc2 = nn.Linear(hidden_dim, output_dim) # Final linear transformation
33        self.dropout_rate = dropout_rate # Dropout rate for regularization
34
35    def forward(self, x: torch.Tensor, edge_index: torch.Tensor) -> torch.Tensor:
36        """
37        Forward pass of the model.
38
39        Args:
40            x (torch.Tensor): Node feature matrix of shape [num_nodes, input_dim].
41            edge_index (torch.Tensor): Graph connectivity matrix (edge list) of shape [2, num_edges].
42
43        Returns:
44            torch.Tensor: Log softmax output of shape [num_nodes, output_dim].
45        """
46        x = F.relu(self.fc1(x)) # Apply linear transformation with ReLU
47        x = self.gcn(x, edge_index) # Apply gated graph convolution
48        x = x.unsqueeze(1) # Add sequence dimension for RNN
49        x, _ = self.rnn(x) # Apply RNN layers
50        x = x.squeeze(1) # Remove sequence dimension
51        x = F.dropout(x, p=self.dropout_rate, training=self.training) # Apply dropout
52        x = self.fc2(x) # Final linear transformation
53        return F.log_softmax(x, dim=1) # Log softmax for classification
54

```

Ek Şekil 2. GatedGNN-RNN modeli için kullanılan Python kodu detayları.

```

1  import torch
2  import torch.nn as nn
3  import torch.nn.functional as F
4  from torch_geometric.nn import GatedGraphConv
5
6  class GatedGCN_GRU(nn.Module):
7      """
8      Gated Graph Convolutional Network with GRU-based Recurrent Neural Network.
9
10     Args:
11         input_dim (int): Dimensionality of input features.
12         hidden_dim (int): Dimensionality of hidden layers.
13         output_dim (int): Dimensionality of the output layer.
14         num_gru_layers (int, optional): Number of GRU layers (default=2).
15         num_layers (int, optional): Number of GatedGraphConv layers (default=2).
16         dropout_rate (float, optional): Dropout rate to be applied during training (default=0.3).
17
18     Methods:
19         forward(x, edge_index):
20             Performs the forward pass of the model.
21     """
22
23     def __init__(self, input_dim: int, hidden_dim: int, output_dim: int, num_gru_layers: int = 2, num_layers: int = 2,
24                 dropout_rate: float = 0.3):
25         """
26         Initializes the GatedGNN_GRU model.
27         """
28         super(GatedGNN_GRU, self).__init__()
29         self.fc1 = nn.Linear(input_dim, hidden_dim) # Initial linear transformation
30         self.gcn = GatedGraphConv(hidden_dim, num_layers) # Gated graph convolution layers
31         self.gru = nn.GRU(hidden_dim, hidden_dim, num_gru_layers, batch_first=True) # GRU layers
32         self.fc2 = nn.Linear(hidden_dim, output_dim) # Final linear transformation
33         self.dropout_rate = dropout_rate # Dropout rate for regularization
34
35     def forward(self, x: torch.Tensor, edge_index: torch.Tensor) -> torch.Tensor:
36         """
37         Forward pass of the model.
38
39         Args:
40             x (torch.Tensor): Node feature matrix of shape [num_nodes, input_dim].
41             edge_index (torch.Tensor): Graph connectivity matrix (edge list) of shape [2, num_edges].
42
43         Returns:
44             torch.Tensor: Log softmax output of shape [num_nodes, output_dim].
45         """
46         x = F.relu(self.fc1(x)) # Apply linear transformation with ReLU
47         x = self.gcn(x, edge_index) # Apply gated graph convolution
48         x = x.unsqueeze(1) # Add sequence dimension for GRU
49         x, _ = self.gru(x) # Apply GRU layers
50         x = x.squeeze(1) # Remove sequence dimension
51         x = F.dropout(x, p=self.dropout_rate, training=self.training) # Apply dropout
52         x = self.fc2(x) # Final linear transformation
53         return F.log_softmax(x, dim=1) # Log softmax for classification
54

```

Ek Şekil 3. GatedGNN-GRU modeli için kullanılan Python kodu detayları.

```

1  import torch
2  import torch.nn as nn
3  import torch.nn.functional as F
4  from torch_geometric.nn import GatedGraphConv
5  from torch_geometric.data import DataLoader
6
7  class RNN_GatedGNN(nn.Module):
8      """
9      Recurrent Neural Network combined with Gated Graph Convolutional Network.
10
11      Args:
12          input_dim (int): Dimensionality of input features.
13          hidden_dim (int): Dimensionality of hidden layers.
14          output_dim (int): Dimensionality of the output layer.
15          num_layers (int, optional): Number of GatedGraphConv layers (default=2).
16          num_rnn_layers (int, optional): Number of RNN layers (default=2).
17          dropout_rate (float, optional): Dropout rate to be applied during training (default=0.3).
18
19      Methods:
20          forward(x, edge_index):
21              Performs the forward pass of the model.
22      """
23
24      def __init__(self, input_dim: int, hidden_dim: int, output_dim: int, num_layers: int = 2, num_rnn_layers: int = 2,
25                  dropout_rate: float = 0.3):
26          """
27          Initializes the RNN_GatedGNN model.
28          """
29          super(RNN_GatedGNN, self).__init__()
30          self.rnn = nn.RNN(input_dim, hidden_dim, num_rnn_layers, batch_first=True) # Recurrent layers
31          self.gcn = GatedGraphConv(hidden_dim, num_layers) # Gated graph convolution layers
32          self.fc1 = nn.Linear(hidden_dim, hidden_dim) # First linear transformation
33          self.fc2 = nn.Linear(hidden_dim, output_dim) # Final linear transformation
34          self.dropout_rate = dropout_rate # Dropout rate for regularization
35
36      def forward(self, x: torch.Tensor, edge_index: torch.Tensor) -> torch.Tensor:
37          """
38          Forward pass of the model.
39
40          Args:
41              x (torch.Tensor): Node feature matrix of shape [num_nodes, input_dim].
42              edge_index (torch.Tensor): Graph connectivity matrix (edge list) of shape [2, num_edges].
43
44          Returns:
45              torch.Tensor: Log softmax output of shape [num_nodes, output_dim].
46          """
47          x = x.unsqueeze(1) # Add sequence dimension for RNN
48          x, _ = self.rnn(x) # Apply RNN layers
49          x = x.squeeze(1) # Remove sequence dimension
50          x = F.relu(self.fc1(x)) # Apply linear transformation with ReLU
51          x = self.gcn(x, edge_index) # Apply gated graph convolution
52          x = F.dropout(x, p=self.dropout_rate, training=self.training) # Apply dropout
53          x = self.fc2(x) # Final linear transformation
54          return F.log_softmax(x, dim=1) # Log softmax for classification
55

```

Ek Şekil 4. RNN-GatedGNN modeli için kullanılan Python kodu detayları.

```

1  import torch
2  import torch.nn as nn
3  import torch.nn.functional as F
4  from torch_geometric.nn import GatedGraphConv
5  from torch_geometric.data import DataLoader
6
7  class GRU_GatedGNN(nn.Module):
8      """
9      GRU-based Recurrent Neural Network combined with Gated Graph Convolutional Network.
10
11      Args:
12          input_dim (int): Dimensionality of input features.
13          hidden_dim (int): Dimensionality of hidden layers.
14          output_dim (int): Dimensionality of the output layer.
15          num_layers (int, optional): Number of GatedGraphConv layers (default=2).
16          num_gru_layers (int, optional): Number of GRU layers (default=2).
17          dropout_rate (float, optional): Dropout rate to be applied during training (default=0.3).
18
19      Methods:
20          forward(x, edge_index):
21              || Performs the forward pass of the model.
22      """
23
24      def __init__(self, input_dim: int, hidden_dim: int, output_dim: int, num_layers: int = 2, num_gru_layers: int = 2,
25                  dropout_rate: float = 0.3):
26          """
27          Initializes the GRU_GatedGNN model.
28          """
29          super(GRU_GatedGNN, self).__init__()
30          self.gru = nn.GRU(input_dim, hidden_dim, num_layers=num_gru_layers, batch_first=True) # GRU layers
31          self.gcn = GatedGraphConv(hidden_dim, num_layers) # Gated graph convolution layers
32          self.fc1 = nn.Linear(hidden_dim, hidden_dim) # First linear transformation
33          self.fc2 = nn.Linear(hidden_dim, output_dim) # Final linear transformation
34          self.dropout_rate = dropout_rate # Dropout rate for regularization
35
36      def forward(self, x: torch.Tensor, edge_index: torch.Tensor) -> torch.Tensor:
37          """
38          Forward pass of the model.
39
40          Args:
41              x (torch.Tensor): Node feature matrix of shape [num_nodes, input_dim].
42              edge_index (torch.Tensor): Graph connectivity matrix (edge list) of shape [2, num_edges].
43
44          Returns:
45              || torch.Tensor: Log softmax output of shape [num_nodes, output_dim].
46          """
47          x = x.unsqueeze(1) # Add sequence dimension for GRU
48          x, _ = self.gru(x) # Apply GRU layers
49          x = x.squeeze(1) # Remove sequence dimension
50          x = F.relu(self.fc1(x)) # Apply linear transformation with ReLU
51          x = self.gcn(x, edge_index) # Apply gated graph convolution
52          x = F.dropout(x, p=self.dropout_rate, training=self.training) # Apply dropout
53          x = self.fc2(x) # Final linear transformation
54          return F.log_softmax(x, dim=1) # Log softmax for classification
55

```

Ek Şekil 5. GRU-GatedGNN modeli için kullanılan Python kodu detayları.

6.2. Ek 2. Mekansal-zamansal Modellerin Doğruluk Performansları

Ek Tablo 1 ve 2 çalışmada incelenen 40 adet mekansal-zamansal CPI ve SPI tahmin modelinin doğruluk (Acc.) ve F1 skoru (F1) performanslarını göstermektedir.

Ek Tablo 1. Farklı pencerelerde CPI tahmininde kullanılan mekansal-zamansal modellerin performansı.

Model name	Proje	Pencere 1		Pencere 2		Pencere 3		Pencere 4		Pencere 5		Pencere 6		Pencere 7		Pencere 8		Pencere 9	
		Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1	Acc.	F1
Bi-GRU-GAT	Adana	82	80	81	81	31	30	24	23	79	72	82	81	-	-	-	-	-	-
	Bursa	76	68	83	79	86	81	84	77	79	69	79	72	79	69	81	75	-	-
	Elazığ	56	53	64	61	71	70	57	56	77	77	77	76	-	-	-	-	-	-
	Yozgat	83	76	82	76	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Bi-GRU-GCN	Adana	73	69	72	70	31	30	28	27	75	68	77	74	-	-	-	-	-	-
	Bursa	72	56	75	68	78	69	79	66	75	61	75	65	75	62	75	64	-	-
	Elazığ	70	68	68	67	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Yozgat	77	61	76	67	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Bi-LSTM-GAT	Adana	76	70	75	75	30	29	23	23	73	66	77	74	-	-	-	-	-	-
	Bursa	74	65	80	75	84	79	84	76	78	68	77	68	78	65	79	71	-	-
	Elazığ	61	57	72	71	72	70	72	71	79	79	73	73	79	78	71	70	66	67
	Yozgat	79	67	80	73	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Bi-LSTM-GCN	Adana	67	64	69	68	30	29	31	30	74	65	68	64	-	-	-	-	-	-
	Bursa	71	56	73	66	78	69	79	67	75	59	75	65	75	62	76	65	-	-
	Elazığ	64	61	70	69	66	64	52	52	71	71	55	54	73	72	70	68	66	66
	Yozgat	76	59	76	67	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Bi-RNN-GAT	Adana	85	83	79	79	34	32	28	28	79	72	84	81	-	-	-	-	-	-
	Bursa	78	69	85	82	86	82	85	76	81	72	80	74	81	73	82	75	-	-
	Elazığ	58	54	67	66	79	78	78	77	83	82	82	81	79	77	74	74	70	70
	Yozgat	81	70	79	71	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Bi-RNN-GCN	Adana	74	72	70	70	63	50	58	49	78	69	76	73	-	-	-	-	-	-
	Bursa	70	41	76	69	79	69	79	65	76	59	75	63	76	59	76	64	-	-
	Elazığ	55	55	61	61	67	66	65	65	71	71	64	64	71	70	68	64	63	64
	Yozgat	74	49	71	46	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GAT	Adana	63	58	62	59	24	24	16	15	50	48	62	52	-	-	-	-	-	-
	Bursa	71	45	69	47	73	46	75	44	73	42	70	42	72	42	70	41	-	-
	Elazığ	59	54	58	52	61	56	48	48	56	53	47	47	63	61	62	62	61	61
	Yozgat	74	44	70	44	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GAT-Bi-GRU	Adana	69	66	66	64	44	41	37	34	64	59	68	65	-	-	-	-	-	-
	Bursa	70	46	71	62	77	67	78	64	74	53	73	55	74	49	73	53	-	-
	Elazığ	56	53	59	53	68	66	49	49	61	61	64	64	72	71	65	62	63	64
	Yozgat	77	62	77	66	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GAT-Bi-LSTM	Adana	65	63	65	64	29	29	55	48	68	64	69	64	-	-	-	-	-	-
	Bursa	71	56	76	70	80	71	78	63	74	52	73	54	74	49	73	53	-	-
	Elazığ	57	54	65	62	66	64	58	58	68	68	63	63	71	70	65	63	60	61
	Yozgat	78	66	77	66	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GAT-Bi-RNN	Adana	61	58	66	64	30	30	24	24	66	62	69	64	-	-	-	-	-	-
	Bursa	70	46	72	62	76	66	77	62	74	54	72	52	73	47	72	51	-	-
	Elazığ	67	66	67	65	67	64	50	50	64	63	67	67	71	70	63	62	62	62
	Yozgat	75	53	73	53	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Ek Tablo 1'nin devamı

		GRU-GCN				GRU-GAT				GRU-GatedGAT				GRU-GatedGNN				GRU-GatedGAT-LSTM				GRU-GatedGAT-RNN				GRU-GatedGNN				GRU-GatedGNN-LSTM				GRU-GatedGNN-RNN				LSTM-GAT																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																					
		Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat	Adana	Bursa	Elazığ	Yozgat																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																						
		67	72	57	76	65	72	54	61	69	79	67	74	60	67	79	66	70	83	90	78	86	84	77	85	75	82	81	72	82	79	82	88	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	74	80	78	85	82	79	84	81	77	82	83	75	80	76	83	86	

Ek Tablo 1'nin devamı

LSTM-GCN	Adana	66	64	69	68	30	28	25	24	74	65	68	64	-	-	-	-	-	-
	Bursa	71	53	73	67	77	67	78	65	75	60	75	65	75	61	76	65	-	-
	Elazığ	62	60	70	69	76	74	65	64	75	75	75	74	72	71	69	68	64	64
	Yozgat	76	59	76	66	-	-	-	-	-	-	-	-	-	-	-	-	-	-
LSTM-GatedGAT	Adana	85	82	78	78	73	73	69	67	85	85	-	-	-	-	-	-	-	-
	Bursa	74	65	80	74	86	81	85	77	79	67	79	72	80	71	81	75	-	-
	Elazığ	79	78	81	80	83	82	70	67	85	85	76	76	85	84	77	76	68	68
	Yozgat	82	76	82	77	-	-	-	-	-	-	-	-	-	-	-	-	-	-
LSTM-GatedGNN	Adana	87	85	83	83	33	32	26	25	80	75	88	87	-	-	-	-	-	-
	Bursa	77	71	82	79	90	87	87	82	84	77	78	65	84	78	86	82	-	-
	Elazığ	85	85	87	87	86	86	80	80	86	86	83	83	86	85	78	77	76	77
	Yozgat	85	79	86	82	-	-	-	-	-	-	-	-	-	-	-	-	-	-
RNN-GAT	Adana	83	81	80	80	31	30	24	24	78	72	82	80	-	-	-	-	-	-
	Bursa	74	64	84	81	85	80	84	75	78	67	78	69	78	68	79	71	-	-
	Elazığ	75	74	74	73	81	80	69	67	79	79	73	71	81	80	80	79	78	78
	Yozgat	83	73	81	73	-	-	-	-	-	-	-	-	-	-	-	-	-	-
RNN-GCN	Adana	72	70	67	67	38	33	46	40	77	66	73	71	-	-	-	-	-	-
	Bursa	72	53	74	63	76	67	78	66	76	61	75	64	75	62	74	64	-	-
	Elazığ	57	56	59	58	57	56	50	50	58	56	53	52	72	71	67	64	58	60
	Yozgat	74	46	71	46	-	-	-	-	-	-	-	-	-	-	-	-	-	-
RNN-GatedGAT	Adana	84	82	78	78	31	30	24	24	77	71	78	76	-	-	-	-	-	-
	Bursa	79	72	85	82	87	83	86	79	82	73	82	76	83	75	83	78	-	-
	Elazığ	80	79	83	83	83	83	71	70	80	79	80	80	83	82	78	76	73	74
	Yozgat	84	78	81	76	-	-	-	-	-	-	-	-	-	-	-	-	-	-
RNN-GatedGNN	Adana	88	86	83	83	33	32	28	28	79	73	85	84	-	-	-	-	-	-
	Bursa	85	81	89	86	90	86	88	83	82	77	82	75	84	78	85	82	-	-
	Elazığ	85	84	81	80	80	80	76	75	88	88	82	82	83	82	80	79	64	66
	Yozgat	84	78	82	77	-	-	-	-	-	-	-	-	-	-	-	-	-	-
ResGatedGN	Adana	66	59	65	61	37	36	24	24	65	58	63	54	-	-	-	-	-	-
	Bursa	71	57	70	59	76	64	76	60	74	53	72	53	74	53	73	56	-	-
	Elazığ	66	64	64	60	64	59	53	53	64	63	59	59	67	66	67	65	62	62
	Yozgat	73	51	78	63	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Ek Tablo 2 Adana, Bursa, Elazığ ve Yozgat projelerinin farklı pencereleri boyunca SPI tahmini için incelenen mekansal-zamansal modellerin en yüksek doğruluk performanslarını detaylandırmaktadır.

Ek Tablo 2. Farklı pencerelerde SPI tahmininde kullanılan mekansal-zamansal modellerin performansı.

[illegible]

Ek Tablo 2'nin devamı

GAT-Bi-GRU	Adana	77	43	82	45	31	30	17	17	65	62	66	66	-	-	-	-	-	-
	Bursa	66	42	69	50	69	58	75	61	77	62	79	66	80	67	79	69	-	-
	Elazığ	52	34	64	62	65	64	76	56	72	56	68	57	65	56	66	63	67	71
GAT-Bi-LSTM	Yozgat	64	61	59	52	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	77	43	82	46	30	29	17	17	69	66	66	66	-	-	-	-	-	-
	Bursa	66	41	70	53	69	58	76	63	78	66	78	66	79	66	78	69	-	-
	Elazığ	47	35	57	36	67	65	76	60	73	58	68	58	65	56	66	61	69	74
GAT-Bi-RNN	Yozgat	63	60	58	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	77	43	82	45	29	27	16	16	58	57	65	65	-	-	-	-	-	-
	Bursa	66	41	68	43	66	45	72	45	75	49	77	55	78	61	75	59	-	-
	Elazığ	65	65	65	65	66	65	76	56	74	65	71	68	72	69	77	74	72	74
GAT-GRU	Yozgat	62	60	60	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	77	43	82	46	30	30	20	20	69	65	68	68	-	-	-	-	-	-
	Bursa	66	42	68	43	68	56	75	60	78	65	79	67	79	67	77	69	-	-
	Elazığ	52	34	60	49	66	65	76	58	72	58	68	57	64	54	66	61	68	73
GAT-LSTM	Yozgat	64	61	60	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	77	43	82	45	30	29	17	17	70	65	69	68	-	-	-	-	-	-
	Bursa	66	40	69	46	68	57	74	59	78	63	79	65	80	65	79	69	-	-
	Elazığ	52	34	57	37	63	38	73	47	72	59	67	60	65	58	65	61	67	72
GAT-RNN	Yozgat	63	61	57	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	77	43	82	48	28	26	16	16	60	58	64	64	-	-	-	-	-	-
	Bursa	66	41	68	43	66	44	72	45	75	52	79	64	80	64	76	62	-	-
	Elazığ	66	66	76	69	66	65	69	59	75	69	72	69	72	70	77	74	72	74
GCN	Yozgat	63	60	61	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	63	47	76	47	26	23	18	18	60	58	63	63	-	-	-	-	-	-
	Bursa	66	40	68	43	65	42	71	44	74	47	77	53	78	54	74	54	-	-
	Elazığ	66	64	70	59	68	51	65	51	67	53	64	56	66	58	71	65	61	66
	Yozgat	61	56	62	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Adana	78	55	82	50	30	28	21	21	66	64	69	69	-	-	-	-	-	-
	Bursa	66	42	69	50	69	58	75	61	77	62	79	66	80	67	79	69	-	-
	Elazığ	52	34	64	62	65	64	76	56	72	56	68	57	65	56	66	63	67	71

Ek Tablo 2'nin devamı

GCN-Bi-GRU	Bursa	69	53	70	58	69	60	76	62	79	66	80	66	80	66	79	70	-	-
	Elazığ	52	34	68	67	67	65	75	56	72	53	69	56	67	59	67	65	65	67
	Yozgat	62	59	57	50	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GCN-Bi-LSTM	Adana	78	56	82	52	29	28	20	20	68	66	68	67	-	-	-	-	-	-
	Bursa	67	43	69	55	68	57	74	58	77	61	78	63	79	62	76	64	-	-
	Elazığ	52	34	57	36	67	65	75	58	73	55	70	57	65	58	67	64	68	70
	Yozgat	63	59	58	50	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GCN-Bi-RNN	Adana	77	45	81	52	32	32	20	20	67	65	69	68	-	-	-	-	-	-
	Bursa	68	51	69	55	68	57	74	58	76	60	78	63	78	63	77	65	-	-
	Elazığ	71	68	75	67	67	66	71	61	72	64	69	66	71	67	75	71	70	73
	Yozgat	62	60	58	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GCN-GRU	Adana	77	44	82	51	31	31	22	22	69	66	70	69	-	-	-	-	-	-
	Bursa	69	53	70	58	69	61	76	64	79	66	80	67	80	66	79	69	-	-
	Elazığ	52	34	57	36	68	64	75	57	73	55	69	56	65	57	66	64	68	70
	Yozgat	61	58	58	50	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GCN-LSTM	Adana	77	47	82	52	30	30	21	21	67	65	67	66	-	-	-	-	-	-
	Bursa	67	42	69	55	68	57	74	57	77	61	78	63	78	62	77	66	-	-
	Elazığ	52	34	58	58	65	50	74	52	72	54	70	57	65	56	66	63	66	69
	Yozgat	62	59	58	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GCN-RNN	Adana	77	51	81	51	31	30	23	23	67	65	68	68	-	-	-	-	-	-
	Bursa	68	51	69	56	68	58	74	58	77	60	78	64	79	62	76	64	-	-
	Elazığ	71	70	75	67	69	67	68	61	70	64	68	65	70	67	76	73	71	73
	Yozgat	63	60	58	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GRU-GAT	Adana	78	58	82	52	27	26	19	19	69	62	71	70	-	-	-	-	-	-
	Bursa	65	43	68	49	67	52	76	64	79	69	80	70	79	68	80	73	-	-
	Elazığ	52	34	58	41	66	65	77	61	74	58	70	60	67	59	68	65	70	73
	Yozgat	68	62	66	51	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GRU-GCN	Adana	76	45	82	51	29	28	22	22	68	61	68	67	-	-	-	-	-	-
	Bursa	66	43	66	47	67	53	75	61	78	66	78	66	79	65	78	69	-	-

Ek Tablo 2'nin devamı

	Elazığ	52	34	57	36	63	38	73	47	70	55	67	58	64	55	65	62	65	68
	Yozgat	64	62	64	53	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GRU-GatedGAT	Adana	78	56	82	52	29	28	27	27	67	63	72	71	-	-	-	-	-	-
	Bursa	69	52	70	64	72	67	79	70	81	73	84	76	85	75	82	76	-	-
	Elazığ	79	79	82	81	84	82	80	71	77	68	76	71	79	76	73	72	73	74
	Yozgat	66	62	66	52	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GRU-GatedGNN	Adana	78	63	81	57	30	30	27	26	69	65	76	75	-	-	-	-	-	-
	Bursa	71	63	75	69	74	70	80	73	82	77	84	77	86	79	85	80	-	-
	Elazığ	82	82	86	85	88	86	81	72	77	67	73	69	80	78	76	76	75	78
	Yozgat	68	65	62	52	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GatedGAT-GRU	Adana	77	57	82	54	36	36	36	34	71	68	72	71	-	-	-	-	-	-
	Bursa	70	61	72	66	73	68	80	73	81	74	84	76	85	78	83	77	-	-
	Elazığ	78	78	80	80	83	81	79	68	76	66	75	68	77	74	73	72	72	75
	Yozgat	69	65	65	54	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GatedGAT-LSTM	Adana	77	53	81	55	32	31	28	27	71	68	71	70	-	-	-	-	-	-
	Bursa	71	61	71	65	72	66	79	70	82	74	84	75	85	76	82	77	-	-
	Elazığ	80	79	81	80	83	81	80	67	77	66	74	67	77	75	74	73	74	76
	Yozgat	69	65	63	53	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GatedGAT-RNN	Adana	74	44	82	49	29	29	26	26	70	65	71	71	-	-	-	-	-	-
	Bursa	71	65	73	67	73	68	79	70	82	76	84	76	87	78	85	79	-	-
	Yozgat	68	65	69	58	-	-	-	-	-	-	-	-	-	-	-	-	-	-
	Elazığ	51	42	63	54	67	64	75	55	72	57	72	63	68	62	67	66	70	71
GatedGNN	Adana	77	56	82	59	52	51	48	43	73	71	75	74	-	-	-	-	-	-
	Bursa	73	66	72	68	73	70	81	74	83	77	86	79	88	82	85	80	-	-
	Elazığ	86	85	82	82	85	82	78	72	80	76	83	83	83	82	89	87	92	92
	Yozgat	67	65	58	52	-	-	-	-	-	-	-	-	-	-	-	-	-	-
GatedGNN-GRU	Adana	74	64	80	60	31	30	27	27	73	70	76	75	-	-	-	-	-	-
	Bursa	72	66	73	69	76	73	83	77	84	77	86	77	87	78	85	81	-	-
	Elazığ	83	83	87	86	87	86	78	70	76	67	71	66	79	78	74	73	72	74

Ek Tablo 2'nin devamı

[illegible]

Ek Tablo 2'nin devamı

[illegible]

ÖZGEÇMİŞ

Fatemeh MOSTOFI Heriot-Watt Üniversitesi'nden Birinci Sınıf Onur Derecesi ile İnşaat Mühendisliği lisans diplomasına sahip bir inşaat mühendisidir. Araştırmalarında yapım yönetimi alanında kullanılabilecek makine öğrenimi tabanlı karar destek araçlarının geliştirilmesine odaklanmaktadır. Özellikle süreç verimliliğini artırmak, finansal ve güvenlik risklerini azaltmak ve kaynak yönetimini optimize etmek amacıyla grafik sınır ağlarını kullanmaktadır. Araştırmalarında ayrıca öneri sistemleri ve büyük dil modelleri gibi veri bilimi tekniklerinin öngörüye dayalı karar destek araçları güvenilirliğini artırmak amacıyla kullanılmasını da incelemektedir.

Fatemeh, lisans eğitimini 2013 Heriot-Watt Üniversitesi'nde tamamladı ve sonrasında 2014-2016 yılları arasında aynı üniversitenin Yapılı Çevre Fakültesi'nde yarı zamanlı öğretim görevlisi olarak akademik kadroya katıldı.

Fatemeh Women in Data Science (WiDS) elçisidir. Amerikan İnşaat Mühendisleri Derneği (American Society of Civil Engineers, ASCE) ve Proje Yönetim Enstitüsü'nün (Association for Project Management, APM) aktif bir üyesidir. Aynı zamanda, İnşaat Mühendisleri Kurumu'nun (Institution of Civil Engineers, ICE) Mezunlar ve Öğrenciler Macmillan Makale Yarışması'nda ve BITS Pilani'nin ENGInuity yarışmasında ödüllendirilmiştir.

Fatemeh'in SCI, SCIE, SSCI ve AHCI gibi akademik veri tabanlarında indekslen uluslararası prestijli hakemli dergilerde yayımlanmış yirmin üzerinde çalışması bulunmaktadır.