



**BETONARME PERDELERİN ŞEKİL DEĞİŞTİRME
KAPASİTESİNİN YAPAY ZEKÂ YÖNTEMLERİYLE
MODELLENMESİ**

Mahinur SERTKAYA

**Doktora Tezi
İnşaat Mühendisliği Anabilim Dalı
Prof. Dr. İlker KAZAZ**

**2025
Her hakkı saklıdır.**



FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZİ

**BETONARME PERDELERİN ŞEKİL DEĞİŞTİRME KAPASİTESİNİN YAPAY
ZEKÂ YÖNTEMLERİYLE MODELLENMESİ**

Mahinur SERTKAYA

Tez Danışmanı: Prof. Dr. İlker KAZAZ

Anabilim Dalı: İnşaat Mühendisliği

Erzurum

2025

Her hakkı saklıdır.

T.C.
ERZURUM TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ ONAY FORMU

**BETONARME PERDELERİN ŞEKİL DEĞİŞTİRME KAPASİTESİNİN YAPAY
ZEKÂ YÖNTEMLERİYLE MODELLENMESİ**

Prof. Dr. İlker KAZAZ danışmanlığında, Mahinur SERTKAYA tarafından hazırlanan bu çalışma 18/09/2025 tarihinde aşağıdaki jüri tarafından İnşaat Mühendisliği Ana Bilim Dalı'nda Doktora tezi olarak **Oy birliği (5/5) ile** kabul edilmiştir.

Başkan	: Prof. Dr. Fatih Mehmet ÖZKAL	İmza	:
Üye	: Prof. Dr. İlker KAZAZ	İmza	:
Üye	: Prof. Dr. Fatih TOSUNOĞLU	İmza	:
Üye	: Dr. Öğr. Üyesi Sait ALP	İmza	:
Üye	: Dr. Öğr. Üyesi Muhammed GÜRBÜZ	İmza	:

Yukarıdaki sonucu onaylıyorum

Prof. Dr. İlker KAZAZ
Enstitü Müdürü

*Bu tez çalışması tarafından nolu proje ile desteklenmiştir.

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

18 / 09 / 2025

İmzası

Mahinur SERTKAYA

ÖZET

DOKTORA TEZİ

BETONARME PERDELERİN ŞEKİL DEĞİŞTİRME KAPASİTESİNİN YAPAY ZEKÂ YÖNTEMLERİYLE MODELLENMESİ

Mahinur SERTKAYA

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Ana Bilim Dalı

Danışman: Prof. Dr. İlker KAZAZ

Betonarme perde davranışının deneysel olarak test edilmesi ve sonlu elemanlar yöntemiyle modellenmesi, gerektirdiği yüksek zaman ve maliyet nedeniyle önemli kısıtlamalar içermektedir. Son yıllarda açık veri ve kod paylaşımının artış göstermesi nedeniyle uygulamalarda makine öğrenmesine (ML) yönelim artmaktadır. Bu çalışma kapsamında sonlu elemanlar yöntemiyle üretilen 2548 perde modeline ait kesit uçlarındaki plastik dönme, donatı ve beton birim şekil değiştirme değerleri ML yöntemleriyle incelenmiştir. İlk olarak çeşitli girdi parametreleri kullanılarak ağaç tabanlı dört yöntemle (Karar Ağacı, Rasgele Orman, Uyarlanabilir Arttırma, Aşırı Gradyan Arttırma) plastik dönme tahmin edilmiş ve modellerin performansı 10 katlı çapraz doğrulama kriteri dikkate alınarak değerlendirilmiştir. Karşılaştırmalar sonucunda en iyi performans gösteren XGBoost modeli, Rasgele Arama ve Optuna ile hiperparametre ayarı yapılarak yeniden eğitilmiştir. XGBoost-Optuna konfigürasyonunun en yüksek başarıyı verdiği belirlenmiştir. Bu modelin sonuçları SHAP analiziyle yorumlanarak değişkenlerin göreceli etkileri ve olası etkileşimleri ortaya konmuştur. Plastik dönme tahmininde başarılı olduğu kanıtlanan bu modelleme yaklaşımı, perde birim şekil değiştirmelerine de uygulandığında benzer derecede etkili sonuçlar vermiştir. Sonuçlardan denklem üretmek amacıyla, toplamsal güç yasası regresyon modeli hem gerçek (ANSYS) ölçümler hem de ML tahmin çıktıları üzerinde ayrı ayrı oluşturulmuştur. ML yöntemiyle türetilen denklemin davranışı daha iyi temsil ettiği saptanmıştır. Bulgular, betonarme perdelerin davranışının ML ile yüksek doğrulukta, hızlı ve yorumlanabilir biçimde öngörülebileceğini göstermektedir.

2025, 143 sayfa

Anahtar Kelimeler: Betonarme perde, makine öğrenmesi, plastik dönme, birim şekil değiştirmeler

ABSTRACT

Ph.D

MODELING THE DEFORMATION CAPACITY OF REINFORCED CONCRETE SHEAR WALLS USING ARTIFICIAL INTELLIGENCE METHODS

Mahinur SERTKAYA

Erzurum Technical University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering

Supervisor: Prof. Dr. İlker KAZAZ

Experimentally testing the behavior of reinforced concrete walls and modeling them using the finite element method involves significant limitations due to the high time and cost required. In recent years, the increase in open data and code sharing has led to a growing trend towards machine learning (ML) in applications. Within the scope of this study, the plastic rotation, reinforcement, and concrete unit deformation values at the section ends of 2548 wall models generated using the finite element method were examined using ML methods. First, plastic rotation was predicted using four tree-based methods (Decision Tree, Random Forest, Adaptive Boosting, Extreme Gradient Boosting) with various input parameters, and the performance of the models was evaluated considering the 10-fold cross-validation criterion. As a result of the comparisons, the XGBoost model, which showed the best performance, was retrained with hyperparameter tuning using Random Search and Optuna. The XGBoost-Optuna configuration was determined to yield the highest success. The results of this model were interpreted using SHAP analysis to reveal the relative effects of the variables and their possible interactions. This modeling approach, proven successful in plastic rotation prediction, yielded similarly effective results when applied to curtain unit deformations. To derive equations from the results, a sum of additive power law regression model was created separately for both actual (ANSYS) measurements and ML prediction outputs. The equation derived using the ML method was found to better represent the behavior. The findings show that the behavior of reinforced concrete walls can be predicted with high accuracy, speed, and interpretability using ML.

2025, 143 pages

Keywords: Shear wall, machine learning, plastic rotation, strain demands

TEŞEKKÜR

Tez çalışmamın her aşamasında değerli rehberliğini, bilgi ve deneyimini esirgemeyen, yapıcı eleştirileri ve teşvikiyle araştırmama yön veren danışman hocam Prof. Dr. İlker KAZAZ'a teşekkür ederim.

Tez izleme komitemde yer alan Prof. Dr. Fatih TOSUNOĞLU ve Dr. Öğr. Üyesi Sait ALP hocalarıma, çalışmamın şekillenmesine yönelik sundukları kıymetli görüş ve önerileri için teşekkür ederim.

Lisans ve lisans üstü eğitimim boyunca fikirlerine başvurduğum, bilgi ve deneyimini esirgemeyen hocam Prof. Dr. Mehmet ÖZYAZICIOĞLU'na teşekkür ederim.

Ülkemde huzur ortamını muhafaza eden ve bu uğurda canlarını feda eden Türk Silahlı Kuvvetleri ve Türk Polis Teşkilatı üyelerine ve ailelerine teşekkürü borç bilirim.

Yerde ve gökte bana huzur veren, hayatıma güzellikler katan tüm mahlukata teşekkür ederim.

Hayatımın her aşamasında sevgi ve ilgileriyle yanımda olan, bana inanan, güvenen ve her zaman destek olan, öğretileri ile hayatıma yön veren, varlıklarıyla huzur bulduğum aileme; babacığım ve anneciğim Hakkı SERTKAYA ve Zehra SERTKAYA'ya, kardeşlerim Neslihan SERTKAYA, Nesligül SERTKAYA ve M. Zeki SERTKAYA'ya teşekkür ve şükranlarımı sunarım.

Doktora çalışmam, Yükseköğretim Kurulu (YÖK) tarafından yürütülen 100/2000 Doktora Burs Projesi kapsamında “Yapı” alanında desteklenmiştir. Yükseköğretim Kuruluna desteklerinden dolayı teşekkür ederim.

Mahinur SERTKAYA
Eylül 2025

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	xiii
SİMGELER ve KISALTMALAR DİZİNİ	xiv
1. GİRİŞ	1
1.1. Betonarme Perdelerin Genel Tanımı ve Önemi.....	3
1.2. Performansa Dayalı Tasarımda Şekil Değiştirme Sınırları.....	6
1.2.1. Plastik dönme.....	6
1.2.2. Beton birim kısalması	7
1.2.3. Çelik birim uzaması.....	7
1.3. Makine Öğrenmesi.....	8
1.3.1. Karar Ağacı (DT).....	13
1.3.2. Rastgele Orman (RF).....	21
1.3.3. Boosting algoritmaları	22
1.3.4. Uyarlanabilir Arttırma (AdaBoost).....	23
1.3.5. Aşırı Gradyan Arttırma (XGBoost)	24
1.3.6. Hiperparametre optimizasyonu.....	28
1.3.7. Makine öğrenmesi model yorumlama: SHAP	29
1.3.8. Toplamsal güç yasası regresyon modeli	31
1.3.9. Makine öğrenmesi regresyon kriterleri.....	31
2. KAYNAK ÖZETLERİ	35
3. MATERYAL ve YÖNTEM	42
3.1. Materyal	42
3.1.1. Perdelerin tasarımı ve detaylandırma	42
3.1.2. Parametrik çalışma.....	43
3.1.3. Sonlu eleman modeli ve malzeme özellikleri	44
3.1.4. Makine öğrenmesi modeli	48
3.2. Yöntem.....	53

3.2.1. Veri işleme.....	53
3.2.2. Model oluşturma ve yorumlama.....	69
3.2.3. Toplamsal güç yasası regresyon modeli.....	69
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	70
4.1. Modeller ve Modellerin Çıktıları.....	70
4.1.1. Karar Ağacı-plastik dönme.....	70
4.1.2. Rastgele Arama-plastik dönme.....	70
4.1.3. Uyarlanabilir Arttırma-plastik dönme	73
4.1.4. Aşırı Gradyan Arttırma-plastik dönme.....	75
4.1.5. SHAP yorumlama-plastik dönme	79
4.1.6. Aşırı Gradyan Arttırma-beton birim kısalması.....	87
4.1.7. SHAP Yorumlama-beton birim kısalması.....	89
4.1.8. Aşırı Gradyan Arttırma-çelik birim uzaması.....	99
4.1.9. SHAP yorumlama-çelik birim uzaması.....	101
4.1.10. Modellerin performans değerlendirmesi	111
4.1.11. Denklemler.....	122
5. SONUÇ ve ÖNERİLER.....	129
KAYNAKLAR	134

ŞEKİLLER DİZİNİ

Şekil 1.1. Yatay yük altında perde davranışı (Tan 2022).	5
Şekil 1.2. Makine öğrenmesi algoritmalarının genel olarak sınıflandırılması (çalışma özelinde).....	10
Şekil 1.3. Aşırı öğrenmeyi önlemek için veri setinin bölümlere ayrılması.	12
Şekil 1.4. Karar ağacı algoritmasının grafiksel gösterimi (Şekil çalışmadaki Karar Ağacı modelinden alındı).	14
Şekil 1.5. Gradyan arttırma metodu algoritmasının çalışma prensibi (Thai 2022).....	25
Şekil 1.6. Aşırı gradyan arttırma algoritmasının çalışma prensibi (Liu et al. 2022).....	26
Şekil 1.7. 10 katlı çapraz doğrulama şematik gösterimi (Ngo et al. 2022).....	34
Şekil 3.1. Çalışmada kullanılan perde detayı (Sertkaya 2018).	42
Şekil 3.2. Perdelerin (a) sonlu eleman modeli ve (b) detayları (Sertkaya 2018).	46
Şekil 3.3. Çalışmada kullanılan perdelerin sonlu eleman modelleri (Sertkaya 2018). ...	47
Şekil 3.4. Betonarme perde detayı ve şekil değiştirme sınırlarının gösterimi.	48
Şekil 3.5. Tüm veri seti için plastik dönme korelasyon ısı haritası.	54
Şekil 3.6. Nihai şekil değiştirme anında perde taban dönme açısı üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018).	55
Şekil 3.7. Nihai şekil değiştirme anında perde taban dönme açısı üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).	56
Şekil 3.8. Plastik dönme korelasyon ısı haritası.	57
Şekil 3.9. Plastik dönme ve parametreler arasındaki ilişki.	58
Şekil 3.10. Tüm veri seti için beton birim kısalması korelasyon ısı haritası.	59
Şekil 3.11. Nihai şekil değiştirme anında perde uç bölgesi beton birim kısalması üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018). ...	60
Şekil 3.12. Nihai şekil değiştirme anında perde uç bölgesi beton birim kısalması üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).....	61
Şekil 3.13. Beton birim kısalması korelasyon ısı haritası.	62
Şekil 3.14. Beton birim kısalması ve parametreler arasındaki ilişki.....	63
Şekil 3.15. Tüm veri seti için çelik birim uzaması korelasyon ısı haritası.	64
Şekil 3.16. Nihai şekil değiştirme anında perde uç bölgesi çelik birim uzaması üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018)....	65

Şekil 3.17. Nihai şekil değiştirme anında perde uç bölgesi çelik birim uzaması üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).....	66
Şekil 3.18. Çelik birim uzaması korelasyon ısı haritası.....	67
Şekil 3.19. Çelik birim uzaması ve parametreler arasındaki ilişki.	68
Şekil 4.1. Plastik dönme karar ağacı modeli birinci ağacın kesiti.	71
Şekil 4.2. Plastik dönme rastgele orman modeli birinci ağacın kesiti.	72
Şekil 4.3. Plastik dönme uyarlanabilir arttırma modeli birinci ağacın yapısı.	74
Şekil 4.4. Plastik dönme aşırı gradyan arttırma modeli birinci ağacın yapısı.	75
Şekil 4.5. Plastik dönme aşırı gradyan arttırma-rastgele arama modeli altmışıncı ağacın yapısı.	76
Şekil 4.6. Plastik dönme aşırı gradyan arttırma-optuna modeli altmışıncı ağacın yapısı.	78
Şekil 4.7. Plastik dönme (θ_p) modelinin SHAP önem grafiği.	79
Şekil 4.8. Plastik dönme (θ_p) modelinin SHAP özet grafiği.....	80
Şekil 4.9. Plastik dönme (θ_p) modelinin SHAP şelale grafikleri, perde boyu özelinde; (a) $l_w=2$ m, (b) $l_w=3$ m, (c) $l_w=5$ m ve (d) $l_w=8$ m.	81
Şekil 4.10. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve sargı donatısı oranı (ρ_s) ilişkisi.....	82
Şekil 4.11. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve sargı donatısı oranı (ρ_s) ilişkisi.	83
Şekil 4.12. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve perde boyu (l_w) ilişkisi.	84
Şekil 4.13. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve eksenel yük oranı (P/P_o) ilişkisi.....	85
Şekil 4.14. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve sargı donatısı oranı (ρ_s) ilişkisi.....	86
Şekil 4.15. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (ν_n) ve sargı donatısı oranı (ρ_s) ilişkisi.	87
Şekil 4.16. Beton birim kısalması aşırı gradyan arttırma-optuna modeli yüz üçüncü ağacın yapısı.	88
Şekil 4.17. Beton birim kısalması (ϵ_{cu}) modelinin SHAP önem grafiği.	89

Şekil 4.18. Beton birim kısalması (ε_{cu}) modelinin SHAP özet grafiği.	90
Şekil 4.19. Beton birim kısalması (ε_{cu}) modelinin SHAP şelale grafikleri, perde boyu özelinde; (a) $l_w=2$ m, (b) $l_w=3$ m, (c) $l_w=5$ m ve (d) $l_w=8$ m.	92
Şekil 4.20. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve normalize edilmiş kesme gerilmesi (ν_n) ilişkisi.	93
Şekil 4.21. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ilişkisi.	94
Şekil 4.22. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve sargı donatısı oranı (ρ_s) ilişkisi.	95
Şekil 4.23. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; boyuna donatı oranı (ρ_b) ve sargı donatısı oranı (ρ_s) ilişkisi.	96
Şekil 4.24. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve eksenel yük oranı (P/P_o) ilişkisi.	97
Şekil 4.25. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve eksenel yük oranı (P/P_o) ilişkisi. ..	98
Şekil 4.26. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (ν_n) ve perde boyu (l_w) ilişkisi.	99
Şekil 4.27. Çelik birim uzaması aşırı gradyan arttırma-optuna modeli birinci ağacın kesiti.	100
Şekil 4.28. Çelik birim uzama (ε_{su}) modelinin SHAP önem grafiği.	101
Şekil 4.29. Çelik birim uzaması (ε_{su}) modelinin SHAP özet grafiği.	102
Şekil 4.30. Çelik birim uzaması (ε_{su}) modelinin SHAP şelale grafikleri, perde boyu özelinde; (a) $l_w=2$ m, (b) $l_w=3$ m, (c) $l_w=5$ m ve (d) $l_w=8$ m.	104
Şekil 4.31. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve eksenel yük oranı (P/P_o) ilişkisi.	105
Şekil 4.32. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve sargı donatısı oranı (ρ_s).	106
Şekil 4.33. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve perde boyu (l_w) ilişkisi.	107

Şekil 4.34. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; boyuna donatı oranı (ρ_b) ve sargı donatısı oranı (ρ_s) ilişkisi.	108
Şekil 4.35. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve eksenel yük oranı (P/P_o) ilişkisi.	109
Şekil 4.36. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve sargı donatısı oranı (ρ_s) ilişkisi. ...	110
Şekil 4.37. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (v_n) ve eksenel yük oranı (P/P_o) ilişkisi.	111
Şekil 4.38. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile karar ağacı dağılım grafiği (a) ve kalıntı grafiği (b).	113
Şekil 4.39. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile rastgele orman dağılım grafiği (a) ve kalıntı grafiği (b).	114
Şekil 4.40. Plastik dönme (θ_p) ANSYS sonlu eleman değeri ile uyarlanabilir arttırma dağılım grafiği (a) ve kalıntı grafiği (b).	115
Şekil 4.41. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile aşırı gradyan arttırma dağılım grafiği (a) ve kalıntı grafiği (b).	116
Şekil 4.42. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile aşırı gradyan arttırma-rastgele arama dağılım grafiği (a) ve kalıntı grafiği (b).	117
Şekil 4.43. Plastik dönme (θ_p) ANSYS sonlu eleman değeri ile aşırı gradyan arttırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).	118
Şekil 4.44. Beton birim kısalması (ε_{cu}) ANSYS sonlu eleman değeri ile aşırı gradyan arttırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).	119
Şekil 4.45. Çelik birim uzaması (ε_{su}) ANSYS sonlu eleman değeri ile aşırı gradyan arttırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).	120
Şekil 4.46. Plastik dönme (θ_p) aşırı gradyan arttırma-optuna modeli ile Çizelge 4.5.'te verilen plastik dönmenin (θ_{p-ML}) kıyaslanması (a) ve plastik dönme ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen plastik dönmenin ($\theta_{p-ANSYS}$) kıyaslanması (b).	126
Şekil 4.47. Beton birim kısalması (ε_{cu}) aşırı gradyan arttırma-optuna modeli ile Çizelge 4.5.'te verilen Beton birim kısalması (ε_{cu-ML}) kıyaslanması (a) ve beton birim	

kısalması ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen beton
birim kısalması ($\epsilon_{cu-ANSYS}$) kıyaslanması (b). 127

Şekil 4.48. Çelik birim uzaması (ϵ_{su}) aşırı gradyan arttırma-optuna modeli ile Çizelge
4.5.'te verilen çelik birim uzaması (ϵ_{su-ML}) kıyaslanması (a) ve çelik birim
uzaması ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen çelik birim
uzaması ($\epsilon_{su-ANSYS}$) kıyaslanması (b). 128



ÇİZELGELER DİZİNİ

Çizelge 1.1. Karar ağacı algoritmaları (Saitoğlu Sevimli 2015).....	17
Çizelge 3.1. Makalelerde sunulan açık kaynaklı kodlar.	51
Çizelge 3.2. Python uygulamasında kullanılan başlıca makine öğrenmesi kütüphaneleri.	52
Çizelge 4.1. Plastik dönme modellerinin performans değerlendirmeleri.	121
Çizelge 4.2. Beton birim kısalması modelinin performans değerlendirmeleri.	121
Çizelge 4.3. Çelik birim uzaması modelinin performans değerlendirmeleri.	121
Çizelge 4.4. Betonarme perdelerde şekil değiştirme makine öğrenmesi model detayları.	122
Çizelge 4.5. Betonarme perdelerin şekil değiştirme değerleri için toplamsal güç yasası modeli ile üretilen denklemler.	124

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

Açıklama

A_s	Perde uç bölgesinde bulunan toplam boyuna donatı alanı
A_{sh}	s enine donatı aralığına karşı gelen yükseklik boyunca, perde uç bölgesindeki tüm etriye kollarının ve çirozların enkesit alanı değerlerinin göz önüne alınan b_k 'ya dik doğrultudaki izdüşümlerinin toplamı
A_{sw}	Perde uç bölgesi alanı
f_c	Beton basınç dayanımı
f_{ck}	Betonun karakteristik silindir basınç dayanımı
f_{su}	Donatı çeliğinin kopma dayanımı
f_y	Donatı çeliği akma gerilmesi
H_w	Perde yüksekliği
H_w/l_w	Perde yükseklik-boy oranı
L_p	Plastik mafsallık boyu
L_{pz}	Plastikleşmenin yayıldığı bölge uzunluğu
l_u	Perde uç bölgesi uzunluğu
L_v	Etkin kesme boyu
L_v/l_w	Kesme boyu oranı
l_w	Perde boyu
M_y	Perde taban kesiti moment kapasitesi
P	Eksenel yük
P/P_o	Eksenel yük oranı ($P_o=f_c A_w$)
s	Enine donatı aralığı
t_w	Perde kalınlığı
V_e	Pekleşmeli moment kapasitesi göz önüne alınarak hesaplanan kesme kuvveti
V_{max}	Maksimum kesme kuvveti
V_r	Perde kesitinin kesme dayanımı
Δ_p	Plastik ötelenme
Δ_y	Akma anında ötelenme

ϵ_c	Beton birim şekil değıştirmesi
ϵ_{cu}	Nihai şekil değıştirme anında beton birim kısalması
ϵ_c	Donatı çeliğı birim şekil değıştirmesi
ϵ_{su}	Nihai şekil değıştirme anında çelik birim uzaması
v_n	Normalize edilmiş kesme gerilmesi
θ_p	Perde plastik dönme açısı
ρ_b	Perde uç bölgesinde boyuna donatının hacimsel oranı
ρ_d	Diyagonal donatı oranı
ρ_s	Perde uç bölgesinde sargı donatısı oranı
ρ_t	Perde yatay gövde donatısı oranı
ρ_{sx}	Perde uç bölgesinde x yönündeki enine donatı oranı
ρ_{sy}	Perde uç bölgesinde y yönündeki enine donatı oranı

Kısaltmalar

10-cv	10 Katlı Çapraz Doğrulama
AdaBoost	Uyarlanabilir Arttırma
DT	Karar Ağacı
GBM	Gradyan Arttırma Metodu
MAE	Ortalama Mutlak Hata
ML	Makine Öğrenmesi
R^2	Belirleme Katsayısı
RF	Rastgele Orman
RMSE	Karekök Ortalama Kare Hata
RS	Rastgele Arama
SHAP	Shapley Toplamsal Açıklamaları
XGBoost	Aşırı Gradyan Arttırma

1. GİRİŞ

Gelişim ve dönüşümü giderek hızlanan yaşam içerisinde teknolojinin rolü her geçen gün artmakta; özellikle bilgisayar sistemleri günlük yaşamın vazgeçilmez bir unsuru haline gelmektedir. Bu yaygınlaşma, çok sayıda alanın dijital ortama entegre edilerek birlikte çalışabilirliğinin araştırılmasını zorunlu kılmıştır. Bu bağlamda yapay zekâ (Artificial Intelligence-AI), 1970’lerde sağlık alanındaki ilk uygulamalarından bu yana kapsamını sürekli genişletmiş ve günümüzde en yaygın kullanılan teknolojik yaklaşımlardan biri olmuştur. Yapay zekânın en başarılı alt alanlarından biri olan makine öğrenmesi (Machine Learning-ML), mevcut veri kümelerinden ve algoritmalarından yararlanarak verideki gizli kalıpları keşfeden, bu kalıplar üzerinden tahmin üreten modellere odaklanır. Geleneksel yöntemlerde kurallar önceden belirlenip sisteme tanımlanırken, ML örneklerden öğrenerek kuralları kendisi oluşturur ve bir modeli kademeli biçimde geliştirir.

Yapı mühendisliğinde doğrusal olmayan ve çok parametrelili davranışların modellenmesi, zaman alıcı kalibrasyon süreçleri ve uygulamada karşılaşılan kısıtlar nedeniyle zordur. Bu noktada ML, hem zaman ve emek tasarrufu sağlaması hem de karmaşık ilişkileri veriye dayalı biçimde yakalayabilmesiyle uygulanabilir ve güçlü bir alternatif olarak öne çıkmaktadır. Son yıllarda veri platformlarının çoğalması ve açık kaynak kodlu araçların yaygınlaşması, ML tabanlı yaklaşımların yapı mühendisliğinde daha hızlı ve sistematik şekilde kullanılmasına zemin hazırlamıştır.

Bu gelişmeler ışığında, taşıyıcı sistem elemanı olarak yaygın biçimde kullanılan betonarme perdelerin davranışının veri odaklı yöntemlerle çözülmesi kritik önem taşımaktadır. Betonarme perdelerin büyük boyutları ve karmaşık hasar süreçleri, deneysel çalışmaların kapsamını sınırlandırmakta; daha ayrıntılı inceleme ihtiyacı bilgisayar ortamında kurulan sayısal modellerle sağlanmaktadır. Sayısal analizlerle elde edilen yüksek hacimli veriler, ML modellerinin eğitimi için uygun bir zemin sunar ve böylece hem parametrik etkilerin ayrıştırılması hem de genellenebilir öngörülerin üretilmesi mümkün olur.

Bu doktora çalışmasının amacı; deneysel olarak test edilmesi ve sonlu elemanlar yöntemiyle modellenmesi, gerektirdiği yüksek zaman ve maliyet nedeniyle önemli kısıtlamalar içeren betonarme perdelerin hasar sınırlarından plastik dönme (θ_p), nihai şekil değiştirme anında beton birim kısalması (ϵ_{cu}) ve nihai şekil değiştirme anında çelik birim uzaması (ϵ_{su}) değerlerinin yapay zekâ yöntemleriyle incelenmesidir. Çalışmada kullanılacak veri, “Betonarme Perdelerin Hasar Sınırlarının Analitik Olarak Belirlenmesi” başlıklı yüksek lisans tezim kapsamında ANSYS ile modellenen 2, 3, 5 ve 8 metrelik perdelerin çeşitli parametrelerle oluşturulan sayısal analizlerinden derlenmiştir. Toplam 2600 analiz sonucunda elde edilen çıktılar, bu çalışmada ML modellerinin eğitimi, doğrulanması ve karşılaştırılmasında girdi olacaktır. Veri setindeki inceleme neticesinde ML’de kullanılacak örnek sayısı 2548 olacak şekilde güncellenmiştir.

Makine öğrenmesi boru hattı dört temel aşamada kurgulanmıştır: (i) veri setindeki parametrelerin birbirleriyle ilişkisi, (ii) modelleme ve hiperparametre optimizasyonu, (iii) değerlendirme ve model yorumlaması ve (iv) model çıktılarından denklem üretimi.

İlk aşamada veri setinin dağılım özellikleri incelenecek ve değişkenler arası ilişkileri görmek üzere korelasyon matrisi oluşturulacaktır. Korelasyon matrisi, Sertkaya (2018) ve literatürden yararlanılarak çıktı üzerinde daha etkin olan parametreler seçilecektir.

İkinci aşamada, ağaç tabanlı öğrenme algoritmasını esas alan dört yöntem; Karar Ağacı (Decision Tree-DT), Rastgele Orman (Random Forest-RF) ve Uyarlanabilir Arttırma (Adaptive Boosting-AdaBoost) ve Aşırı Gradyan Arttırma (Extreme Gradient Boosting-XGBoost) ile oluşturulan modeller birlikte karşılaştırmalı olarak incelenecektir. Model veri uyumunu en iyi düzeye taşımak ve aşırı-eksik öğrenme riskini azaltmak için hiperparametre optimizasyonu uygulanacaktır. Bu amaçla yaygın bir yöntem olan Rastgele Arama (Randomized Search-RS) ve arama sürecini daha verimli yöneten Optuna çerçevesi kullanılacak; böylece nihai modele karar verilecek (Model karar verme aşamasında betonarme perdelerde plastik dönme veri seti kullanılacak, karar verilen model birim şekil değiştirmelere entegre edilecektir).

Üçüncü aşamada modeller, eğitim-test ayrımı altında genelleme başarısı odaklı ölçütlerle değerlendirilecektir. Başlıca performans değerlendirme kriteri olarak karekök ortalama kare hata (RMSE), ortalama mutlak hata (MAE), belirleme katsayısı (R^2) ve 10 katlı çapraz doğrulama (10-cv) kullanılacak; tahmininde en düşük hata ve en yüksek genelleme kabiliyetini sunan yapı seçilecektir. Seçilen modelin sonuçları SHAP analiziyle yorumlanarak değişkenlerin göreceli etkileri ve olası etkileşimleri ortaya konacaktır.

Dördüncü aşamada modelin denklem formunu üretmek amacıyla toplamsal güç yasası regresyon modeli hem ML tahminleri üzerinde hem de gerçek ölçümlerde kurularak; ML yöntemiyle oluşturulan modelin etkisi incelenecektir.

Bu çalışma, beş bölüm halinde düzenlenmiştir. İlk bölüm olan Giriş kısmında, konuya ilişkin genel çerçeve çizilmekte, çalışmanın kapsamı tanımlanmakta ve kuramsal bilgiler açıklanmaktadır. Kaynak Özetleri bölümünde, araştırma konusu ile bağlantılı daha önceki çalışmalar özetlenmektedir. Materyal ve Yöntem bölümünde ise Sertkaya (2018) çalışmasında belirlenen perde modelinin özellikleri, kullanılan parametreler ve malzemeler; makine öğrenmesi modellerinin ayrıntıları ve denklem geliştirme süreci açıklanmaktadır. Araştırma Bulguları ve Tartışma bölümünde, elde edilen model sonuçları sunulmakta ve bu sonuçlar değerlendirilerek tartışılmaktadır. Son olarak Sonuç ve Öneriler bölümünde, çalışmadan çıkarılan temel bulgular ile bunlara dayalı öneriler yer almaktadır.


1.1. Betonarme Perdelerin Genel Tanımı ve Önemi

Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik'te (DBYBHY 2007) perdeler, plan düzleminde uzun kenarının kısa kenarına oranı en az yedi olan düşey taşıyıcı elemanlar olarak tanımlanmaktadır. FEMA 356 (Prestandard and Commentary for the Seismic Rehabilitation of Buildings) belgesinde, betonarme yapılarda yatay yükleri taşımak amacıyla düzenlenen düzlemsel düşey elemanlar olarak ifade edilmektedir. Eurocode 8'de (Design of Structures for Earthquake Resistance) ise perdeler, diğer taşıyıcı elemanlarla mesnetlenmiş olan ve enkesit uzunluğu kalınlığının dört katından büyük elemanlar olarak tarif edilmektedir.

Betonarme perdeler, özellikle orta ve çok katlı yapıların deprem ve rüzgâr gibi yatay yüklere karşı direncini sağlayan en temel taşıyıcı sistem elemanlarıdır. Perde elemanların temel rolü, kendi düzlemleri içindeki yüksek rijitlikleri ve dayanımları sayesinde yatay kuvvetleri temele güvenli bir şekilde aktarmaktır. Kolon ve kirişlerden oluşan çerçeve sistemlerin aksine, perdeler geniş yüzey alanları sayesinde yer değiştirmeleri çok daha etkin bir şekilde sınırlar. Bu sınırlandırmalar, sadece taşıyıcı sistemin (kolonlar, kirişler) hasar görmesini engellemekle kalmaz, aynı zamanda duvarlar, pencereler, mekanik tesisat gibi yapısal olmayan elemanların hasarını da önemli ölçüde azaltır. Bu durum, yapının sadece can güvenliği performans seviyesini değil, aynı zamanda deprem sonrası hemen kullanım gibi daha yüksek performans hedeflerini de karşılayabilmesi için hayati önem taşır. Bu nedenle, sismik bölgelerde yapının genel stabilitesini sağlamakta önemli rol oynar.

Perdeler, geometrik özellikleri ve kesit geometrilerine göre sınıflandırılır; bu çalışma kapsamında dolu gövdeli, dikdörtgen kesitli perdeler kullanılmıştır. Dolu gövdeli perdeler H_w/l_w (yükseklik/boy) oranına bağlı olarak kısa (kesme etkisi baskın), narin (eğilme etkisi baskın) ve kesme-eğilme etkisinde olan perde olmak üzere üç grupta değerlendirilir. Türkiye Bina Deprem Yönetmeliği'nde (TBDY 2018) bu sınıflandırma için açık bir sınır değeri tanımlanmamıştır. FEMA 356'da $H_w/l_w > 3$ olduğunda narin, $H_w/l_w < 1,5$ olduğunda kısa ve $1,5 < H_w/l_w < 3$ aralığında kesme-eğilme etkisinde perde, Eurocode 8'de $H_w/l_w > 2$ olduğunda narin, $H_w/l_w < 2$ olduğunda kısa perde olarak tanımlanır. Her üç tipe ait yatay yük altındaki karakteristik davranışlar Şekil 1.1.'de sunulmaktadır.

Depreme dayanıklı tasarımın üç temel ilkesi; dayanım, rijitlik ve sünekliktir. Yüklere altında yapının davranışını bu ilkeler belirler. Herhangi birindeki yetersizlik hasara yol açacağı için; taşıyıcı sistem ve elemanlar, bu üç özelliği eşzamanlı sağlayacak biçimde tasarlanmalıdır.



Şekil 1.1. Yatay yük altında perde davranışı (Tan 2022)

Yapı mühendisliğinde dayanım, bir elemanın veya sistemin kırılmadan, ezilmeden veya başka bir tür göçme durumuna ulaşmadan taşıyabileceği maksimum kuvvet ya da gerilme kapasitesi olarak ifade edilir. Betonarme perdeler gibi taşıyıcı elemanlarda yeterli dayanım, tasarım yönetmeliklerinde öngörülen deprem yükleri altında oluşacak iç kuvvetleri (eğilme momenti, kesme kuvveti, aksenal yük) güvenli bir şekilde karşılayabilmesidir. Bu, yapının tasarım yükü etkisinde ayakta kalabilmesi için gereken ilk şarttır.

Rijitlik, bir yapının belirli bir yük altında ne kadar şekil değiştirdiğinin bir ölçüsüdür. Bir yapının deprem anında aşırı yatay ötelenme yapmasını önlemek için yeterli rijitlik oldukça gereklidir. Bu kontrolün sağlanması, özellikle katlar arası göreceli ötelenmelerin sınırlandırılması açısından kritik öneme sahiptir. Yeterli rijitlik, hem yapısal güvenliği hem de hasar kontrolünü ve servis edilebilirliği doğrudan etkileyen bir parametredir.

Süneklik, bir malzemenin veya yapısal elemanın dayanımında önemli bir kayıp olmaksızın büyük inelastik şekil değiştirmeler yapabilme kapasitesidir. Yeterli süneklik yapıdaki enerjinin kontrollü hasar yoluyla tüketilmesi durumudur. Deprem sırasında, perdelerin veya kolon-kiriş birleşimlerinin belirli bölgeleri (plastik mafsallar), büyük şekil değiştirmeler yaparak gelen sismik enerjinin önemli bir kısmını sönmüler. Bu enerji

tüketimi, yapının ani ve gevrek bir şekilde göçmesini engelleyerek ayakta kalmasını sağlar ve içindeki insanlar için güvenli bir tahliye imkânı sunar. Bu nedenle süneklik, yapının deprem sırasındaki davranışı için oldukça önemlidir.

Perdeler, deprem anında sadece yatay yükleri taşımakla görevli değildir, aynı zamanda bunu yaparken öngörülebilir ve güvenli bir şekilde hasar görmelidir. İstenen hasar mekanizması, perdenin tabanında sünek bir şekilde eğilme akmasına ulaşmasıdır. Buna karşılık, perdenin gövdesinde meydana gelebilecek gevrek kesme kırılması, ani bir göçmeye yol açabileceği için istenmeyen bir durumdur. Bu nedenle, betonarme perdelerin tasarımında Kapasite Tasarımı İlkesi uygulanır. Bu ilkeye göre, perde önce sünek eğilme kapasitesine ulaşacak şekilde tasarlanır; ardından bu eğilme kapasitesine ulaşıldığında ortaya çıkacak maksimum kesme kuvveti hesaplanır ve perde gövdesi bu kuvveti elastik olarak taşıyabilecek şekilde çok daha güçlü tasarlanır. Böylece, hasarın istenen sünek bölgede kalması ve gevrek şekilde göçme yapmaması sağlanır.

1.2. Performansa Dayalı Tasarımda Şekil Değiştirme Sınırları

Betonarme taşıyıcı sistemlerin sismik performansının değerlendirilmesi, elemanların dayanım kapasitelerinden ziyade, doğrusal olmayan şekil değiştirme kapasitelerine odaklanan Performansa Dayalı Tasarım yöntemine evrilmiştir. Bu yöntemde yapısal elemanların hasar düzeyleri ve performans hedefleri, belirli deformasyon sınırına ulaşıp ulaşılmadığına göre tanımlanır. Bu bağlamda, plastik dönme, beton birim kısalması ve çelik birim uzaması, bir betonarme perdenin davranışını ve kapasitesini tanımlayan en temel deformasyon esaslı performans sınırı parametreleridir.

1.2.1. Plastik dönme

Plastik dönme (θ_p), bir yapısal elemanın akma momentine ulaştıktan sonra, dayanımında önemli bir düşüş olmaksızın yapabildiği elastik ötesi dönme miktarıdır. Bu parametre, kesit düzeyindeki inelastik deformasyonların, eleman davranışı üzerindeki bütünsel etkisini temsil eden bir eleman düzeyinde süneklik göstergesidir. Deprem enerjisinin sönmüldüğü ve kontrollü hasarın meydana geldiği plastik mafsallarda

bölgelerindeki deformasyon kapasitesini nicel olarak ifade eder. ASCE 41 gibi yönetmeliklerde, yapısal elemanların performans düzeylerini karşılayıp karşılamadığı, büyük ölçüde plastik dönme taleplerinin, kapasiteyi aşıp aşmadığına göre belirlenir. Dolayısıyla θ_p bir perdenin genel sismik performansını ve deplasman kapasitesini tanımlayan önemli parametrelerden biridir.

1.2.2. Beton birim kısalması

Beton birim kısalması, bir kesitin en dış basınç lifinde meydana gelen deformasyon miktarını ifade eden performans kriteridir. Betonun davranışı, basınç altında belirli bir birim kısalma değerine (ϵ_c) ulaştığında gevrek bir şekilde ezilerek son bulur. Bu ezilme anı, kesitin basınç bloğunun taşıma kapasitesini kaybettiği ve moment kapasitesinin tükendiği bir göçme durumu olarak tanımlanır. Bu nedenle, betonun ulaştığı maksimum birim kısalma değeri, perdenin eğilme kapasitesinin ve sünekliğinin basınç kontrollü sınırını belirler. ϵ_c kesitin gevrek bir göçmeye ne kadar yakın olduğunu anlamak için önemlidir.

1.2.3. Çelik birim uzaması

Çelik birim uzaması, kesitin çekme bölgesinde yer alan boyuna donatılarda meydana gelen deformasyon miktarını tanımlar. Bu parametre, kesitin çekme kontrollü davranışını ve göçme modunu belirleyen malzeme düzeyinde bir performans göstergesidir. Donatının, akma birim uzaması ϵ_y değerine ulaşmasıyla birlikte, kesit belirgin bir rijitlik kaybı yaşar ve inelastik davranış göstererek sismik enerjiyi sönmülemeye başlar. Çekme kuvvetinin artmasıyla donatıdaki birim uzamanın kopma sınırına ϵ_{su} ulaşması ise, kesitin çekme kapasitesini tamamen kaybettiği ve ani göçmenin meydana geldiği bir durumu ifade eder. Bir kesitin göçme anında beton ezilmesi mi yoksa donatı kopması mı yaşayacağı, bu iki malzemenin ulaştığı nihai birim şekil değiştirme değerlerine bağlıdır. Tasarımda beklenen sünek davranış, çekme donatısının akma sınırını aştıktan sonra betonun ezilme sınırına ulaşmasıyla sağlanır. ϵ_s kesitin süneklik düzeyini ve göçme mekanizmasını kontrol eden temel bir parametredir.

1.3.Makine Öğrenmesi

Makine öğrenimi, bilgisayarlara mevcut veri kümeleri ve algoritmalarından nasıl tahmin yapılacağını öğretmeye odaklanan ve öğrendiği sistem üzerinden verideki gizli kalıpları bularak çıktıları oluşturan bir yapay zekâ sınıfıdır. Kullanılan öğrenme algoritması istenen performansı sağlayana kadar öğrenebilecek şekilde eğitilebilir.


Makine öğrenmesi yöntemleri, öğrenme biçimine göre üç ana grupta ele alınmaktadır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir.

- Denetimli öğrenme algoritması girdilere bağlı olarak çıktı değişkenlerinin olduğu ve bu etiketli (girdilere karşılık gelen çıktı) veri kümesinden eğitilen en temel makine öğrenimi türüdür. Eğitilen model, daha sonra yeni ve daha önce görülmemiş girdi verileri için çıktıları tahmin etme yeteneği kazanır. Bu yöntem, regresyon ve sınıflandırma problemleri için uygundur. Yapı mühendisliğinde hasar tespiti (sınıflandırma) ve dayanım tahminleri (regresyon) gibi alanlarda yaygın olarak kullanılmaktadır (Thai 2022). Çünkü bu alandaki problemler genellikle karmaşık ilişkiler içerir ve deneysel/simülasyon verileri etiketli veri setleri oluşturmaya elverişlidir.
- Denetimsiz öğrenmede sadece girdi değerleri bulunur ve temel amaç, verinin kendisi içindeki gizli yapıları, desenleri veya doğal gruplamaları keşfetmektir. Algoritma, etiketlenmemiş (çıktı değerleri olmayan) bir veri kümesinden eğitilir; bu nedenle, önceden tanımlanmış bir "doğru cevap" yoktur, algoritma verideki yapıyı kendisi ortaya çıkarır. Bu yöntem en yaygın olarak kümeleme ve boyut indirgeme problemlerinde kullanılır.
- Pekiştirmeli öğrenmede çevreyle iletişim kurularak karar alma süreci yönetilir. Algoritma deneme yanılma süreciyle eğitilir ve bu eğitim ödül veya ceza sistemiyle yürütülür. Nihai olarak toplam ödülü en üst düzeye çıkaracak en uygun davranış politikasını öğrenir.

Makine öğrenmesi algoritmaları, veri setindeki hedef fonksiyonun yapısına göre iki ana paradigmaya ayrılır: parametrik ve nonparametrik (parametrik olmayan)

yöntemler. Parametrik yöntemler, hedef fonksiyonun (gerçek değer ile tahmin edilen değer arasındaki ilişkinin) belirli bir yapıda olduğunu ve parametre sayısının sabit olduğunu varsayan modellerdir. Model, bu önceden tanımlanmış formülün sabit parametre katsayılarını eğitim verisini kullanarak öğrenmektedir. Az sayıda veriyle güçlü bir tahmin yapmaya olanak sağlar ancak verinin gerçek ilişkisi modelin varsaydığı formdan çok uzakta ise çok veri ile eğitilse dahi performans olumlu yönde gelişmez. Parametrik olmayan yöntemler, hedef fonksiyonun (gerçek değer ile tahmin edilen değer arasındaki ilişkinin) şekli hakkında çok az varsayımda bulunur veya hiç varsayımda bulunmaz. Bu modellerde, parametre sayısı sabit olmadığı gibi veri miktarına bağlı olarakta arttırılabilir. Varsayımlara sahip olmadığı için yeterli veriyle daha karmaşık ilişkileri yakalayabilir. Yapısındaki esneklik nedeniyle veri setinin ana yapısını öğrenmek için daha çok veriye ihtiyaç duyar. Öğrenme aşamasında veri setindeki gürültülü verileri de öğrenmeye yatkınlığı sebebiyle aşırı uyuma eğilimi vardır.

Çalışmada kullanılan veri seti girdiler ve etiketli verilerden oluştuğu için denetimli öğrenme kategorisinde incelenmelidir. Çıktı değişkeni sayısal verilerden oluşur, bu nedenle regresyon grubunda inceleme yapılacaktır. Denetimli öğrenmede regresyon algoritmaları incelendiğinde parametrik ve parametrik olmayan yöntemler olarak ikiye ayrılır. Veri setini daha iyi yansıtacağı için parametrik olmayan yöntemlerden ağaç tabanlı algoritmalar kullanılarak modeller oluşturuldu. Çalışmada kullanılan makine öğrenmesi algoritmalarının sınıflandırılması aşağıda verilmiştir (Şekil 1.2.). Bu kapsamda Karar Ağacı, Rastgele Orman, AdaBoost ve XGBoost algoritmaları ile modeller oluşturuldu.



Şekil 1.2. Makine öğrenmesi algoritmalarının genel olarak sınıflandırılması (çalışma özelinde)

1. GİRİŞ

Makine öğrenmesi modeli oluşturulurken üç temel adım vardır: veri tabanı hazırlama, öğrenme ve modeli değerlendirme.

1. Model oluşturulurken veriler girdi (öznitelik) ve çıktı (hedef) olarak nitelendirilir. Model performansını test etmek üzere tüm veri rastgele olarak eğitim ve test verisi şeklinde ayrılır. Verilerin büyük bir kısmı (%70-80) eğitim verisi olarak belirlenir.
2. Eğitim verileri üzerinden makine öğrenme algoritması eğitilir. Farklı algoritmalarda eğitilerek karşılaştırma yapılabilir. En uygun modele karar verilir.
3. Model eğitildikten sonra test verisi kullanılarak modelin performans değerlendirmesi yapılır. Tahmin edilen değerlerin gerçek değerlerle ilişkisini ölçmek için karekök ortalama kare hata, ortalama mutlak hata, belirleme katsayısı gibi kriterler kullanılır.

ML modeli kurulurken eğitim veri seti üzerinden en iyi genelleştirme yapacak şekilde algoritma seçilir. Bu şekilde oluşturulan modelin performansı test veri seti ile ölçülür. Kurulan modelin yeni bir veri setinde iyi bir tahmin yapabilmesi için bu modelin genelleştirilmiş bir model olması gerekmektedir. Eğitim verileri üzerinde model eğitilirken işlem sonucunda model aşırı öğrenebilir veya eksik öğrenebilir. Bu durumda model yanlış kurulduğu için yapılan tahminlerde hatalı olacaktır.


Aşırı öğrenme (overfitting)

Makine öğrenmesinde model kurulurken eğitim verisinin özelliklerinin çok iyi öğrenilip, farklı bir veri setinde (test veri setinde) hata yapmasına aşırı öğrenme (overfitting) denir. Bu durumda eğitim veri setini genel olarak yansıtan örneklerle beraber dağılımın dışında kalan örneklerde ezberlenir; böylece farklı bir veri setinde ezberlenilen örnek bulunmadığında hatalı bir tahmin ortaya çıkar. Model kurulurken aşırı öğrenme yapıldığının en belirgin göstergeleri; eğitim veri seti belirleme katsayısının (R^2) çok yüksek, test veri seti belirleme katsayısının düşük olması ve eğitim veri seti hata metriklerinin (RMSE, MAE) düşük, test veri seti hata metriklerinin belirgin şekilde yüksek olmasıdır.

Aşırı öğrenme için çözümler;

1. GİRİŞ

- Veri setine ek gözlemler dahil edilerek veri çeşitliliği artırılır.
- Modelin karmaşıklığını azaltmak amacıyla düzenleme (regularization) yöntemlerinden yararlanılır. Bu yaklaşımda, modelde ağırlığı yüksek olan değişkenlerin ağırlığı azaltılarak bu değişkenlerin etki oranını düşürülür. Regularization metotları Lasso ve Ridge teknikleridir. Lasso tekniğinde veri için daha önemli özellikler modele dahil edilirken, Ridge tekniğinde veride yer alan tüm özellikler kullanılır ancak katkılarının mümkün olduğunca az olması istenir.
- Veri seti öğrenme ve test verisi olarak ayrılır. Öğrenme verisi kendi içinde eğitim ve doğrulama olarak tekrar ayrılır. Eğitim seti üzerinden kurulan model ilk olarak doğrulama veri setinde test edilir. Model gelişim süreci tamamlandığında, test veri setinde değerlendirilmesi yapılır (Şekil 1.3.).



Şekil 1.3. Aşırı öğrenmeyi önlemek için veri setinin bölümlere ayrılması

Eksik öğrenme (underfitting)

Eksik öğrenme (underfitting), bir modelin verideki gerçek ilişkiyi yakalamada basit kalması nedeniyle hem eğitim hem de test verisinde düşük performans göstermesi durumudur. Model kurulurken eksik öğrenme yapıldığının en belirgin göstergeleri; eğitim veri seti belirleme katsayısının (R^2) düşük, test veri seti belirleme katsayısının da benzer şekilde düşük olması; eğitim ve test veri seti hata metriklerinin (RMSE, MAE) birbirine yakın ve yüksek olmasıdır.

Eksik öğrenme için çözümler;

- Veri setine veriyi daha iyi açıklayan özellikler eklemek ve veri sayısını arttırmak.
- Veri setini daha iyi yansıtacak esnek bir yöntemle modeli oluşturmak.
- Makine öğrenmesi algoritması olarak ağaç tabanlı bir yaklaşım belirlendi ise ağaç derinliğini veriyi yansıtacak şekilde arttırmak.

- Modelin karmaşıklığını azaltmak için kullanılan düzenleme parametreleri çok yüksek olduğunda modelin öğrenmesine engel olabilir. Bu değerleri düşürmek eksik öğrenmeyi önleyebilir.

Çalışmada denetimli öğrenme sınıfında yer alan parametrik olmayan regresyon yönteminde ağaç tabanlı algoritmalar kullanılmıştır. Bu algoritmaların detaylı açıklamaları aşağıda sıralanmıştır.


1.3.1. Karar Ağacı (DT)

Ağaç yapısına benzer bir sistem olan karar ağacı (Decision Tree-DT), hem regresyon hem de sınıflandırma problemlerinde kullanılan denetimli makine öğrenmesi algoritmasıdır. Karar Ağacı ağaca benzer şekilde çalışır. Ağacın tabanı *kök düğümüdür* ve düğümler özniteliklerden oluşur. Bu düğümdeki koşula göre “Evet” veya “Hayır” olarak dallanarak sınıflandırılır. Verilecek karara göre *karar düğümleri* oluşur. Karar düğümlerindeki koşula göre “Evet” veya “Hayır” kararlarının sonuçlarını temsil eden *yaprak düğümler* oluşur. Her karar bir soruyu veya ayrılma noktasını temsil eder ve yaprak düğümler nihai cevapları ifade eder. Ağaç yapısına benzer şekilde yaprak düğümleri karar düğümlerindeki dallarda ortaya çıkar. Bu nedenle karar ağacının her bir alt bölümüne *dal* denir. Şekil 1.4.’de yer alan düzey ifadesi, bir düğümün köke olan uzaklığını temsil eder ve derinlik olarak da ifade edilebilir. Kök düğümün düzeyi sıfır alınarak diğer düğümlerin düzeyi belirlenir. Karar Ağacı çalışma sistemini açıkladığımızda; kök düğümdeki $l_w \leq 4$ koşulunun cevabına göre dallanma yapıldı, dallanmaya karar verirken bu düğümdeki örneklerin çıktıya göre ortalama mutlak hatası (*squared_error*) hesaplandı. *sample* bu düğümdeki eğitim örneği sayısını ve *value* çıktı değerinin ortalamasını göstermektedir. *value* değeri yaprakta olsa idi çıktı değerini gösterirdi. Ağacın derinliği *max_depth* şekil kesitinde yer aldığı kadarıyla 3 olarak görülür.

Karar Ağacı modeli oluşturulurken tüm veri seti rastgele olarak öğrenme ve test verisi şeklinde ayrılır. Veri kümesinin büyük bir kısmı (%70-80) öğrenme işleminde, kalan kısımda oluşturulan ağaç modelin test işleminde kullanılır. Öğrenme verisi kullanılarak veri setini en iyi yansıtan Karar Ağacı oluşturulur. Oluşan ağaç modelinin

1. GİRİŞ

başarısını ölçmek için ise daha önce tüm veri setinden ayrılan test verisi kullanılır. Öğrenme verisi ve test verisi arasındaki doğruluk oranı kabul edilebilir seviyede ise model yeni veriler için de kullanılabilir.



Şekil 1.4. Karar ağacı algoritmasının grafiksel gösterimi (Şekil çalışmadaki Karar Ağacı modelinden alındı).

Karar Ağacında dallanma kriterleri

Karar Ağacı oluşturulurken, ilk olarak kök düğümün hangi değişken olması gerektiğine karar verilir. Veri setinde yer alan öznelilikler arasında belirleyici olanın seçimi ağacın performansı için çok önemlidir. Bu nedenle kök düğümün kararı için çeşitli hesaplamalar yapılır.

Ağaçtaki bölünmenin karar aşamasında yaygın olarak *Entropi* hesabına dayalı kriterler ve *Safsızlık Fonksiyonuna* dayalı bölünme kriterleri kullanılır. Safsızlık fonksiyonu kriteri Sınıflama ve Regresyon Ağaçlarında (Classification and Regression

Tress: CART) kullanılır. Sınıflama ağacı problemlerinde yaygın olarak kullanılan safsızlık fonksiyonuna dayalı kriter, *gini* kriteridir. Regresyon ağacı problemlerinde yaygın olarak kullanılan bölme kriteri ise *en küçük kareli sapma* yöntemidir.

Entropi rastgele değerlere sahip bir değişkenin ya da sistemin, rassal bir olayın gerçekleşmesi durumunda taşıdığı belirsizlik düzeyini ifade eden bir ölçüttür. Bu kriterde veri setinde yer alan her bir sınıfın olma olasılığı (p_i) hesaplanır. Olasılık hesabından sonra veri setinin entropisi hesaplanır. Entropiyi düşüren sınıf en çok kazanç sağlayan sınıf olur ve bu sınıf kök düğüm olur (Denklem 1.1). Entropi, 0 ile 1 arasında değer alan bir ölçüttür. Veri kümesinde yalnızca tek bir sınıf bulunduğunda entropi 0 olurken, tüm sınıfların gerçekleşme olasılıklarının birbirine eşit olduğu durumda 1 değerine ulaşır. Örneklerin sınıflar arasında rastgele bir şekilde dağıldığı ara durumlarda entropi 0 ile 1 arasında bir değer alır ve bu değer 1'e yaklaşması, sistemdeki belirsizliğin arttığını gösterir.

$$H_i = -\sum_{i=1}^m p_i \log_2(p_i) \quad (1.1)$$

Gini indeksi bir veri düğümündeki hedef nitelik sınıflarının karışıklık seviyesini ölçen bir kriterdir. Her sınıfın gerçekleşme olasılığı (p_i) hesaplanır ve çıkan sonuçların karelerinin toplamı birden çıkartılır. Bu indeks 0 ile 1 arasında bir değer alır; 0 değeri düğümün tamamen saf (tüm örneklerin tek bir sınıfa ait) olduğunu gösterirken, 1'e yaklaşan değerler yüksek karışıklığı ifade eder. (Denklem 1.2).

$$Gini = 1 - \sum_{i=1}^m (p_i)^2 \quad (1.2)$$

En küçük kareli sapma (LSD) yaklaşımında, model parametreleri toplam kare hata ölçütü en aza indirilerek elde edilmektedir. $R(t)$ ile gösterilen LSD ölçüsü, t düğümüne ait düğüm içi varyansı temsil eder ve bu düğüm için risk tahmini olarak kullanılmaktadır. $R(t)$ 'nin formülü aşağıdaki şekildedir (Oğuzlar 2004).

$$R(t) = \frac{1}{N_w(t)} \sum_{i \in t} w_n f_n(y_1 - \bar{y}(t))^2 \quad (1.3)$$

$N_w(t)$, t düğümündeki ağırlıklandırılmış durum sayısını; W_n i ilgili durum için mevcutsa ağırlıklandırılmış değişken değerini; f_n mevcutsa frekans değişkeninin değerini; y_1 hedef değişkenin değerini ve $\bar{y}(t)$ ise t düğümü için ağırlıklı ortalamayı göstermektedir.

Karar Ağacının Budanması

Karar Ağacı veriyi en yalın halde temsil etmek için karmaşık bir hal alabilir. Bu karmaşıklık sonunda overfitting meydana gelir ve model yeni veriler için doğru sonuçlar ortaya koyamaz. Bu sorunu çözmek için, ağaç üzerinde yer alan bazı alt ağaçlar kaldırılarak yerlerine tek bir yaprak (uç düğüm) konulur. Böylece ağacın gereğinden fazla derinleşmesi ve dallanması engellenir. Karar ağacının bu şekilde sadeleştirilmesi işlemi, “karar ağacının budanması” olarak adlandırılır.

Budama iki şekilde gerçekleştirilir. *Ön budama* ağaç oluşmadan gerçekleştirilir. Ağaçta yer alan alt düğümlerin hepsi yaprak düğüm olan bir düğümün saflık artışı, istatistiki açıdan önemli değilse gereksiz olarak görülür ve bu düğümün tüm alt düğümleri kaldırılır. *Son budama* ağaç oluşuktan sonra gerçekleştirilir. Bir doğruluk ölçütü belirlenerek az bilgi içeren, ağaca katkısı olmayan düğümler kaldırılır. Böylece ağacın genel doğruluğu artırılmış olur.

Karar Ağacı yöntemleri

Karar ağacında; kök, düğüm ve bölme kriteri seçimindeki farklılıklara göre birçok algoritma geliştirilmiştir. Örneğin kök düğümün kararlarına göre farklı ağaç modelleri ortaya çıkabilir. Bunun sonucunda da aynı veri için farklı sınıflandırmalar meydana gelebilir.

Karar ağacında sadece sayısal değerlerle, sadece kategorik değerlerle ve bazıları ise 0-1 değerlerle işlem yapan algoritmalar geliştirilmiştir (Saitoğlu Sevimli 2015).

1. GİRİŞ

Çizelge 1.1. Karar ağacı algoritmaları (Saitoğlu Sevimli 2015)

Karar Ağacı Algoritması	Gelişim Süreci	Veri Tipi	Çalışma Mekanizması	Oluşan Ağaç Modeli	Ağaç Dallanma Kriteri
AID Algoritması	Morgon ve Sonquist-1964	Bağımlı değişken nicel (aralıklı/oransal), bağımsız değişken kategorik (nominal /ordinal) olmalıdır.	Ağaçta sadece ikili bölünmeler olur. Yani ikili ağaçlar oluşturur.	Bağımlı değişken nicel olduğu için regresyon ağacı oluşur.	Gruplar arası kareler toplamı kriterini kullanır.
CHAID Algoritması	Gordon V. Kass-1980	Bağımlı değişken kategorik (ordinal / nominal) veya sürekli, bağımsız değişken kategorik (nominal /ordinal) olmalıdır.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik ise, sınıflama ağacı-sürekli ise regreyon ağacı oluşur.	Bağımlı değişken sürekli ise F testini-Bağımlı değişken nominal ise pearson ki-kare testini, bağımlı değişken ordinal ise en çok olabilirlik testini kullanır.
CART Algoritması	Breiman, Friedman, Olshen ve Stone-1984	Bağımlı değişken kategorik (ordinal / nominal) veya sürekli olabilir. Bağımsız değişken çeşidi ayrımı yoktur.	Ağaçta sadece ikili bölünmeler olur. Yani ikili ağaçlar oluşturur.	Bağımlı değişken kategorik ise, sınıflama ağacı-sürekli ise regreyon ağacı oluşur	Bağımlı değişken kategorik ise, gini ya da twoing kriteri, bağımlı değişken sürekli ise EKK yöntemi kullanılır.
ID3 Algoritması	Quinlan-1986	Bağımlı ve bağımsız değişkenler kategoriktir (ordinal / nominal).	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Kazanç ölçütü kriterini kullanır.
MARS Algoritması	Jerome H. Friedman-1991	Bağımlı değişken ikili (binary) veya sürekli olabilir. Bağımsız değişken çeşidi ayrımı yoktur.	Ağaçta sadece ikili bölünmeler olur. Yani ikili ağaçlar oluşturur.	Bağımlı değişken kategorik ise, sınıflama ağacı-sürekli ise regreyon ağacı oluşur	İleriye ve geriye doğru adım algoritmalarını kullanır.
Exhaustive CHAID Algoritması	Biggs, de ville ve Suen-1991	Bağımlı değişken kategorik (ordinal / nominal) veya sürekli, bağımsız değişken kategorik (nominal /ordina) olmalıdır.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik ise, sınıflama ağacı-sürekli ise regreyon ağacı oluşur	Bağımlı değişken sürekli ise F testini-Bağımlı değişken nominal ise pearson ki-kare testini, bağımlı değişken ordinal ise en çok olabilirlik testini kullanır.

1. GİRİŞ

Çizelge 1.1. (devam)

Karar Ağacı Algoritması	Gelişim Süreci	Veri Tipi	Çalışma Mekanizması	Oluşan Ağaç Modeli	Ağaç Dallanma Kriteri
C4.5 Algoritması	Quinlan 1993	Bağımlı değişken kategorik (ordinal / nominal), bağımsız değişkenler ise kategorik veya sürekli olabilir.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Kazanç oranı kriterini kullanır.
C5.0 Algoritması	Quinlan-1993	Bağımlı değişken kategorik (ordinal / nominal), bağımsız değişkenler ise kategorik veya sürekli olabilir.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Kazanç oranı kriterini kullanır.
SLIQ Algoritması	Mehta, Agarwall ve Rissanen-1996	Bağımlı değişken kategorik (ordinal / nominal), bağımsız değişkenler kategorik veya sürekli olabilir.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Gini kriterini kullanır.
SPRINT Algoritması	Shafer, Agarwall ve Mehta-1996	Bağımlı değişken kategorik (ordinal / nominal), bağımsız değişkenler kategorik veya sürekli olabilir.	Ağaç çoklu alt gruplara ayrılır. Yani çoklu ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Gini kriterini kullanır.
OUEST Algoritması	Loh ve Shih-1997	Bağımlı değişken kategorik (nominal), bağımsız değişkenler kategorik (ordinal / nominal) veya sürekli olabilir.	Bağımlı değişkeni sadece ikiye böler. Yani ikili ağaçlar oluşturur.	Bağımlı değişken kategorik olduğu için sınıflama ağacı oluşur	Kuadratik diskriminant analizini kullanır.

Birçok Karar Ağacı uygulamasında, ağaçları eğitmek için CART (Classification and Regression Trees) algoritması temel alınır.

CART algoritması

CART, hem sınıflandırma (bir verinin hangi kategoriye ait olduğunu bulma) hem de regresyon (sürekli bir değeri tahmin etme) problemleri için kullanılabilen temel bir makine öğrenmesi algoritmasıdır.

CART ağaç oluşum sürecinde bağımsız değişkene yönelik sorulardan alınan evet/hayır yanıtlarına göre ikili gruplara bölünür. Bu şekilde yaprak düğümüne ulaşana kadar, karar düğümleri ikili bölünme yaparak ilerler (Şekil 1.4.).

Karar Ağacı hiperparametreleri

Hiperparametre, modelin eğitim sürecini denetlemeye izin veren başlangıçta ayarlandığı gibi daha sonra da ayarlanabilen parametrelere denir. Modelin performansını önemli derecede etkilediği için hiperparametre seçimleri çok önemlidir.

Scikit-Learn Decision Regression Trees (Karar Ağacı Regresyon) hiperparametreleri aşağıdaki gibidir.

splitter {"best", "random"}, varsayılan="best"

Her düğümde bölme yöntemini seçmek için kullanılan strateji.

criterion {"squared_error", "friedman_mse", "absolute_error", "poisson"},
varsayılan="squared_error" (Regresyon için)

Ağacın dallanma kriterini belirler.

max_depth: int, varsayılan=None

Karar ağacının alabileceği en büyük derinlik değerini belirler. Bu parametre None bırakıldığında, düğümler; yapraklar tamamen saflaşmaya ya da her bir yapraktaki örnek sayısı min_samples_split değerinin altına düşünceye kadar bölünmeye devam eder.

min_samples_split: int or float, varsayılan=2

Bir iç düğümün daha fazla dallanabilmesi için o düğümde bulunması gereken asgari örnek sayısı için bir eşik değeridir.

min_samples_leaf: int or float, varsayılan=1

Bir yaprak düğümdeki en az örnek sayısını ifade eder.

max_leaf_node: sint, varsayılan=None

Yaprak düğüm sayısını temsil eder. None ise sınırsız yaprak düğüm olur.

min_weight_fraction_leaf: float, varsayılan=0.0

Bir yaprak düğümde bulunması gereken örneklerin, toplam örnek ağırlığı içindeki asgari oranını ifade eder.

max_features: int, float or {"auto", "sqrt", "log2"}, varsayılan=None

Her düğümde bölünme için değerlendirilen öznelik sayısının maksimum değeri.

- int ise, her bölmede max_features özelliklerini göz önünde bulundurun.
- Float ise, max_features bir kesirdir ve her bölmede int (max_features * n_features) özellikleri dikkate alınır.
- "otomatik" ise, o zaman max_features=sqrt(n_features).
- Eğer "sqrt" ise, o zaman max_features=sqrt(n_features).
- "log2" ise, max_features=log2(n_features).
- None ise, max_features=n_features.

random_state: int, RandomState instance or None, varsayılan=None

Eğitim ve test verisi olarak ayrılan veri setinde rastgeleliği kontrol eder. Model kurulduğunda her seferinde aynı yerden bölünmesini sağlar. Genelde 0 veya 42 yazılır. Tüm ağaç modellerinde yer alır.

min_impurity_decrease: float, varsayılan=0.0

Safsızlığa bağlı olarak ağacın ne kadar büyüdüğünü kontrol etmeye olanak tanır.

ccp_alpha: non-negative float, varsayılan=0.0

Budama için kullanılan karmaşıklık parametresidir.

Hiperparametre ayarı yapılmadığında regresyon için varsayılan hiperparametreler: `sklearn.tree.DecisionTreeRegressor(*, criterion='squared_error', splitter='best', max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features=None, random_state=None, max_leaf_nodes=None, min_impurity_decrease=0.0, ccp_alpha=0.0)`.

1.3.2.Rastgele Orman (RF)

Bir topluluk algoritması olan Rastgele Orman (Random Forest-RF), bootstrap ile türetilmiş örneklemeler üzerinde birbirinden görece bağımsız çok sayıda karar ağacını eğitir; nihai tahmin, bireysel ağaç çıktılarının ortalaması (regresyon) ya da çoğunluk oyu (sınıflandırma) ile elde edilir. Karar Ağacından farklı olarak her düğümde yalnızca rastgele seçilmiş bir öznelik alt-kümesi değerlendirilir. Bu şekilde ağaçlar arası korelasyon azalır, varyans düşer ve genellenebilirlik artar. Başlıca hiperparametreleri;

n_estimators, num_boost_round, varsayılan =100

Kullanılacak ağaç sayısını ifade eder. 0'dan büyük olmalıdır. Bu sayı çok büyük olduğunda overfittinge sebep olabilir.

max_features, "sqrt", "log2", None, int veya float, varsayılan =1.0

Ağacın her düğümde en iyi bölünmeyi ararken dikkate alacağı maksimum özellik sayısını veya oranını belirler.

Bootstrap, bool, varsayılan: True

Varsayılan ayarı, her bir ağacın, orijinal veri setinin tamamı yerine, o veri setinden tekrar örnekleme ile oluşturulmuş farklı bir alt-veri seti üzerinde eğitilip eğitilmeyeceğini belirler.

max_samples, int veya float (0,1] ya da None, varsayılan = None (yalnızca bootstrap =True iken)

Her ağaç için bootstrap'ten çekilecek örnek sayısı/oranı; hız ve çeşitliliği etkiler.

n_jobs, None / -1 / int, varsayılan = None

Paralel çekirdek sayısı.

Criterion, str, varsayılan= squared_error

Bölünme/kayıp ölçütü.

max_depth, aralık: [0-∞], varsayılan = None

Oluşturulan ağacın derinliğini ifade eder. Derinlik 0 alınır ise herhangi bir sınırlama olmaz, çok fazla olduğunda da overfitting problemine neden olabilir.

1. GİRİŞ

min_samples_split, int veya float, varsayılan =2

Bir düğümün bölünmeden önce sahip olması gereken en az örnek sayısıdır.

min_samples_leaf, int veya float, varsayılan=1

Bir yaprak düğümde bulunması gereken en az örnek sayısını ifade eder. Bu hiperparametre, modelin eğitim verisindeki çok küçük grupları öğrenmesini engelleyerek overfittingi önlemeye yardımcı olur.

min_weight_fraction_leaf, float, varsayılan= 0.0

Alt düğümlerde bulunan örnek ağırlıklarının minimum toplamı. Overfittingi kontrol eder.

oob_score (bool, varsayılan= False

Bootstrap kullanılınca her ağaç için seçilmeyen gözlemler OOB olarak kalır; bunlar, ek bir cv yapmadan genelleme hatasının tahmininde kullanılabilir.

random_state: int, RandomState instance or None, varsayılan=None

Eğitim ve test verisi olarak ayrılan veri setinde rastgeleliği kontrol eder. Model kurulduğunda her seferinde aynı yerden bölünmesini sağlar. Genelde 0 veya 42 yazılır. Tüm ağaç modellerinde yer alır.

1.3.3.Boosting algoritmaları

Uyarlanabilir Arttırma ve Aşırı Gradyan Arttırma bir topluluk öğrenme modeli olan Boosting algoritmalarıdır. Topluluk öğrenme (Ensemble Learning), birden fazla öğrenme algoritmasının birlikte kullanılarak elde edilen çıktılar üzerinden model performansının iyileştirilmesini amaçlayan bir yaklaşımdır.

Boosting'in (Boosting Algorithm-BA) çalışma prensibi, birçok zayıf öğrenciyi bir araya getirip belli kurallar çerçevesinde eğiterek güçlü bir öğrenci ortaya çıkarmaktır. Buradaki amaç sonraki her modelin kendinden önceki hataları düzelterek optimal sonuca ulaşılmasıdır. Gelişim sırasıyla, Uyarlanabilir Arttırma (Adaptive Boosting-AdaBoost), Gradyan Arttırma Metodu (Gradient Boosting Method-GBM), Aşırı Gradyan Arttırma

1. GİRİŞ

(Extreme Gradient Boosting-XGBoost), Light GBM ve CatBoost algoritmaları boosting algoritmasına uygun olarak geliştirilen yöntemlerdir.

1.3.4.Uyarlanabilir Arttırma (AdaBoost)

Uyarlanabilir Arttırma (Adaptive Boosting-AdaBoost), eğitim kümesini ardışık zayıf sığ karar ağaçlarıyla öğrenir. Her turda, hatası yüksek kalan örneklerin ağırlıkları artırılır; sıradaki zayıf ağaç, bu ağırlığı arttırılan örneklere daha çok odaklanır. Turlar sonunda tüm zayıf modellerin çıktıları ağırlıklı olarak birleştirilir ve nihai tahmin elde edilir. Başlıca hiperparametreleri;

n_estimators, num_boost_round, varsayılan =50

Kullanılacak ağaç sayısını ifade eder. 0'dan büyük olmalıdır. Bu sayı çok büyük olursa overfittinge sebep olur.

estimator, object, varsayılan =None

Zayıf öğrenicinin kapasitesini tanımlar ve bu kapasite arttıkça modelin önyargısı azalırken overfitting riski artar.

max_depth, aralık: [0-∞], varsayılan = 3

Oluşturulan ağacın derinliğini ifade eder. Derinlik 0 alınır ise herhangi bir sınırlama olmaz, çok fazla olduğunda da overfitting problemine neden olabilir.

learning_rate, float, varsayılan =1.0

Her turdaki zayıf öğrenicinin katkısını ölçerler; küçük değerler daha çok tur gerektirir ama çoğu zaman daha kararlı genel performans verir.

Loss, 'linear', 'square', 'exponential', varsayılan= linear

Algoritmanın örnek ağırlıklarını güncellemek için hangi kayıp fonksiyonunun kullanılacağını belirler.


random_state: int, RandomState instance or None, varsayılan=None

Eğitim ve test verisi olarak ayrılan veri setinde rastgeleliği kontrol eder. Model kurulduğunda her seferinde aynı yerden bölünmesini sağlar. Genelde 0 veya 42 yazılır. Tüm ağaç modellerinde yer alır.

1.3.5.Aşırı Gradyan Arttırma (XGBoost)

Aşırı Gradyan Arttırma (Extreme Gradient Boosting-XGBoost), Gradyan Arttırma Metodu (Gradient Boosting Method-GBM) algoritmasının çeşitli düzenlemeler ile optimize edilerek yüksek performanslı hale getirilmesiyle ortaya çıkmıştır. 2015 yılında yapılan 29 Kaggle yarışmasının 17 tanesinin XGBoost ile kazanılması (Chen and Guestrin 2016) ve 2016 yılında da Tianqi Chen ve Carlos Guestrin tarafından yayınlanan “XGBoost: A Scalable Tree Boosting System” makale ile XGBoost, algoritma kullanımında öne çıkmıştır. Veri bilimciler tarafından gelişimi devam eden XGBoost’un, Github’ta binlerce içeriği bulunmaktadır. XGBoost, GBM algoritmasının bazı noktalarda yetersiz olmasından dolayı geliştirilmiştir. Bu nedenle GBM algoritmasının işleyişinin incelenmesi gerekmektedir.

Gradyan Arttırma Metodu, zayıf öğrencileri kullanarak güçlü bir tahmin modeli oluşturan, sıralı bir topluluk öğrenme tekniğidir. Regresyon ve sınıflandırma için kullanılır. Temel öğrenci olarak kullanılan ağaç modelleri, her biri seri halinde ağaç, önceki ağaç tarafından hesaplanan hatalar üzerine kurulur. Zayıf öğrenci olarak ağaç modeli kullanıldığı için her ağaç modelinden farklı çıktılar elde edilebilir. Model oluşturulurken, sonraki ağacın eğitiminde önceki ağacın artık kaybı (hata) dikkate alınır (Şekil 1.5.). Ardışık model eğitimi nedeniyle uygulamada yavaş kalan GBM’nin hızını ve performansını iyileştirmek için XGBoost geliştirilmiştir.




Şekil 1.5. Gradyan arttırma metodu algoritmasının çalışma prensibi (Thai 2022)

XGBoost algoritması hem sınıflandırma hem de regresyon problemlerini çözebilen birçok sınıflandırma ve regresyon ağacından (CART) oluşur. Her bir ağaç modelinin sonuçları bir araya getirilerek, XGBoost modelinin tahmin sonucunu verir (Şekil 1.6.).

Aşırı Gradyan Arttırmayı diğer algoritmalarından ayıran belirgin özellikler şu şekildedir: büyük veri kümelerinde hızlı ve doğru çözüm için karar ağaçlarını oluştururken paralel işlem uygular; *max_depth* hiperparametresi ile ağacın derinliği belirlenerek, ağaç aşağı yönde fazla ilerler ise geriye doğru budama yapılır ve performansı artırır; veri setinde eksik veri olduğu durumlarda zayıf öğrenenler yardımıyla eksik veriyi öğrenebilir; ağaçları en doğru noktadan bölebilmek için model oluşturma sürecinde veri setindeki gözlem noktalarını ağırlıklı olarak dikkate alır; çapraz doğrulamayı kendi içinde barındırır; aşırı uydurmayı önlemek için hem Lasso hem de Ridge tekniklerini kullanır. Lasso tekniğinde veri için daha önemli öznitelikler dahil edilerek model sadeleştirilir ve daha iyi yorumlanması sağlanır. Ridge tekniğinde ise veride yer alan tüm öznitelikler kullanılır ancak katkılarının mümkün olduğunca az olması istenir. XGBoost gradyan azaltma optimizasyonu kullanarak hatayı minimum yapar. Gradyan azaltma, bir fonksiyon üzerinde rastgele bir noktadan başlayarak eğitim üzerinde adım adım ilerleyerek

1. GİRİŞ

en az hataya ulaşmayı amaçlayan algoritmadır. Gradyan azaltma optimizasyonu algoritmaya ait hiperparametreleri sürekli güncelleyerek en az hataya ulaşmayı amaçlar.



Şekil 1.6. Aşırı gradyan artırma algoritmasının çalışma prensibi (Liu et al. 2022)

XGBoost hiperparametreleri, genel parametreler, arttırıcı (booster) parametreler, öğrenme görevi parametreleri ve komut satırı parametreleri olarak dört başlık altında incelenir. Model kurulurken daha etkin rol alan hiperparametreler;

Booster, seçenekler: gbtree, gblinear veya dart, varsayılan = gbtree

Algoritmanın her adımda hangi zayıf öğrenici modelini kullanacağını belirler.

num_estimators (num_boost_round), varsayılan =100

Kullanılacak ağaç sayısını ifade eder. 0'dan büyük olmalıdır. Bu sayı çok büyük olursa overfittinge sebep olur.

eta (learning rate), aralık: [0-1], varsayılan =0.3

Algoritmanın öğrenme oranıdır. Overfittingi önlemek için kullanılır.

max_depth, aralık: [0-∞], varsayılan =6

Oluşturulan ağacın derinliğini ifade eder. Derinlik 0 alınır ise herhangi bir sınırlama olmaz, çok fazla olursa da overfitting problemine neden olur.

subsample, aralık: [0-1], varsayılan =1

1. GİRİŞ

Eğitim örneğinin alt örneklem oranını temsil eder. Varsayılan değeri olan 1; örneklem olmadığını tüm verilerin kullanıldığını ifade eder. Örneğin bu parametre, 0.8 olarak belirlenirse, eğitim verisinin %80'i eğitici olarak kullanılır. Overfittingi önlemek için kullanılır.

colsample_bytree, aralık: [0-1], varsayılan =1

Oluşturulan her ağaç sütunların alt örnek oranıdır.

objective, varsayılan =reg:squarederror

Öğrenme görevini ve kullanılacak kayıp fonksiyonunu tanımlar.

alpha (reg_alpha), varsayılan =0

Modelin karmaşıklığını kontrol eden ve overfittingi önleyen bir L1 (Lasso) düzenleme parametresidir. Değeri artırıldıkça, model daha tutucu hale gelir ve önemsiz gördüğü bazı özelliklerin ağırlıklarını tam olarak sıfıra indirgeyerek özellik seçimi yapılabilir.

lambda (reg_lambda), varsayılan =1

Modelin karmaşıklığını kontrol eden ve overfittingi önleyen bir L2 (Ridge) düzenleme parametresidir. Değeri artırıldıkça, model daha tutucu hale gelir; bunu, ağırlıkların karelerini cezalandırarak ve çok büyük değerler almalarını engelleyerek yapar.

gamma (min_split_loss), aralık: [0-∞], varsayılan =0

Ağaçta düğümler bölünürken alt taraftaki düğümlerin hedef fonksiyona göre bir skoru çıkartılır. Bu skor gamma değerinden büyükse bölünme gerçekleşir.

min_child_weight, aralık: [0-∞], varsayılan =1

Alt düğümlerde bulunan örnek ağırlıklarının minimum toplamı. Overfittingi engellemek için kullanılır.

random_state: int, RandomState instance or None, varsayılan=None

Eğitim ve test verisi olarak ayrılan veri setinde rastgeleliği kontrol eder. Model kurulduğunda her seferinde aynı yerden bölünmesini sağlar. Genelde 0 veya 42 yazılır. Tüm ağaç modellerinde yer alır.

1.3.6.Hiperparametre optimizasyonu

Optimum bir makine öğrenmesi modeli oluşturabilmek için modele ait bir dizi olasılık vardır. En uygun hiperparametreleri seçerek model mimarisini oluşturma süreci hiperparametre optimizasyonu olarak adlandırılır. Hiperparametre ayarlama işlemi, kategorik, ayırık ve sürekli hiperparametreler dahil olmak üzere farklı hiperparametre türleri nedeniyle makine öğrenimi algoritmaları arasında farklıdır (Yang and Shami 2020).

En uygun hiperparametreyi bulmak için elle tek tek deneme yapılabilir; ancak bu oldukça uzun süren ve hata ihtimali yüksek bir yöntemdir. Elle yapılan işlemde her bir hiperparametre değeri için ancak bir değer girilir ve model kurulduğunda hangi hiperparametre değerinin olumlu hangisinin olumsuz katkı sağladığı anlaşılamaz. Bu nedenle hiperparametre optimizasyonu için birçok yöntem geliştirilmiştir.

Çalışmada; hiperparametre optimizasyonu için klasikleşen ve yeni geliştirilen, iki yöntem kullanılarak aralarındaki fark ortaya konmuştur. Scikit-Learn’de yer alan Izgara Arama (Grid SearchCV) ve Rastgele Arama (RandomSearchCV-RS) yöntemleri hiperparametre optimizasyonunda yaygın olarak kullanılmaktadır. Her iki optimizasyon tekniğinden uygulama süresi daha az olan RS seçilmiştir. Diğer bir yöntem olarak ise son zamanlarda geliştirilen ve uygulamada daha hızlı işlem süresine sahip Optuna seçilmiştir.

Rastgele Arama

Rastgele Aramanın hiperparametre optimizasyonu için popüler ve etkili bir yöntem olarak kabul görmesi, 2012 yılında James Bergstra ve Yoshua Bengio tarafından yayınlanan "Random Search for Hyper-Parameter Optimization" adlı makale ile olmuştur.

Rastgele Arama, hiperparametre uzayından önceden belirlenen sayıda rastgele örnek çekerek her örnek için modeli eğitip doğrulama performansını ölçen ve en iyi skoru veren ayarı seçen bir optimizasyon yöntemidir. Yani, her bir parametre için olası tüm

değerleri tek tek denemek yerine, rastgele noktalar seçerek bu uzayı daha verimli bir şekilde keşfetmeye çalışır.

Optuna

Optuna, Japon yapay zekâ şirketi Preferred Networks tarafından geliştirilmiştir (Akiba et al. 2019). Açık kaynaklı bir otomatik hiperparametre optimizasyon kütüphanesidir ve hiperparametreleri optimize etmek için deneme-yanılma sürecini otomatikleştirir. Bir optimizasyon hedefine dayalı olarak optimum hiperparametre değerlerini otomatik olarak bulur. Bayes optimizasyonu tabanlı bir hiperparametre ayarlama kütüphanesi olan Optuna; TPE, CMA-ES ve GridSearch gibi çeşitli arama algoritmalarını desteklemenin yanı sıra, paralel ve dağıtılmış optimizasyon olanağı sağlamaktadır. Optuna varsayılan olarak bayes optimizasyon algoritmasını (TPE) kullanır.

Optuna üç temel kavram üzerinden çalışır: amaç, deneme ve çalışma. Amaç, optimize edilecek minimum fonksiyonun tanımlanmasından ve hiperparametrelerin aralığının belirlenmesinden sorumludur; deneme, amacın tek bir uygulamasına karşılık gelir; çalışma, optimizasyonun yönetilmesinden ve toplam deneme sayısının nasıl optimize edileceğine karar verilmesinden ve sonuçların kaydedilmesinden sorumludur. Optuna ile hiperparametrelerin etkinlikleri görselleştirilerek incelenebilir.

1.3.7.Makine öğrenmesi model yorumlama: SHAP

Shapley Toplamsal Açıklamaları (Shapely Additive Explanation-SHAP), oyun teorisindeki Shapley değerlerine dayanarak her bir gözlem için her özelliğin tahmine marjinal katkısını hesaplayan katkı-toplamlı bir yorumlama çerçevesidir. Böylece model türünden bağımsız biçimde açıklamalar üretir; bu katkılar ortalamasıyla genel önem ve etki yönleri de türetilir. Kuramsal olarak SHAP; yerel doğruluk, yokluk ve tutarlılık aksiyomlarını aynı anda sağlayan tekil bir çözümü karakterize eden birleştirici bir çerçeve sunar (Lundberg and Lee 2017). Makine öğrenmesi modellemesi, girdi değişkenlerinin çıktı üzerindeki genel etkisini belirleyebilir. SHAP gibi açıklanabilirlik yöntemleri, her bir girdinin etki büyüklüğünü, yönünü (pozitif veya negatif) ve girdilerin birbirleriyle

olan etkileşimlerinin çıktı üzerindeki birleşik etkisini detaylı olarak ortaya koyar. SHAP'da yer alan grafiklerin özellikleri aşağıda sıralanmıştır.

Global Bar Plot (Çubuk Grafiği); Modeldeki en önemli özelliklerin net bir sıralamasını sunar. Genellikle tek renkli olan bu grafikte en uzun çubuk, o özelliğin modelin tahminleri üzerinde ortalama olarak daha büyük bir etkiye sahip olduğunu gösterir. Her bir çubuk uzunluğu, o özelliğin ortalama mutlak SHAP ($\text{mean}(|\text{SHAP value}|)$) değerini temsil eder. Bu, o özelliğin tahminleri ne kadar etkilediğini gösterir.

Beeswarm Plot (Özet Grafiği); SHAP'ın en bilgilendirici ve en sık kullanılan genel yorumlama grafiğidir. Modelin genel davranışının özetini detaylı bir şekilde sunar. Dikey eksende özelliklerin çıktı tahminine etkisini sırasıyla gösterir. Önem sırası, o özelliğin ortalama mutlak SHAP değerine göre belirlenir. Yatay eksen, SHAP değerini gösterir; 0 noktası, modelin ortalama tahminini, pozitif SHAP değeri (sağ taraf): girdi değerinin, o veri noktası için tahmini artırdığını ve negatif SHAP değeri (sol taraf): girdi değerinin, o veri noktası için tahmini azalttığını gösterir. Saçılım kalınlığı o noktada yer alan veri miktarı hakkında bilgi verir. Kırmızı renk girdideki yüksek değerleri, mavi renk girdideki düşük değerleri temsil eder. Yani: girdi değerinde kırmızı renk yoğunluğu yatay eksenin pozitif kısmında yer alıyorsa çıktıyı arttırıcı yönde, negatif tarafta yer alıyorsa azaltıcı yönde etkilemekte; girdi değerinde mavi renk yoğunluğu yatay eksenin pozitif kısmında yer alıyorsa çıktıyı arttırıcı yönde, negatif tarafta yer alıyorsa azaltıcı yönde etkilemektedir. Mor renk ise kırmızı ve mavi renklerin ortasında yer alır ve girdi değerine ait orta düzey değerlerin modele yansımalarını gösterir.

Waterfall Plot (Şelale Grafiği); Modeldeki tek bir tahminin nasıl oluştuğunu gösterir. Tek bir noktadaki çıktı değerine karşılık gelen girdi değerlerinin etkisini ortaya koyar. Grafik en altta, tüm veri setinin ortalama tahmini olan $E[f(X)]$ ile başlar. En üstteki $f(x)$ değeri, tüm katkılar eklendikten sonra ulaşılan nihai tahmindir. Her bir satır, o tahmine özel olarak bir girdi değerinin katkısını gösterir. Çubuğun uzunluğu, o girdi değerinin tekil tahmin üzerindeki etkisinin büyüklüğünü (SHAP değerini) gösterir. Çubuğun rengi kırmızı ise arttırıcı mavi ise azaltıcı yönde etkilediğini gösterir. Grafikte yer alan sayısal ifadeler; +0.01: Tahmine ölçülebilir pozitif bir katkıyı, +0: Tahmine pozitif yönde, ancak pratikte önemsiz derecede küçük bir katkıyı, -0.01: Tahmine

1. GİRİŞ

ölçülebilir negatif bir katkıyı, -0: Tahmine negatif yönde, ancak pratikte önemsiz derecede küçük bir katkıyı temsil eder.

Dependence Plot (Bağımlılık Grafiği); Bir girdi değerinin doğrusal mı, yoksa daha karmaşık bir etkiye mi sahip olduğunu göstermenin yanı sıra etkileşimde olduğu bir diğer girdi değeriyle beraber çıktı üzerindeki etkisini de ortaya koyar. Yatay eksen, incelenen girdi değerinin orijinal değerini; sol dikey eksen, o girdi değerinin SHAP değerini (tahmine olan katkısı) ve sağ dikey eksen, etkileşimde olunan diğer girdi değerinin katkısını kırmızı mavi mor renk dağılımında gösterir. Bu renk göstergeleri özet grafiğindeki gibi yorumlanır. Etkileşimde olunan ikinci girdi değeri eğer ilk girdi değeri üzerinde önemli bir farklılığa neden olursa kırmızı ve mavi renk göstergeleri yoğun olarak dikkat çeker.

1.3.8. Toplamsal güç yasası regresyon modeli

Bu model, bir bağımlı değişkenin (y), birden fazla bağımsız değişkenin (x_i) kuvvetlerinin (üslerinin) ağırlıklı toplamı şeklinde ifade edildiği ampirik bir regresyon yaklaşımıdır. Genel formu $y = a + \sum b_i x_i^{p_i}$ şeklindedir; burada y bağımlı değişken, x bağımsız değişken, a sabit terim, b her bir terimin ağırlık katsayısı ve p her bir bağımsız değişkenin etki derecesini gösteren üslerdir. Bu model, farklı girdi faktörlerinin çıktı üzerindeki doğrusal olmayan etkilerini esnek bir şekilde birleştirmek için kullanılır. Denklemdaki a , b_i ve p_i parametreleri, genellikle deneysel veya simülasyon verilerine uygun olarak belirlenir. Makine öğrenmesinde Python'daki `scipy.optimize.curve_fit` gibi doğrusal olmayan en küçük kareler yöntemleri kullanılarak tahmin edilebilir.

1.3.9. Makine öğrenmesi regresyon kriterleri

Makine öğrenmesi modelinin performansını ölçmek için ortalama mutlak hata (MAE), karekök ortalama kare hata (RMSE), belirleme katsayısı (R^2) ve 10 katlı çapraz doğrulama (10-cv) değerlerine bakılmıştır.

Ortalama mutlak hata (MAE)

Ortalama mutlak hata (MAE), model kurulduktan sonra tahmin edilen değer ve gerçek değer arasındaki hataları; ortalama olarak gerçek değerden ne kadar saptığını gösterir. Birimi tahmin edilen değer birimiyle aynıdır. Bu yöntemde; ilk olarak her bir veri noktası için gerçek ve tahmin değeri arasındaki fark bulunur. Bulunan hataların negatif veya pozitif olmasına bakılmaksızın mutlak değeri alınır. Son olarak, tüm bu mutlak hataların ortalaması alınır. (Denklem 1.4). Büyük veya küçük fark etmeksizin tüm hatalara eşit ağırlık verdiği için aykırı değerlerden etkilenmeden sonucu bulur. Performans değerlendirmesinde tek başına kullanıldığında yeterli olmayabilir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (1.4)$$

Burada; y : gerçek değer, $\bar{y}_i$: tahmin edilen değer, n : gözlem sayısı.

Karekök ortalama kare hata (RMSE)

Karekök ortalama kare hata (RMSE), model kurulduktan sonra tahmin edilen değer ve gerçek değer arasındaki hataları; ne kadar saçılım yaparak gösterdiğini ifade eder. Değeri, tahmin ettiğiniz birimle aynıdır. Bu yöntemde; ilk olarak her bir veri noktası için gerçek ve tahmin değeri arasındaki fark bulunur. Bulunan her bir hatanın karesi alındıktan sonra tüm bu kareli hataların ortalaması alınır. Son olarak, bu ortalamanın karekökü alınır (Denklem 1.5). Hataların karesini aldığı için, büyük hatalara çok daha fazla ağırlık vererek sonuca ulaşır. Bu nedenle performans değerlendirmesinde tek başına kullanılmamalıdır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (1.5)$$

Burada; y : gerçek değer, $\bar{y}_i$: tahmin edilen değer, n : gözlem sayısı.

Belirleme katsayısı (R^2)

Belirleme katsayısı (R^2) model kurulduktan sonra tahmin edilen değerin gerçek değeri ne kadar iyi yansıttığını gösteren 0-1 arasında bir sayıdır (Denklem 1.6). Bu yöntem modelin ne kadar iyi olduğunu anlamak için yorumlanabilir kolay bir yöntemdir. Farklı modellerin aynı veri setindeki başarısını kıyaslamayı kolaylaştırır. Eğitim veri seti yüksek test veri seti düşük olduğu durumlarda aşırı uyumu gözlemlemeye olanak sağlar. Bunların yanı sıra modelin güvenilirliğini açıklamak için tek başına dikkate alınmamalıdır. Belirleme katsayısında modele yeni bir girdi parametresi eklendiğinde matematiksel olarak azalmaz ve eklenen değişkenin hedef değişkenle bir ilişkisi olmasa dahi, R^2 değeri artış gösterme eğilimindedir. Bu durumda, aslında modelin genelleme yeteneğini zayıflatan ve aşırı uyuma yol açan önemsiz değişkenlerin modele dahil edilmesine sebep olabilir. Eğitim veri setinde yüksek bir ilişki kurulabilirken test veri setinde daha düşük bir sonuç ortaya çıkabilir. Bu nedenle performans değerlendirmesinde hata metrikleriyle beraber dikkate alınmalı veya 10 katlı çapraz doğrulama ile performansı dikkate alınmalıdır.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1.6)$$


Burada; y : gerçek değer, $\bar{y}_i$: tahmin edilen değer, $\bar{y}$: gözlemlerin ortalaması, n : gözlem sayısı.

10 katlı çapraz doğrulama (10-cv)

Bu yöntemde veri, rastgele biçimde 10 eşit kata ayrılır; her yinelemede 9 kat öğrenme, 1 kat test için kullanılır. Öğrenme verisi de kendi içinde eğitim ve doğrulama verisi olarak ayrılır. Bu işlem 10 tur devam ettirilerek veri setindeki tüm örnekler öğrenme ve test veri seti içinde yer alır. İşlem sonunda her bir kat için belirlenen belirleme katsayılarının (R^2) ortlaması alınarak 10-cv'nin nihai R^2 'si belirlenir ve hatalar ortalama

1. GİRİŞ

sapma olarak raporlanır. 10 katlı çapraz doğrulama, tek bir bölme işlemine kıyasla varyansı düşürür ve tüm gözlemler hem eğitimde hem de doğrulamada rol aldığından mevcut veriden azami yararlanmayı sağlar. Yöntemin uygulanmasını anlatan şematik gösterim aşağıda verilmiştir (Şekil 1.7.).



Şekil 1.7. 10 katlı çapraz doğrulama şematik gösterimi (Ngo et al. 2022)

2. KAYNAK ÖZETLERİ

Al-Mudhafar et al. (2022) yaptıkları çalışmada, heterojen karbonat rezervuarlarında litofasiyes sınıflandırması için boosting makine öğrenimi algoritmaları; AdaBoost, GBM, XGBoost, lojistik arttırma regresyon (Logistic Boosting Regression-LogitBoost) ve K-en yakın komşular (kNN) algoritmasını kullanmışlardır. XGBoost'un, tahminler açısından diğer algoritmalarından daha doğru litofasiyes sınıflandırması sağladığını belirtmişlerdir.

Bentéjac et al. (2021) yaptıkları çalışmada, boosting makine öğrenimi algoritması tekniklerini karşılaştırmalı olarak incelemişlerdir. Bu kapsamda 28 farklı veri kümesi ile RF, GBM, XGBoost, LightGBM ve CatBoost algoritmalarından oluşan modelleri incelemişlerdir. Çalışma sonunda, CatBoost'un en doğru sonuçları verdiğini ancak diğerlerinden biraz daha yavaş olduğunu, XGBoost'un, hem doğruluk hem de hız açısından ikinci sırada olduğunu, LightGBM'un en hızlı algoritma olduğunu ancak doğruluğunun diğerlerine kıyasla iyi olmadığını belirtmişlerdir.

Bakouregui et al. (2021) yaptıkları çalışmada, fiber takviyeli polimer çubuklarla donatılmış betonarme kolonların yük taşıma kapasitesini tahmin etmek için makine öğrenmesini kullanmışlardır. Literatürden aldıkları 283 deneysel numuneyi kullanarak XGBoost algoritmasının başarısını ölçmek için; literatürde yer alan tasarım kodları ve formülleri ile kıyaslamışlardır. Önerilen modelin iyi bir tahmin ortaya koyduğunu vurgulamışlardır. Model çıktılarını yorumlamak için SHAP (Shapley Additive Explanations) kullanmışlardır. Araştırmacılar çalışmada kullanılan kodları GitHub'da abdoulayesanni hesabında paylaşmışlardır.

Farzinpour et al. (2023) yaptıkları çalışmada, bodur perde duvarların kesme dayanımını tespit etmek için literatürden alınan 558 örnek üzerinde makine öğrenmesi yöntemini kullanmışlardır. Makine öğrenmesi modeli olarak topluluk öğrenmesi algoritmaları XGBoost, CatBoost ve LightGBM ve geleneksel algoritmalar RF, Yapay Sinir Ağı (Artificial Neural Network-ANN), DT, Destek Vektör Makinesi (Support Vector Machine-SVM) seçilmiştir. Algoritmaların hiperparametre optimizasyonu ile performansını incelemek için Genetik Algoritma (Genetic Algorithm-GA)

optimizasyonunu topluluk öğrenme yaklaşımlarında uygulamış ve başarılı sonuçlar verdiğini ortaya koymuşlardır. Her üç topluluk öğrenme modeli için de en az %98,6'lık bir belirleme katsayısıyla yüksek tahmin doğruluğu elde edilmiştir. Modellerde ayrıca girdi değerleri 4 ve 9 bileşen olacak şekilde yapılan incelemede 4 bileşenli incelemede CatBoost ve LightGBM, 9 bileşenli incelemede XGBoost'un daha başarılı olduğu belirlenmiştir.

Khan et al. (2025) yaptıkları çalışmada, AutoML (otomatik makine öğrenmesi) çerçevelerinin hiperparametre optimizasyonundaki başarısını ve farklı XAI (açıklanabilir yapay zekâ) tekniklerinin yorumlanabilirlik etkisini karşılaştırmalı olarak incelemiştir. Bu kapsamda, UHPC (ultra yüksek performanslı beton) kirişler (100 adet) ve U-kesitli kirişlerde (700 adet) nihai eğilme momenti kestirimi için; makine öğrenmesi modeli olarak RF, optimizasyon yöntemi olarak RS, GS, Hyperopt, TPOT, Optuna, GP Minimize, Orman Minimize, GBRT Minimize ve Sahte Minimize olmak üzere dokuz farklı AutoML yöntemi; yorumlama için SHAP ile LIME, PDP ve sklearn permütasyon önem sıralamaları karşılaştırmalı olarak incelemiştir. Optuna tabanlı AutoML en yüksek tahmin doğruluğunu ve en düşük hesaplama eğitimi süresini elde ederek benzerlerinden sürekli olarak daha iyi performans gösterdiğini ve SHAP'ın en güvenilir ve ayrıntılı açıklanabilirlik çıktısını sağladığını tespit etmişlerdir.

Lai et al. (2023) yaptıkları çalışmada, devre analizi için empedans değerlerinin tahmin edilmesinde hiperparametre optimizasyon yöntemi Optuna ile ağaç tabanlı makine öğrenme modellerinin kullanımını incelemiştir. Bu kapsamda DT, RF, XGBoost, CatBoost ve LightGBM ağaç modelleri kullanmışlardır. Yapılan inceleme sonucunda Optuna'lı beş ağaç tabanlı makine öğrenimi modelinin tatmin edici tahmin doğruluğu üretebildiğini belirtmişlerdir. En iyi sonucu ise LightGBM-Optuna modelinin verdiğini belirtmişlerdir.

Le Nguyen et al. (2024) yaptıkları çalışmada, sonlu elemanlar yöntemini kullanarak analizini gerçekleştirdikleri 639 bodur perde duvarda girdi parametrelerinin kesme dayanımına etkisini makine öğrenmesi algoritmaları ile incelemiştir. Makine öğrenmesi algoritması olarak; doğrusal regresyon (Linear Regression-LR), kNN, DT, rastgele orman RF, AdaBoost, XGBoost, CatBoost ve gradyanla artırılmış regresyon

ağaçları (Gradient Augmented Regression Trees-GBRT) kullanılmıştır. XGBoost, CatBoost, GBRT ve RF algoritmalarının birbirine yakın bir şekilde diğerlerine oranla daha iyi sonuç verdiğini, XGBoost'un ise en iyi sonucu verdiğini tespit etmişlerdir. Çalışmada ayrıca modelde yer alan girdi sayısı değiştirilerek dört farklı durum için yeniden inceleme yapılmış, girdi sayısının artmasının model performansının artırması beklenirken en iyi performans orta dereceli girdi sayısında ortaya çıkmıştır. Modelde kullanılan girdi değerlerinin etkisini ölçmek için SHAP kullanılmıştır.

Liu et al. (2022) yaptıkları çalışmada, çevresel etkilere maruz kalan Elyaf Takviyeli Polimer (FRP) kompozitlerinin uzun vadeli bozulmalarını tahmin etmek için XGBoost modelini kullanmışlardır. Karar ağaçlı modellerin FRP çalışmalarında daha etkili tahminler yaptığını belirterek XGBoost'un öne çıkan özellikleri belirtilmiştir. 746 deneysel sonuçtan oluşan veri tabanı üzerinde yapılan çalışma sonucunda XGBoost modelinin tahmin doğruluğunun oldukça yüksek olduğu vurgulanmıştır.

Ma et al. (2023a) yaptıkları çalışmada, literatürden alınan sargılı ve sargısız 774 ince betonarme kirişin kesme dayanımını yorumlanabilir makine öğrenmesi ile incelemişlerdir. Makine öğrenmesi modeli için kNN, DT, RF, AdaBoost, GBM ve XGBoost algoritmaları, girdi değerlerinin yorumlanması için de SHAP kullanılmıştır. XGBoost algoritması ile oluşturulan modelin en iyi tahmini yaptığı ortaya konmuştur.

Ma et al. (2023b) yaptıkları çalışmada, harçlı ekleme manşon bağlantısının (GSSC) çekme yükü kapasitesini ve arıza modunu tahmin etmek için 418 mevcut GSSC deneysel veri setinde makine öğrenmesi algoritmalarını kullanmışlardır. MLR, ANN, SVM, kNN, DT, RF, GBM, aşırı rastgele ağaçlar (Extremely Randomized Trees-ET), LightGBM, CatBoost, XGBoost makine öğrenmesi algoritmaları ve hiperparametre optimizasyonu için Optuna çerçevesinde; amaç fonksiyonunu minimize etmek için Ağaç Parzen Tahmincisi (TPE) ve model yorumlaması için SHAP ve (Partial Dependence Plot-PDP) kullanmışlardır. Topluluk öğrenme modellerinin (LightGBM, CatBoost, XGBoost) diğer modellere göre daha iyi sonuç verdiğini ve kendi içlerinde CatBoost'un en doğru sonucu verdiğini belirtmişlerdir.

Mangalathu et al. (2020) yaptıkları çalışmada, dikdörtgen veya dikdörtgen olmayan betonarme perde duvarların göçme modlarını (eğilme, kesme, eğilme-kesme ve kayma kesme) tahmin etmek için naive bayes (Naïve Bayes-NB), kNN, DT, RF, AdaBoost, XGBoost, LightGBM ve CatBoost algoritmalarını kullanmışlardır. Çeşitli geometrik konfigürasyonlara sahip perde duvarlar için 393 deneysel sonuçtan oluşan veri tabanı ile yapılan çalışma sonucunda %86 doğruluk oranı ile RF en iyi tahmini yapmıştır. Yazarlar yaptıkları çalışmada oluşan sınıflandırma modelini açık kaynaklı olarak sunmuşlardır. GitHub'da yazar sujithmangalathu hesabında kodlar paylaşılmaktadır.

Mangalathu et al. (2021) yaptıkları çalışmada, enine donatısız düz levhaların zımbalama kesme dayanımını makine öğrenimi yaklaşımlarıyla incelemişlerdir. Veri seti olarak literatürden 380 deneysel sonuç kullanılmıştır. Doğrusal regresyona (Linear Regression-RA1), ridge regresyon (Ridge Regression-RA5), destek vektör regresyonu (Support Vector Regression-SVR), DT, kNN, RF, AdaBoost, XGBoost algoritmalarını kullanmışlardır. XGBoost algoritması en iyi tahmini yapmıştır. Çalışmada ayrıca XGBoost modelinde zımbalama kesme dayanımını etkileyen faktörlerin önemini ve katkısını açıklamak için SHAP yöntemi kullanılmıştır. GitHub'da yazar sujithmangalathu hesabında kodlar paylaşılmaktadır.

Mangalathu et al. (2022) yaptıkları çalışmada, yorumlanabilir makine öğrenimi tekniklerini incelemek amacıyla Mangalathu et al. (2020) çalışmasında kullanılan perde duvarların veri setini kullanarak bileşen düzeyinde kesme dayanımını tahmin etmiş ve Kaliforniya'daki çarpık köprülerin bölgesel hasar değerlendirmelerinin bölgesel düzeyde uygulamasını gerçekleştirmişlerdir. Çeşitli ML algoritmaları arasında her iki durumdada, XGboost modeli diğer makine öğrenimi modellerinden daha iyi performans gösterdiğini belirtmişlerdir. Perde duvarlar ve köprülerin tahminlerini değerlendirmek için yorumlanabilir yaklaşımlar kullanmışlardır. ML yorumlanabilir model tekniği olarak kısmi bağımlılık grafiği (Partial Dependence Plot-PDP), birikmiş yerel etkiler (Accumulated Local Effects-ALE) ve Shapeley toplanmış açıklamalar (Shapeley Additive Explanations-SHAP) kullanılmıştır. Bölgesel risk değerlendirmesine yönelik bir makine öğrenimi modelinin davranışını tam olarak anlamak için bu üç modelin de beraber kullanılması gerektiğini ortaya koymuşlardır. GitHub'da yazarın kullanıcı adı sujithmangalathu olan hesabında kodlar paylaşılmaktadır.

Naderpour et al. (2021) yaptıkları çalışmada, betonarme kolonların göçme modlarını incelemek maksadıyla literatürden alınan deneysel verileri kullanarak makine öğrenmesi modelleri oluşturmuşlardır. 163 dairesel kolon ve 253 dikdörtgen kolondan oluşan veri setinde DT ve ANN algoritmalarını uygulamışlardır. Eğilme, kesme ve eğilme-kesme modlarının tahmininde bu iki algoritmayı kıyaslamışlardır. Her üç sınıfın tahmininde de DT modelinin daha doğru sonuç verdiğini tespit etmişlerdir.

Sertkaya (2018) yaptığı çalışmada, betonarme perde elemanlarının kesit uçlarındaki donatı ve beton birim şekil değiştirmeleri ile kesit dönmesi, eğrilik ve ötelenme davranışlarını incelemek amacıyla sonlu eleman yazılım programı (ANSYS) kullanılarak çeşitli parametrelere bağlı 2600 vaka analizi gerçekleştirilmiştir. ASCE/SEI 41, Eurocode 8, DBYBHY (2007), taslak olarak yayınlanan Türkiye Bina Deprem Yönetmeliği (TBDY-2016) ve TBDY (2018) yönetmeliklerinde betonarme perdeler için önerilen hasar sınırları değerlendirmiş ve bu sınır durumları, sonlu eleman analizlerinden elde edilen sınır değerler ile karşılaştırmıştır. Bu karşılaştırmaların sonucunda, betonarme perdeler için daha ayrıntılı modelleme parametreleri ve kabul kriterleri önermiştir.

Shekhar et al. (2021) yaptıkları çalışmada, Optuna, Hyper-opt, Optunity ve hiperparametre optimizasyonu için önerilen sıralı model tabanlı algoritma yapılandırması (SMAC) olmak üzere Bayesian optimizasyonuna dayanan dört hiperparametre optimizasyon tekniğini karşılaştırmış ve birleşik algoritma seçimi ve hiperparametre optimizasyon problemlerinin Optuna kullanılarak daha iyi çözüldüğü sonucuna varmışlardır.

Shen and Lin (2018) yaptıkları çalışmada, Boyutsal Analiz'i modern istatistiksel modelleme ile entegre eden iki yöntemi; tekli kuvvet yasası modeli ve daha genel olan toplamsal güç yasası modelini incelemişlerdir. Yöntemleri göstermek için bilinen fiziksel formüllere dayalı simüle edilmiş Okyanus Dalga Hızı verisi (100 nokta toplamsal güç yasası için) ve ek materyalde parçacık fiziği verisi (prim7 tekli kuvvet yasası için) kullanmışlardır. Okyanus Dalga Hızı örneği üzerinde toplamsal güç yasası modelinin karmaşık fiziksel davranışı başarıyla yakaladığını, esnek ve verimli olduğunu belirterek bu modeli önermişlerdir.

Tian et al. (2025) yaptıkları çalışmada, betonarme perde duvarların kesme dayanımını tespit etmek için literatürden alınan 583 örnek üzerinde makine öğrenmesi yöntemini uygulamışlardır. Modelleri oluştururken tekil, topluluk ve derin makine öğrenimi modellerine dayalı yöntemleri uygulamışlardır. Oluşturulan makine öğrenmesi modelleri geleneksel analitik yöntemlerle kıyaslanmıştır. Kıyas sonunda tekil öğrenme modellerinden DT, topluluk öğrenme modellerinde GBM ve derin öğrenme modellerin derin sinir ağları (DNN) diğer modellerdenden daha iyi performans gösterdiğini belirtmişlerdir. Tüm modeller arasında DNN'nin en iyi tahmin gücüne sahip olduğu tespit edilmiştir. Geleneksel analitik yöntemlerle kıyaslandığında makine öğrenmesi modellerinin daha iyi bir performans gösterdiğini belirtmişlerdir. Çalışmada son olarak, ML yöntemlerinin tahmin doğruluğunu ve güvenilirliğini artırmak amacıyla, ayrı ayrı eğitilen modeller, istifleme yöntemi kullanılarak bir istifleme modeline entegre edilmiş ve istifleme modelinin tahmin performansı değerlendirilmiştir. İstifleme yönteminin tüm modellerden daha iyi performans gösterdiğini tespit etmişlerdir.

Thai (2022) yaptığı çalışmada, yapı mühendisliğinde makine öğrenmesi üzerine detaylı bir literatür taraması gerçekleştirmiştir. İncelemesini makine öğreniminin çok çeşitli yapısal mühendislik uygulamaları: yapısal analiz ve tasarım, yapısal sağlık izleme ve hasar tespiti, yapıların yangına dayanıklılığı, yapısal elemanların çeşitli eylemler altındaki direnci ve betonun mekanik özellikleri ve karışım tasarımı başlıkları altında toplamıştır. Her bölümde kullanılan algoritmaları ve bu algoritmaların kullanım oranlarını belirtmiştir. Yazar son beş yılda boosting algoritmaları, sinir ağları ve destek vektör makinelerinin kullanımında büyük bir artış olduğunu vurgulamıştır. Regresyon problemlerinde XGBoost'un çok etkili olduğunu ancak sınıflandırma için böyle bir ayrımın yapamayacağını belirtmiştir.

Yahiaoui et al. (2023) yaptıkları çalışmada, Asteris tarafından 2016 yılında önerilen FP4026 Araştırma Veri Tabanında yer alan 4026 dolgu betonarme çerçevede binaların temel periyodunu tahmin etmede en iyi performansı elde etmek için makine öğrenme modellerinde hiperparametre optimizasyonunun önemini incelemişlerdir. Bu amaçla: GBM, LightGBM ve Catboost makine öğrenmesi algoritmaları ve optimizasyon için Optuna kullanılmıştır. Optuna ile belirlenen hiperparametre modelleri, daha yüksek belirleme katsayısı ve daha düşük hata değerleriyle en iyi sonuçları vermiştir. Ayrıca,

optimize edilmiş parametreleriyle belirlenen lightGBM modeli diğer iki yöntemden daha iyi performans gösterdiğini belirtmişlerdir.

Yang and Prayogo (2025) yaptıkları çalışmada, betonarme perde duvarların göçme modlarını (eğilme, kesme, eğilme-kesme ve kayma kesme) tahmin etmek için makine öğrenmesi yöntemini uygulamışlardır. Genellenebilir bir yöntem ortaya koymak için Fizik Bilinçli Koşullu Varyasyonel Otomatik Kodlayıcı'yı (PA-CVAE) makine öğrenmesi modellerine entegre etmişlerdir. Makine öğrenmesi modeli olarak NB, DT, RF, Çok Katmanlı Algılayıcı (Multi-layer Perceptron-MLP), Ekstra Ağaçlar (Extra Trees-ET), XGBoost, LightGBM ve CatBoost algoritmalarını kullanmışlardır. Çeşitli geometrik konfigürasyonlara sahip perde duvarlar için gerçek ve sentetik 170 örnekten oluşan veri tabanı ile yapılan çalışma sonucunda CatBoost'un en iyi tahmini yaptığını belirtmişlerdir. Modelin yorumlanması için SHAP kullanılmıştır.

Zhang et al. (2022) yaptıkları çalışmada, betonarme perde duvarların göçme modlarını (eğilme, kesme, eğilme-kesme ve kayma kesme), dayanım ve deformasyon kapasitesini tahmin etmek için literatürden alınan 429 deneysel veriyi kullanarak ML algoritmaları üzerinde incelemelerde bulunmuşlardır. ML algoritması olarak sınıflandırma için; NB, kNN, DT, ANN, RF, GBM, XGBoost, LightGBM ve CatBoost, regresyon için; lineer regresyon (LR), SVR, DT, GBM, RF, kNN, XGBoost, ANN ve gauss süreç regresyonu (GPR) algoritmalarını kullanmışlardır. Çöçme modu tahmininde yani sınıflandırma algoritmalarında en iyi sonucu XGBoost ve GBM %97 doğrulukla vermiştir. Kesme dayanımında topluluk algoritmaları sırasıyla XGBoost, RF, GBM daha iyi sonuç vermiştir. Deformasyon kapasitesinde topluluk algoritmaları sırasıyla RF, XGBoost, GBM daha iyi sonuç vermiştir.


Zhu and Randolph (2011) yaptıkları çalışmada; denizaltı heyelanlarının boru hatları üzerindeki etkisini değerlendirirken karşılaşılan, zeminin yüksek kayma hızı bağımlılığı için model önermişlerdir. Bu amaçla: kayma hızına bağlı mukavemet modelleri ve zemini Bingham veya Herschel-Bulkley gibi viskoplastik bir akışkan olarak modelleyen yaklaşımları karşılaştırmışlardır. Bu iki farklı yaklaşımı birleştirerek, akışkanlar mekaniğindeki Herschel-Bulkley modelinin normalize edilmiş bir formu olan ve zemin mekaniği temelli toplamsal güç yasası modelini önermişlerdir.

3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Perdelerin tasarımı ve detaylandırma

Bu çalışmada incelenen dikdörtgen kesitli perdeler, TBDY (2018) yürürlüğe girmeden önce modellenmiş olup tasarımda DBYBHY (2007) hükümleri esas alınmıştır. Yönetmelikte tanımlandığı gibi kritik perde yüksekliği boyunca uç bölgelerin her birinin plandaki uzunluğu, perdenin toplam uzunluğunun %20'si olarak kabul edilmiştir ($l_u = 0.2l_w$). Tüm perdelerde perde duvar kalınlığı 250 mm alınmıştır (Şekil 3.1.).



Şekil 3.1. Çalışmada kullanılan perde detayı (Sertkaya 2018)

Analizlerde perde gövdesine ait düşey (ρ_{sv}) ve yatay ($\rho_{sh} = \rho_t$) donatı oranları başlangıçta, perde gövdesinin brüt enkesit alanının 0,0025'i olacak şekilde seçilmiştir. Ancak pekleşmeli moment kapasitesinin etkisiyle oluşan kesme kuvveti ($V_e = \lambda V_d$), Denklem (1.1) ile hesaplanan kesme dayanımını aştığı durumlarda, gerekli gövde donatısı aynı bağıntı kullanılarak yeniden belirlenmiş ve diğer parametreler sabit tutularak analizler bu yeni donatı oranı ile tekrarlanmıştır. Düşey ve yatay gövde donatısı miktarları eşit kabul edilmiştir.

$$V_r = A_{ch} (0.65 f_{ctd} + \rho_{sh} f_{ywd}) \quad (1.1)$$

Kolon gibi tasarlanan perdelerin uç bölgeleri için sargı donatısı, kolon gereksinimlerinin 2/3'ü olarak alınır. DBYBHY (2007) yönetmeliği, betonarme perde uç bölgelerindeki sargı donatısının hesaplanması için $A_{sh} = 0.05 s b_c f_{ck} / f_{ywk}$ bağıntısını

önerir. Aynı yönetmelik, düşey doğrultuda sargı aralığının 50 mm'den az olmamasını; 100 mm'den ve perde kalınlığının yarısından fazla olmaması gerektiğini belirtir. Bu çalışmada, hem bu yönetmelik şartlarını sağlayan ($\phi 8/50$ mm, $\phi 8/100$ mm) hem de sağlamayan ($\phi 8/150$ mm ve $\phi 8/250$ mm) sargı donatısı konfigürasyonları incelenmiştir. Yönetmelik dışı olan bu aralıkların analize dahil edilmesinin nedeni, özellikle mevcut eski yapı stokundaki yetersiz sargı detaylarının davranış üzerindeki etkisini de irdeleyebilmektir.

3.1.2. Parametrik çalışma

Bu çalışmada esas alınan girdi parametreleri ve bu parametrelerin değer aralıkları aşağıda sunulmuştur:

- **Perde boyu (l_w):** Model oluşumundaki ana parametredir ve 2 m, 3 m, 5 m, 8 m olarak belirlenmiştir.
- **Perde duvar yüksekliği (H_w):** Perde duvar yükseklikleri; perde boyu 2 m için 9 ve 15 m; perde boyu 3 m için 9, 15 ve 27 m; perde boyu 5 m için 9, 15, 21 ve 37,5 ve perde boyu 8 m için 18, 27 ve 45 m olarak seçilmiştir.
- **Etkin kesme boyu (L_v):** Etkin kesme boyu ($L_v = M_y/V_d$), perde taban kesiti moment kapasitesinin (M_y) tasarım kesme kuvvetine (V_d) oranıdır. Bu çalışmada etkin kesme boyu; perde boyu 2 m için 6 ve 9 m; perde boyu 3 m için 6, 10 ve 18 m; perde boyu 5 m için 6, 9, 15 ve 25 m; perde boyu 8 m için 12, 18 ve 30 m olarak belirlenmiştir. Deprem yüklerinin perde yüksekliği boyunca üçgen yayılı yük şeklinde dağıldığı varsayıldığında; toplam yatay yükün, perde yüksekliğinin yaklaşık $L_v = 2H_w/3$ seviyesinde tekil bir yük olarak etkidiği kabul edilebilir. Üçgen yayılı yükleme ve bu yükseklikte uygulanan tekil yük, perde tabanında yaklaşık aynı momenti oluşturmaktadır. Bu nedenle çalışmada yük H_w boyunca üçgen yayılı olarak tanımlanmak yerine, $L_v = 2H_w/3$ seviyesinde tekil yatay yük olarak uygulanmıştır.
- **Eksenel yük oranı (P/P_o):** Uygulamada, kısa ve orta yükseklikteki binalarda konsol perdeler için eksenel yük oranının genellikle $0 \leq P/P_o \leq 0,15$ aralığında olduğu kabul edilmektedir ve bu durumda her bir perde elemanına yaklaşık 1~1,25% düzeyinde

eksenel yük oranı düştüğü varsayılmaktadır. Çalışmada eksenel yük oranı 0,05, 0,1 ve 0,2 değerleri için inceleme yapılmıştır.

- **Perde uç bölgesi boyuna donatı oranı (ρ_b):** Uç bölgede boyuna donatı oranı, dikdörtgen perde duvarların uç bölgesinde bulunan toplam boyuna donatı alanının (A_s), ilgili uç bölge alanına (A_{sw}) oranıdır. Çalışmada perde uç bölgeleri için boyuna donatı oranı 0,005, 0,01, 0,02 ve 0,04 olarak seçilmiştir.
- **Perde uç bölgesinde sargı aralığı (s):** 50 mm, 100 mm, 150 mm ve 250 mm olarak seçilmiştir.
- **Perde uç bölgesi enine donatı oranı (ρ_s):** Dört farklı sargı düzeyi esas alındığında, perde uç bölgesinde sargı oranı (ρ_s) için üç sınıflandırma yapılmıştır. $\rho_s \leq 0,003$, yetersiz sargıya sahip ve yönetmelikte öngörülen sargı koşullarını karşılamayan perde uç bölgelerini; $0,003 < \rho_s < 0,005$, sargı düzeyi yeterli olmakla birlikte yönetmelikte belirtilen minimum sınırları tam olarak sağlamayan uç bölgelerini ve $\rho_s \geq 0,005$, yönetmeliğe uygun biçimde sargılanmış perde uç bölgelerini temsil etmektedir.
- **Beton basınç dayanımı (f_c):** Eski ve yeni uygulamaları dikkate alacak şekilde 10 MPa, 20 MPa, 30 MPa, 50 MPa olarak belirlenmiştir.
- **Donatı akma dayanımı (f_y):** Eski ve yeni uygulamaları dikkate alacak şekilde 220 MPa, 420 MPa olarak belirlenmiştir.
- **Perde kalınlığı (t_w):** Tüm perdelerde 250 mm alınmıştır.

3.1.3.Sonlu eleman modeli ve malzeme özellikleri


Çalışmadaki perde elemanlarının analizi, ANSYS sonlu elemanlar yazılım programıyla gerçekleştirilmiştir. Modellemenin en kritik aşamasını oluşturan ANSYS programının kalibrasyonu ise, Kazaz et al. (2006), Kazaz (2010 ve 2011) çalışmalarından faydalanılarak sağlanmıştır.

Şekil 3.2.(b)'de görüldüğü üzere, perde modellerinin doğrusal olmayan analizleri, tepe noktasına etkiyen tekil statik yükler altında gerçekleştirilmiş ve bu yükleme biçimi nedeniyle en büyük kesit tesirleri perde tabanında oluşmuştur. Hesaplamalar sonucunda,

beton çatlaklarının perde orta yüksekliğine kadar ilerlediği, ancak donatıdaki belirgin akmanın ilk bir iki kat seviyesinde yoğunlaştığı gözlenmiştir. Bu nedenle, Şekil 3.2.(a)'da gösterildiği gibi perde elemanlarının analizinde, katı ve çubuk elemanların birlikte kullanıldığı hibrit sonlu eleman modelleri kullanılmıştır.


Hasarın yoğunlaştığı alt kat bölgelerinde daha ayrıntılı sonuçlar elde edebilmek için 8 düğüm noktalı katı elemanlar (SOLID65) kullanılmıştır. Yapılan sonlu eleman analizlerinde, perde davranışı; 2 ve 3 m boyundaki perdeler için ilk iki kat, 5 m boyundaki perdeler için ilk üç kat ve 8 m boyundaki perdelerde ise ilk dört kat boyunca SOLID65 elemanı ile modellenip ayrıntılı olarak incelenmiştir. Katı elemanlarla kurulan bu modellemenin en önemli avantajı, modelin istenen herhangi bir noktasında birim şekil değiştirme ve ötelenme değerlerinin elde edilebilmesi ve bu büyüklüklerden yararlanılarak dönme ve eğrilik değerlerinin hesaplanabilmesine olanak sağlamasıdır.

Donatı, betondan ayrı çubuk elemanla modellenmek yerine, karşılık geldiği katı eleman hacmi içinde yayılı donatı olarak idealize edilmiştir. Beton için çatlama dışındaki hasar türlerinin ihmal edilebildiği üst bölgeler ise, kesme-eğilme etkilerine dayalı kolon-kiriş formülasyonuna sahip çubuk elemanlar (BEAM188) ile modellenmiştir. Sadece ötelenme serbestlik derecelerine (u_x, u_y, u_z) sahip katı eleman düğümleri ile hem ötelenme hem de dönme serbestlik derecelerine ($u_x, u_y, u_z, \theta_x, \theta_y, \theta_z$) sahip kiriş elemanı düğümleri arasındaki uyumsuzluğu ortadan kaldırmak amacıyla, MPC184 uyum elemanının rijit kiriş benzeri davranışından yararlanılarak bu iki eleman tipi birbirine bağlanmıştır.



Şekil 3.2. Perdelerin (a) sonlu eleman modeli ve (b) detayları (Sertkaya 2018)


Bu çalışma kapsamında on iki perde modeli esas alınarak farklı parametrelerle 2548 model üretilmiştir. Perde modelleri Şekil 3.3.'te verilmektedir.



Şekil 3.3. Çalışmada kullanılan perdelerin sonlu eleman modelleri (Sertkaya 2018)

Şekil değiştirme sınırları

Betonarme perdelerin plastik dönmesi yer değiştirmeye dayalı olarak; aynı kotta yer alan çekme ve basınç bölgelerindeki yatay ötelenmelerin farkının duvar boyuna (l_w) bölünmesiyle hesaplandı. Çekme ve basınç bölgesindeki ötelenme oranları, plastikleşmenin yoğun olduğu plastik mafsal bölgesinin üst kotundaki (L_{pz}) değerlerdir ve l_w eğilme doğrultusundaki duvar boyudur. Beton birim kısalması ve çelik birim uzaması; basınç ve çekme bölgelerindeki üç elemanın (yaklaşık 1 metrelik kısım) ortalama değeri olarak alındı.



Şekil 3.4. Betonarme perde detayı ve şekil değiştirme sınırlarının gösterimi

3.1.4. Makine öğrenmesi modeli

Makine öğrenmesi modelleri, algoritmalar ve uygulamaları üzerine incelemeler yapılırken özellikle yapı mühendisliğindeki kullanımları irdelendi. Thai (2022) tarafından detaylı yapılan çalışmada, ML algoritmalarının yapı mühendisliğindeki kullanım yüzdeleri %56 NN (Yapay Sinir Ağları), %11 BA (Boosting Algoritması), %10 SVM (Destek Vektör Makineleri), %8 RA (Regresyon Analizi), %6 RF (Rastgele Orman), %5 DT (Karar Ağacı) ve %4 KNN (K En Yakın Komşu) ve NB (Naive Bayes) olarak

belirtmiştir. Yapılan incelemede özellikle 2020 yılından itibaren BA algoritmalarında önemli bir artış olduğu ortaya konmuştur. Aynı çalışmada boosting algoritmalarında en çok kullanılan algoritmanın ise %40 ile XGBoost algoritması olduğu belirtmiştir.

Çalışmalarda kullanılan makine öğrenmesi algoritmaları veri setine göre farklılık göstermekle beraber ağaç tabanlı algoritmalar daha doğru sonuçlar ortaya koymaktadır (Mangalathu et al. 2020; Bentéjac et al. 2021; Mangalathu et al. 2021; Naderpour et al. 2021; Wakjira et al. 2021; Al-Mudhafar et al. 2022; Liu et al. 2022; Mangalathu et al. 2022; Zhang et al. 2022; Farzinpour et al. 2023; Lai et al. 2023; Ma et al. 2023a; Ma et al. 2023b; Yahiaoui et al.2023; Le Nguyen et al. 2024; Yang and Prayogo 2025).

Ağaç tabanlı algoritmalar kendi içinde incelendiğinde ise XGBoost ile kurulan modellerin genellikle en doğru sonucu verdiği tespit edilmiştir (Bakouregui et al. 2021; Mangalathu et al. 2021; Naser 2021; Nguyen et al. 2021; Wakjira et al. 2021; Al-Mudhafar et al. 2022; Liu et al. 2022; Mangalathu et al. 2022; Thai 2022; Zhang et al. 2022; Farzinpour et al. 2023; Ma et al. 2023a; Le Nguyen et al. 2024).

XGBoost'un yapı mühendisliğindeki kullanımları incelendiğinde ise oldukça iyi sonuç verdiği ve birçok ML uygulamasıyla kıyaslandığında ise daha doğru sonuç verdiği görülmektedir. Betonarme levhaların zımbalama kesme dayanımı (Mangalathu et al. 2021), betonarme perdelerin kesme dayanımı (Mangalathu et al. 2022; Zhang et al. 2022; Farzinpour et al. 2023; Le Nguyen et al. 2024), betonarme perdelerin göçme modu (Zhang et al. 2022), FRC ile güçlendirilmiş betonarme kolonların eksenel yük dayanımı (Bakouregui et al. 2021), sargılı ve sargısız betonarme perde kirişin kesme dayanımı (Ma et al. 2023a), FRP ile güçlendirilmiş kirişlerin maksimum moment kapasitesi (Naser 2021), yüksek dayanımlı betonun basınç ve çekme dayanımları (Nguyen et al. 2021), dikkörtgen betonarme kolonların plastik mafsallık uzunluğu (Wakjira et al. 2021).

Ağaç tabanlı algoritmalar arasında genellikle XGBoost algoritması daha doğru sonuçlar vermekle beraber, XGBoost'un da yer aldığı bazı çalışmalarda performans açısından farklılık görülmektedir (Mangalathu et al. 2020; Bentéjac et al. 2021; Zhang et al. 2022; Farzinpour et al. 2023; Lai et al. 2023; Ma et al. 2023b; Yang and Prayogo 2025). Bentéjac et al. 2021 boosting algoritmalarının kendi içinde başarısını tespit etmek

için 28 farklı veri kümesi üzerinde incelemeler yapmışlardır. Bu çalışmada, CatBoost'un en doğru sonuçları verdiğini ancak diğerlerinden biraz daha yavaş olduğunu, XGBoost'un hem doğruluk hem de hız açısından ikinci sırada olduğunu, LightGBM'un en hızlı algoritma olduğunu ancak doğruluğunun diğerlerine kıyasla iyi olmadığını belirtmişlerdir. Bu çalışma da dikkate alınarak hem doğruluk hem de hız açısından XGBoost kullanımı uygun olacağı için ağaç temelli modellerin gelişim sırası dikkate alınarak yapılan incelemede, XGBoost aşamasından sonraki algortimalar incelenmedi.

Çalışmada DT, RF, AdaBoost ve XGBoost algoritmaları ile oluşturulan modeller kıyaslandı. Özellikle hiperparametre optimizasyonu yapılmadan kıyaslanan modellerde DT'nin aşırı öğrenme hatası vermesi nedeniyle ilk aşamada sadece bu modelde RS tekniği kullanıldı. Bu yöntem uzun yıllardır kullanılan ve başarılı sonuç veren bir yöntemdir (Bergstra and Bengio 2012; Li et al. 2018; Meaney et al. 2025). Tüm bu modeller kıyaslandığında daha iyi bir performans gösteren XGBoost modelinde hiperparametre optimizasyon teknikleri kullanılarak inceleme yapıldı. İlk hiperparametre optimizasyon yöntemi olarak yine RS incelendi.

Diğer hiperparametre optimizasyon yöntemi olarak Optuna seçildi (Shekhar et al. 2021; Ma et al. 2023b; Yahiaoui et al. 2023). Optuna özellikle hızıyla öne çıkmaktadır (Akiba et al. 2019; Shekhar et al. 2022; Khan et al. 2025). XGBoost-Optuna modeli ile yapılan çalışmalarda (Srinivas and Katarya 2022; Shi et al. 2024) başarılı sonuçlar ortaya koymaktadır.

Makine öğreniminin yorumlanabilir olmaması gerçek zamanlı bir değerlendirmeyi veya tahminleri engellemektedir. Bu sorunu gidermek için ML yorumlama modelleri ortaya çıkmıştır. SHAP modellemesi girdi parametrelerinin çıktıya nasıl katkı sağladığını ortaya koyan ve son zamanlarda kullanımı yaygınlaşan bir yorumlama modelidir. SHAP modellemesini kullanarak model yorumlaması yapan birçok çalışma bulunmaktadır (Aladsani et al. 2021; Mangalathu et al. 2021; Bakouregui et al. 2021; Naser 2021; Wakjira et al. 2021; Mangalathu et al. 2022; Ma et al. 2023a; Ma et al. 2023b; Le Nguyen et al. 2024; Safaeian Hamzekolaei and Barkhordari 2024; Khan et al. 2025; Yang and Prayogo 2025).

Ağaç tabanlı algoritmalarda model oluşturulduktan sonra çıktı olarak tahmin değerini ve model oluşma aşamasında üretilen ağaç yapısının görselleri verilmektedir. Girdi değerleri ile çıktı değerleri arasındaki ilişkiyi sayısal olarak açıklayan bir denklem yapısı yer almamaktadır. Oluşturulan bu modelin herkes tarafından kullanılabilmesi için modelin internet ortamına yüklenip hesap makinesi formunda yeni parametre değerlerine karşılık çıktı üretilbildiği yöntemler veya modeli veri seti ile beraber GitHub ve Kaggle gibi platformlara yükleyerek kullanıma sunan uygulamalar mevcuttur; ancak bu yöntemler için internet bağlantısı gerektirmekle beraber kullanıcı bilgisi yönünden kısıt getirmektedir. Bu nedenle modellerin herkes tarafından kullanılabilmesi için pratik bir yöntem olarak denklem formuna dönüştürülmesi gerekmektedir.

Çalışma kapsamında modelin denklem formunu üretmek için toplamsal güç yasası regresyon modeli kullanıldı (Zhu and Randolph 2011; Shen and Lian 2018). Veri setindeki girdi ve çıktı değişkenleri arasındaki ilişki; bu denklem formuna uyacak şekilde fit edildi.

Makalelerde sunulan açık kaynaklı makine öğrenmesi kodları

Makine öğrenmesi modelleri oluşturulurken kaynak kod yapısı olarak özellikle aşağıda yer alan çalışmalardan faydalandı. Yetersiz kalınan durumlarda, kod yazılımında kullanılan farklı yapay zekâ yöntemleri (ChatGPT ve Gemini) birbirleriyle kıyaslanarak ve her adımda kontrol sağlanarak kod yapısı oluşturuldu.

Çizelge 3.1. Makalelerde sunulan açık kaynaklı kodlar

Kod Bağlantısı	Konu	ML Algoritması	Referans
https://github.com/sujithmangalathu/Explainable_AL_Infrastructure_damage	Betonarme perdelerin kesme dayanımı	RA5, kNN, SVM, DT, RF, AdaBoost, XGBoost ve ALE, PD, SHAP	Mangalathu et al. (2022)
https://github.com/sujithmangalathu/Punching_shear_flat_slab	Betonarme levhaların zımbalama kesme dayanımı	RA1, RA5, kNN, SVM, DT, RF, AdaBoost, XGBoost ve SHAP	Mangalathu et al. (2021)

3. MATERYAL ve YÖNTEM

Çizelge 3.1. (devam)

Kod Bağlantısı	Konu	ML Algoritması	Referans
https://github.com/abdoulayesanni/Prediction-Load-Carrying-Capacity-of-FRP-RC-Columns	FRC ile güçlendirilmiş betonarme kolonların eksenel yük dayanımı	XGBoost ve SHAP	Bakouregui et al. (2021)
https://github.com/sujithmangalathu/Shear-Wall-Failure-Mode	Betonarme perdelerin göçme modlarının belirlenmesi	NB, DT, RF, AdaBoost, XGBoost, kNN, LightGBM ve CatBoost	Mangalathu et al. (2020)

Makine öğrenmesinde Python için kütüphaneler

Programlama dili olarak Python ve editör olarak PyCharm kullanıldı. PyCharm programında ilk olarak gerekli kütüphane indirilerek işleme başlanır. Bu çalışmada kullanılan başlıca kütüphaneler özetlendi (Çizelge 3.2.).

Çizelge 3.2. Python uygulamasında kullanılan başlıca makine öğrenmesi kütüphaneleri

İsim	Özellikler
Scikit-learn	İstatistiksel analiz, veri madenciliği ve veri analizi için çok çeşitli ML algoritmalarını içerir ve sürekli geliştirilir. Python için en önemli kütüphanelerdendir. DT, RF, AdaBoost ve RS buradan alınır.
Pandas	Farklı formattaki veri türlerini okuma kolaylığı ve veri ön işleme kolaylığı sunar.
NumPy	Büyük, çok boyutlu dizileri ve matrisleri işleyebilir, yüksek düzeyde matematiksel fonksiyonlar içerir.
SciPy	Bilimsel ve analitik hesaplamalar için fonksiyonlar içerir.
Matplotlib	Veri görselleştirmede kullanılır.
Seaborn	İstatistiksel grafikler çizmek için kullanılır.
XGBoost	XGBoost modeli için gerekli.
Optuna	Hiperparametre optimizasyonu.
SHAP	Model açıklanabilirliği.
Graphviz	XGBoost modelinin görseli için gerekli.

Makine öğrenmesi regresyon kriterleri

Makine öğrenmesi modelinin performansını ölçmek için ortalama mutlak hata (MAE), karekök ortalama kare hata (RMSE), belirleme katsayısı (R^2) ve 10 katlı çapraz doğrulama (10-cv) değerlerine bakıldı. Modellerin genellenebilirlik performansını nesnel

biçimde ölçmek için değerlendirme çerçevesi olarak 10-katlı çapraz doğrulama (10-cv R^2) kullanıldı. Yöntemde veri, rastgele biçimde 10 eşit kata ayrılır; her yinelemede 9 kat eğitim, 1 kat ise doğrulama için kullanılır ve süreç on turda döndürülerek hatalar ortalama sapma olarak raporlanır. K-katlı cv, tek bir bölmeye kıyasla varyansı düşürür ve tüm gözlemler hem eğitimde hem de doğrulamada rol aldığından mevcut veriden azami yararlanmayı sağlar. Çapraz doğrulama, basitliği ve görünür evrenselliği nedeniyle model seçimi ve hata kestirimi için yaygın bir stratejidir (Arlot and Celisse 2010; Raschka 2018; Ngo et al. 2022; Dunias et al. 2024).


3.2.Yöntem

3.2.1.Veriişleme

ANSYS sonlu eleman yöntemi kullanılarak elde edilen veri setinde plastik dönme ve birim şekil değiştirme değerlerini en çok etkileyen parametrelerin tespiti için korelasyon matrisleri incelendi. Sertkaya (2018) çalışması ve literatürdeki incelemeler ışığında model kurulumunda daha etkili olan parametreler seçildi.

Plastik dönme

Plastik dönme için ilk olarak tüm veri setiyle korelasyon matrisi oluşturuldu (Şekil 3.5.). Korelasyon matrisi oluşturulurken Pearson yöntemi kullanıldı. Pearson yönteminde kullanılan katsayı, iki sürekli değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ölçer. +1 tam pozitif doğrusal, -1 tam negatif doğrusal, 0 doğrusal ilişki yok demektir. Korelasyon katsayısının karesi belirleme katasayısını (R^2) verir. Bu da bir değişkenin, diğer değişkendeki varyansın yüzde kaçını açıkladığına dair doğrudan bir bilgi sunar. Korelasyonda girdi değişkenin çıktı değişkenini azaltıcı veya arttırıcı yönde etkisi ısı haritası ile gösterilir. Python'daki `pandas.DataFrame.corr()` gibi fonksiyonlarda varsayılan `method='pearson'` olarak seçilidir.




Şekil 3.5. Tüm veri seti için plastik dönme korelasyon ısı haritası

Etkili olan parametrelerin belirlenmesinde Sertkaya (2018) çalışmasında nihai şekil değiştirme anında perde taban dönme açısını etkileyen parametreler iki başlık altında incelenmiştir. En etkili parametreler olan perde boyu ve perde uç bölgesi sargı donatsı oranı özelinde tüm veri seti gruplara ayrılarak parametreler ve plastik dönme ilişkisi saçılım grafikleri ile gösterilmiştir (Şekil 3.6., Şekil 3.7.). Perde boyu 2, 3, 5 ve 8 metre, sargı donatsı oranı ise $\rho_s \leq 0,003$, $0,003 < \rho_s < 0,005$ ve $\rho_s \geq 0,005$ şeklinde gruplar oluşturulmuştur.

Nihai şekil değiştirme anındaki perde taban dönme açısını etkileyen parametreleri perde boyuna (l_w) göre gruplandırarak incelediğimizde, genel olarak perde boyu arttıkça perde taban dönme açısının (θ_u) azaldığı görülmektedir. Diğer parametrelerden belirgin özellik gösterenler incelendiğinde; donatı çeliği akma gerilmesi (f_y) azaldıkça θ_u 'nun azaldığı, beton basınç dayanımı (f_c) arttıkça θ_u 'nun arttığı ancak $f_c=50\text{MPa}$ seviyesinde


azaldığı, aksel yük oranı (P/P_o) arttıkça θ_u 'nun belirli bir seviyeye kadar arttığı daha sonra azaldığı özellikle $P/P_o=0,40$ seviyesinde belirgin bir düşüş olduğu, perde uç bölgesi boyuna donatı oranı (ρ_b) arttıkça θ_u 'nun arttığı ancak perde boyuna göre grupta özellikle 8m'lik perdelerde genel dağılımdan farklı olduğu, perde uç bölgesi sargı donatısı oranı (ρ_s) azaldıkça θ_u 'nun azaldığı, perde yatay gövde donatısı oranı ($\rho_{sh}=\rho_t$) arttıkça θ_u 'nun azaldığı görülmekte ve normalize edilmiş kesme gerilmesi ($v=v_n$) arttıkça θ_u 'nun $v=0,15$ seviyesine kadar arttığı sonrasında azaldığı görülmektedir (Şekil 3.6.).



Şekil 3.6. Nihai şekil değiştirme anında perde taban dönme açısı üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018).

Nihai şekil değiştirme anındaki perde taban dönme açısını etkileyen parametreleri perde uç bölgesinde sargı donatısı oranına (ρ_s) göre gruplandırarak incelediğimizde, genel


olarak sargı donatısı oranı azaldıkça perde taban dönme açısının (θ_u) azaldığı görülmektedir. Diğer parametrelerin etkisi Şekil 3.6.'daki ile benzer özellik göstermekte ancak farklı olarak boyuna donatı oranının (ρ_b) sargı donatısı oranına göre gruplamadan etkilenmediği görülmektedir (Şekil 3.7.).



Şekil 3.7. Nihai şekil değiştirme anında perde taban dönme açısı üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).

Korelasyon ısı haritası, Sertkaya (2018) ve literatürden yararlanılarak yapılan çalışma neticesinde seçilen parametreler: l_w :perde boyu, L_v :etkin kesme boyu, P/P_o :eksenel yük oranı, ρ_s :perde uç bölgesinde sargı donatısı oranı, $\rho_t f_y/f_c$:perde yatay gövde donatısı oranının donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı, v_n :normalize edilmiş kesme gerilmesi olarak belirlendi (Orakcal and Wallace


2006; Su and Wong 2007; Dazio et al. 2009; Segura and Wallace 2018; Abdullah and Wallace 2019; Moradi and Hariri-Ardebili 2019; Aladsani et al. 2022; Zhang et al. 2022; Kazaz et al. 2024). Seçilen parametreler ile korelasyon ısı haritası yeniden oluşturuldu (Şekil 3.8.).



Şekil 3.8. Plastik dönme korelasyon ısı haritası

Seçilen parametreler ve plastik dönme arasındaki ilişki çoklu saçılım diyagramları matrisi ile gösterildi (Şekil 3.9.).


Çoklu Saçılım Diyagramları Matrisi — Özellikler ile θ_p (rad) ilişkisi



Şekil 3.9. Plastik dönme ve parametreler arasındaki ilişki

Beton birim kısılması


Beton birim kısılması için ilk olarak tüm veri setiyle korelasyon matrisi oluşturuldu (Şekil 3.10.).



Şekil 3.10. Tüm veri seti için beton birim kısılması korelasyon ısı haritası


Etkili olan parametrelerin belirlenmesinde Sertkaya (2018) çalışmasında nihai şekil değiştirme anında beton birim kısılmasını etkileyen parametreler iki başlık altında incelenmiştir. En etkili parametreler olan perde boyu ve perde uç bölgesi sargı donatısı oranı özelinde tüm veri seti gruplara ayrılarak parametreler ve beton birim kısılması ilişkisi saçılım grafikleri ile gösterilmiştir (Şekil 3.11., Şekil 3.12.). Perde boyu 2, 3, 5 ve 8 metre, sargı donatısı oranı ise $\rho_s \leq 0,003$, $0,003 < \rho_s < 0,005$ ve $\rho_s \geq 0,005$ şeklinde gruplar oluşturulmuştur.

Nihai şekil değiştirme anındaki beton birim kısalmasını etkileyen parametreleri perde boyuna (l_w) göre gruplandırarak incelediğimizde, perde boyu arttıkça beton birim kısalmasının (ε_{cu}) azaldığı görülmektedir. Diğer belirgin özellik gösteren parametreler incelendiğinde; eksenel yük oranı (P/P_o) arttıkça ε_{cu} 'nun $P/P_o=0,40$ seviyelerine kadar arttığı daha sonra belirgin bir düşüş olduğu, perde uç bölgesi boyuna donatı oranının (ρ_b) perde boyuna bağlı olarak genel davranışın dışına çıktığı, perde uç bölgesi sargı donatısı oranının $\rho_s=0,005$ seviyelerine kadar ε_{cu} 'yu arttırdığını ancak ρ_s arttıkça ε_{cu} 'nun azaldığı ve normalize edilmiş kesme gerilmesi (ν) arttıkça ε_{cu} 'nun belirli bir seviyeye ulaştıktan sonra azaldığı görülmektedir (Şekil 3.11.).



Şekil 3.11. Nihai şekil değiştirme anında perde uç bölgesi beton birim kısalması üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018).


Nihai şekil değiştirme anındaki beton birim kısalmasını etkileyen parametreleri perde uç bölgesi sargı donatısı oranına (ρ_s) göre gruplandırarak incelediğimizde, sargı donatısı oranı $\rho_s=0,005$ seviyelerine kadar beton birim kısalmasının (ϵ_{cu}) arttığı ancak ρ_s arttıkça azaldığı görülmektedir. Diğer parametrelerin etkisi Şekil 3.11.'deki ile benzer özellik göstermekle beraber, boyuna donatı oranının (ρ_b) beton birim kısalmaya etkisi sargı donatısı oranı ile beraber dikkate alındığında farklılık göstermekte (Şekil 3.12.).



Şekil 3.12. Nihai şekil değiştirme anında perde uç bölgesi beton birim kısalması üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).

Korelasyon ısı haritası, Sertkaya (2018) ve literatürden yararlanılarak yapılan çalışma neticesinde seçilen parametreler; L_w :perde boyu, L_v :etkin kesme boyu, P/P_o :eksenel yük oranı, ρ_b :perde uç bölgesinde boyuna donatı oranı, ρ_s :perde uç


bölgesinde sargı donatısı oranı, $\rho_t f_y / f_c$:perde yatay gövde donatısı oranının donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı, ν_n :normalize edilmiş kesme gerilmesi olarak belirlendi (Thomsen and Wallace 2004; Orakcal and Wallace 2006; Dazio et al. 2009; Welt el al. 2017; Haro et al. 2018; Segura and Wallace 2018; Abdullah and Wallace 2019). Seçilen parametreler ile korelasyon ısı haritası yeniden oluşturuldu (Şekil 3.13).



Şekil 3.13. Beton birim kısalması korelasyon ısı haritası

Seçilen parametrelerle beton birim kısalma arasındaki ilişki çoklu saçılım diyagramları matrisi ile gösterildi (Şekil 3.14.).


Çoklu Saçlım Diyagramları Matrisi — Özellikler ile ε_{cu} ilişkisi



Şekil 3.14. Beton birim kısalması ve parametreler arasındaki ilişki

Çelik birim uzaması


Çelik birim uzaması için ilk olarak tüm veri setiyle korelasyon matrisi oluşturuldu (Şekil 3.15.).



Şekil 3.15. Tüm veri seti için çelik birim uzaması korelasyon ısı haritası


Etkili olan parametrelerin belirlenmesinde Sertkaya (2018) çalışmasında nihai şekil değiştirme anında çelik birim uzamasını etkileyen parametreler iki başlık altında incelenmiştir. En etkili parametreler olan perde boyu ve perde uç bölgesi sargı donatısı oranı özelinde tüm veri seti gruplara ayrılarak parametreler ve çelik birim uzaması ilişkisi saçılım grafikleri ile gösterilmiştir (Şekil 3.16., Şekil 3.17.). Perde boyu 2, 3, 5 ve 8 metre, sargı donatısı oranı ise $\rho_s \leq 0,003$, $0,003 < \rho_s < 0,005$ ve $\rho_s \geq 0,005$ şeklinde gruplar oluşturulmuştur.

Nihai şekil değiştirme anındaki çelik birim uzamasını etkileyen parametreleri perde boyuna (l_w) göre gruplandırarak incelediğimizde, perde boyu arttıkça çelik birim uzamasının (ε_{su}) azaldığı görülmektedir. Diğer belirgin parametreler incelendiğinde; eksenel yük oranı (P/P_o) arttıkça ε_{su} 'nun belirli bir seviyeye kadar arttığı daha sonra azaldığı perde uç bölgesi boyuna donatı oranının (ρ_b) perde boyuna bağlı olarak özellikle 8 metrelik perdelerde genel davranışın dışına çıktığı, perde uç bölgesi sargı donatısı oranı (ρ_s) arttıkça ε_{su} 'nun arttığı ve normalize edilmiş kesme gerilmesi (ν) arttıkça ε_{su} 'nun belirli bir seviyeye ulaştıktan sonra azaldığı görülmektedir (Şekil 3.16.).



Şekil 3.16. Nihai şekil değiştirme anında perde uç bölgesi çelik birim uzaması üzerine parametrelerin etkisi, perde boyuna göre gruplandırma (Sertkaya 2018).


Nihai şekil değiştirme anındaki çelik birim uzamasını etkileyen parametreleri perde uç bölgesi sargı donatısı oranına (ρ_s) göre gruplandırarak incelediğimizde, sargı donatısı oranı azaldıkça çelik birim uzamasının (ε_{su}) azaldığı görülmektedir. Diğer parametrelerin etkisi Şekil 3.16.'daki ile benzer özellik göstermekle beraber, boyuna donatı oranının (ρ_b) çelik birim uzamasına etkisi sargı donatısı oranının yetersiz olduğu durumlarda genel davranıştan farklılık göstermekte (Şekil 3.17.).



Şekil 3.17. Nihai şekil değiştirme anında perde uç bölgesi çelik birim uzaması üzerine parametrelerin etkisi, sargı donatısı oranına göre gruplandırma (Sertkaya 2018).

Korelasyon ısı haritası, Sertkaya (2018) ve literatürden yararlanılarak yapılan çalışma neticesinde seçilen parametreler; l_w :perde boyu, L_v :etkin kesme boyu, P/P_o :eksenel yük oranı, ρ_b :perde uç bölgesinde boyuna donatı oranı ρ_s :perde uç


bölgesinde sargı donatısı oranı, $\rho_t f_y / f_c$:perde yatay gövde donatısı oranının donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı, ν_n :normalize edilmiş kesme gerilmesi parametrelerinin etkin olduğu görülmüştür (Orakcal and Wallace 2006; Dazio et al. 2009; Wallace 2012; Haro et al. 2018; Segura and Wallace 2018; Abdullah and Wallace 2019). Seçilen parametreler ile korelasyon haritası yeniden oluşturuldu (Şekil 3.18.).



Şekil 3.18. Çelik birim uzaması korelasyon ısı haritası

Seçilen parametrelerle çelik birim uzama arasındaki ilişki çoklu saçılım diyagramları matrisi ile gösterildi (Şekil 3.19.).

Çoklu Saçılım Diyagramları Matrisi — Özellikler ile ε_{su} ilişkisi



Şekil 3.19. Çelik birim uzaması ve parametreler arasındaki ilişki

3.2.2. Model oluřturma ve yorumlama

Seilen drt yntem iin modeller oluřturuldu. DT, RF, AdaBoost ve XGBoost ile oluřturulan modeller birlikte karřılařtırılmal olarak incelendi. DT modeli oluřturulurken hiperparametre ayarları yapılmadıėı durumda ařırı ėrenme problemi ortaya ıktı. Bu nedenle RS hiperparametre optimizasyonu uygulandı. Modeller kıyaslandıėında en iyi sonucu veren XGBoost modeli iin de RS ve Optuna hiperparametre optimizasyonu yapıldı. İnceleme sonunda XGBoost-Optuna modelinin en iyi sonucu verdiėi tespit edildi ve model yorumlaması iin SHAP yntemi kullanıldı.

Plastik dnme zelinde yapılan incelemeler sonucunda karar verilen XGBoost-Optuna-SHAP hibrit modeli birim řekil deėiřtirmelere de uygulandı.

3.2.3. Toplamsal g yasası regresyon modeli

Performans sınırları iin oluřturulan modeller sonucunda tahmin edilen deėer ile model oluřturulurken kullanılan parametreler birleřtirilerek yeni bir veri seti oluřturuldu. Bu yeni veri setinden; Python *scipy* ktphanesinin iinde bulunan, *optimize* modlnde *curve_fit* kullanılarak g yasası regresyon forml yapısına uygun denklem retildi. Daha sonra ANSYS sonlu eleman modeliyle hesaplanan veri setiyle de aynı yntem kullanılarak denklem retildi. Bu denklemlerin R^2 ve 10-cv R^2 deėerleri kıyaslandı.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Modeller ve Modellerin Çıktıları


Model oluşturma aşamasında ilk olarak betonarme perdelerde inceleme yapılmıştır. İnceleme kapsamında DT, RF, AdaBoost, XGBoost, XGBoost-RS, XGBoost-Optuna modelleri oluşturuldu. XGBoost-Optuna modelinin diğerlerinden daha iyi sonuç verdiği görüldü. Daha sonra, bu modelin yorumlanması için SHAP yöntemi kullanıldı. XGBoost-Optuna-SHAP hibrit modeli beton birim kısalması ve çelik birim uzamasına da uygulandı. Plastik dönme modellerinde veri seti %70 eğitim ve %30 test verisi olarak, birim şekil değiştirmelerde veri seti %80 eğitim ve %20 test verisi olarak ayrıldı.

4.1.1. Karar Ağacı-plastik dönme


Karar ağacı modeli kurulduğunda algoritmayı en iyi yansıtan hiperparametreleri ölçmek için RS yöntemi kullanıldı. Veri seti üzerine inceleme yapılırken her seferinde aynı yerden bölünme olması için random_state:0 verildi. Burada random state değerinden ziyade modelde tutarlılık için her seferinde aynı değerin verilmesi önemlidir. RS içinde karar ağacı hiperparametreleri "max_depth": [5, 50], "min_samples_split": [2, 4, 6, 8, 12, 16, 20], "min_samples_leaf": [1, 2, 3, 5, 8] bu aralıklarda verildi. Optimizasyon sonucunda en iyi hiperparametreler; min_samples_split:12, min_samples_leaf:5, max_depth:45 olarak bulundu. Modelin ağaç görseli Şekil 4.1.'de verildi.

4.1.2. Rastgele Arama-plastik dönme

Bu yöntemde model kurulurken hiperparametre ayarı yapılmadı, sadece random_state:0 olarak verildi ve varsayılan hiperparametrelerle model kuruldu. Örneğin n_estimators =100 varsayılan değerdir. Yani model kurulurken 100 ağaç ile sonucu bulmaya çalışır. Modele ait ağaç yapılarından ilki aşağıda verildi (Şekil 4.2.). Şekilde de görüldüğü gibi DT formuyla aynı ancak burada farklılık aynı formda birçok ağacın oluşması.




Şekil 4.1. Plastik dönme karar ağacı modeli birinci ağacın kesiti



Şekil 4.2. Plastik dönme rastgele orman modeli birinci ağacın kesiti

4.1.3.Uyarlanabilir Arttırma-plastik dönme

Bu yöntemde model kurulurken hiperparametre ayarı yapılmadı, sadece random_state:0 olarak verildi ve varsayılan hiperparametrelerle model kuruldu. Örneğin n_estimators=50 varsayılan değerdir. Yani model kurulurken 50 ağaç oluşturarak sonucu bulmaya çalışır, köklenme kriteri olan max_dept=3 olarak varsayılır. Bu durum ağacın köklenirken derinlik olarak 3'e kadar gidebileceğini gösterir. Bunun sonucu olarak ağaç yeterli köklenemediğinden doğru sonuca ulaşmadan karar verir. Uyarlanabilir arttırmada her bir ağaç modelindeki zayıf öğrenciler öğrenilir ve buna bağlı olarak karara varılır. Ağaçlardan tespit etmesi gereken zayıf öğrenciler hatalı olduğu için sonuçta eksik olur. Bu durum model çıktılarında belirgin olarak gözlemlendi. Modele ait örnek ağaç yapısı aşağıda verildi (Şekil 4.3.).




Şekil 4.3. Plastik dönme uyarlanabilir artırma modeli birinci ağacın yapısı

4.1.4. Aşırı Gradyan Arttırma-plastik dönme

XGBoost

Bu yöntemde model kurulurken hiperparametre ayarı yapılmadı, sadece random_state:0 olarak verildi ve varsayılan hiperparametrelerle model kuruldu. Örneğin n_estimators =100 varsayılan değerdir. Yani model kurulurken 100 ağaç oluşturarak sonucu bulmaya çalışır, köklenme kriteri olan max_dept=6 olarak varsayılır bu ağacın köklenirken derinlik olarak 6'ya kadar gidebileceğini gösterir. Modele ait ilk ağaç görseli aşağıda verildi (Şekil 4.4.).




Şekil 4.4. Plastik dönme aşırı gradyan arttırma modeli birinci ağacın yapısı

XGBoost-RS-plastik dönme

Model kurulduğunda algoritmayı en iyi yansıtan hiperparametreleri ölçmek için RS yöntemi kullanıldı. Veri seti üzerine inceleme yapılırken her seferinde aynı yerden bölünme olması için random_state:0 verildi. RS içinde hiperparametreler 'n_estimators': [100, 200, 500], 'max_depth': [3, 5, 7, 9], 'learning_rate': [0.01, 0.05, 0.1, 0.5], 'subsample': [0.5, 0.8, 1.0], 'colsample_bytree': [0.5, 0.8, 1.0] aralıkları bu şekilde seçildi. Optimizasyon sonucunda en iyi parametreler subsample=0.8, n_estimators=500, max_depth=5, learning_rate=0.05, colsample_bytree=1 olarak belirlendi. Modelle ait örnek ağaç şekli olarak altmışıncı ağaç seçildi (Şekil 4.5.).

XGBoost-Optuna-plastik dönme


Model kurulduğunda algoritmayı en iyi yansıtan hiperparametreleri ölçmek için Optuna yöntemi kullanıldı. Optuna içinde sabit olan hiperparametreler 'tree_method': 'hist', 'n_jobs': -1, 'random_state': 0, 'eval_metric': 'rmse', 'n_estimators': 1000, aralık içinden seçilen hiperparametreler; 'learning_rate', 0.01, 0.3, log=True, 'max_depth': 3, 10, 'subsample': 0.5, 1.0, 'colsample_bytree', 0.5, 1.0, 'gamma': 1e-8, 1.0, log=True, 'reg_alpha': 1e-8, 1.0, log=True, 'reg_lambda': 1e-8, 1.0, log=True. Optimizasyon sonucunda en iyi hiperparametreler; learning_rate=0.034348617, max_depth=4, subsample=0.716975915, colsample_bytree=0.92229198, gamma=5.18157E-08, reg_alpha=0.002263165, reg_lambda=0.743564093 olarak belirlendi. Modelin ait örnek ağaç şekli olarak altmışıncı ağaç seçildi (Şekil 4.6.).



Şekil 4.6. Plastik dönme aşırı gradyan artırma-optuna modeli altmışıncı ağacın yapısı

4.1.5.SHAP yorumlama-plastik dönme


SHAP’da yorumlama grafiklerinden önem grafiğinde modeldeki parametrelerin plastik dönme (θ_p) üzerine etkileri sırasıyla; perde uç bölgesinde sargı donatısı oranı (ρ_s), eksenel yük oranı (P/P_o) ve perde boyu (l_w), normalize edilmiş kesme gerilmesi (ν_n) daha az etkileyen parametreler ise perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve etkin kesme boyu (L_v) şeklinde sıralanmaktadır (Şekil 4.7.). Model oluşurken ρ_s ’nin diğer parametrelere nazaran daha baskın olduğu görülmekte.



Şekil 4.7. Plastik dönme (θ_p) modelinin SHAP önem grafiği


SHAP’da yorumlama grafiklerinden özet grafiğinde modelin genel davranışı detaylı olarak sunulur. Her bir parametrenin artmasının ya da azalmasının plastik dönmeyi (θ_p) nasıl etkilediği renk değişimleriyle gösterilmektedir ve parametre çizgisinin kalınlığı SHAP aralığındaki veri yoğunluğunu gösterir (Şekil 4.8.). Perde uç bölgesinde sargı donatısı oranı (ρ_s), arttıkça plastik dönme artmakta ve orta düzey değerlerin çoğu plastik dönmeyi artırma eğilimindedir. Eksenel yük oranı (P/P_o) arttıkça plastik dönme azalmakta ve orta düzey değerler plastik dönmeyi azaltma eğilimindedir. Perde boyu (l_w) azaldıkça plastik dönme artmakta ve orta düzey değerler plastik dönmeyi azaltıcı eğilimdedir. Normalize edilmiş kesme gerilmesi (ν_n) azaldıkça plastik dönme artmakta ve orta düzey değerlerin etkisi net değildir. Perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) azaldıkça

plastik dönme azalmakta ve orta düzey değerler plastik dönmeyi artırma eğilimindedir. Etkin kesme boyu (L_v) azaldıkça plastik dönme azalmakta ve orta düzey değerler plastik dönmeyi artırma eğilimindedir.



Şekil 4.8. Plastik dönme (θ_p) modelinin SHAP özet grafiği


SHAP’da yorumlama grafiklerinden şelale grafiğinde tek bir tahminde parametrelerin etkisi gösterilir. Veri setinde yer alan dört farklı perde boyu özelinde diğer parametrelerin etkisini ölçmek amacıyla aynı değerdeki örneklerin şelale grafikleri çizdirildi. Perde boyu (l_w) 3 m ve 5 m olan perdelerde; perde uç bölgesinde sargı donatısı oranının (ρ_s), perde boyu arttıkça plastik dönmeye pozitif katkısı azalmaktadır. Perde boyu 2 m, 3 m ve 5 m olan perdelerde; etkin kesme boyunun (L_v) perde boyu arttıkça plastik dönmeye negatif katkı sağlamaktadır. Perde boyu 2 m, 3 m, 5 m ve 8 m olan perdelerde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımının ($\rho_t f_y / f_c$) perde boyu arttıkça plastik dönmeye negatif katkı sağlamaktadır (Şekil 4.9.).



Şekil 4.9. Plastik dönme (θ_p) modelinin SHAP şelale grafikleri, perde boyu özelinde; (a) $l_w=2$ m, (b) $l_w=3$ m, (c) $l_w=5$ m ve (d) $l_w=8$ m.


SHAP’da yorumlama grafiklerinden bağımlılık grafiğinde; bir girdi değerinin doğrusal mı, yoksa daha karmaşık bir etkiye mi sahip olduğunu göstermenin yanı sıra etkileşimde olduğu bir diğer girdi değeriyle beraber çıktı üzerindeki etkisi de ortaya konur.

Şekil 4.10. grafiğinde; perde boyunda (l_w), perde uç bölgesinde sargı donatısı oranına (ρ_s) göre veri setlerinde gruplanma olduğu görülmektedir. Perde boyu; 2 m ve 3 m olan perdelerde sargı donatısı oranı arttıkça plastik dönme (θ_p) artmakta, perde boyu; 5 m ve 8 m olan perdelerde sargı donatısı oranı azaldıkça plastik dönme artmaktadır.




Şekil 4.10. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.11. grafiğinde; etkin kesme boyu (L_v) içerisinde sargı donatısı oranına (ρ_s) göre bir gruplanma görülmektedir. Etkin kesme boyu için iki grupta sargı donatısı oranı azaldıkça plastik dönme (θ_p) artmakta, diğer gruplarda sargı donatısı oranı arttıkça plastik dönme artmaktadır. SHAP değeri yaklaşık -0,001’den sonra pozitif yönde artışın olduğu değerlerde etkin kesme boyu gruplarında, sargı donatısı oranı etkisinin ortak özelliklere sahip olduğu görülmektedir.




Şekil 4.11. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.12. grafiğinde; eksenel yük oranına (P/P_o) göre perde boyunun (l_w) etkisi farklılık göstermektedir. Perde boyu 4,571'den daha küçük olan grup en yüksek plastik dönme (θ_p) değerine sahip ve eksenel yük oranı arttıkça azalan bir eğilim göstermektedir. Perde boyu 5,429'dan daha büyük olan perdeler ve orta düzey değere sahip perdeler benzer ilişki göstererek eksenel yük oranı arttıkça plastik dönme değerinde azalan bir eğilim göstermektedir. Bu grafikte aynı eksenel yük oranına sahip değerlerdeki gruplanmadan ziyade farklı eksenel yük oranı değerlerinde bir gruplanma olduğu görülmektedir.




Şekil 4.12. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve perde boyu (l_w) ilişkisi.

Şekil 4.13. grafiğinde; sargı donatısı oranında (ρ_s) eksenel yük oranına (P/P_o) göre bir gruplanma olduğu görülmektedir. Sargı donatısı oranı 0,002'den küçük olduğu durumlarda eksenel yük oranı arttıkça plastik dönme (θ_p) artmaktadır. Sargı donatısı oranı 0,002-0,005 aralığında eksenel yük oranı azaldıkça plastik dönme artmakta ve 0,005'den büyük olduğu durumlarda genel bir davranış görülmemektedir.




Şekil 4.13. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve eksenel yük oranı (P/P_o) ilişkisi.

Şekil 4.14. grafiğinde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımında ($\rho_t f_y / f_c$) sargı donatısı oranına (ρ_s) göre bir gruplanma olduğu görülmektedir. $\rho_t f_y / f_c$ 'nin farklı değerlerine göre bu gruplanmanın özellikleri değişiklik göstermektedir. Genel bir ifade olarak $\rho_t f_y / f_c = 0,15$ 'den büyük olduğu durumlarda sargı donatısı oranı arttıkça plastik dönme (θ_p) azalmaktadır.



Şekil 4.14. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.15. grafiğinde; normalize edilmiş kesme gerilmesinde (v_n) sargı donatısı oranına göre bir gruplanma olduğu görülmektedir. Sargı donatısı oranının arttığı ve azaldığı durumlara göre plastik dönme (θ_p) için ayrı dağılımlar ortaya çıkmaktadır. Özellikle normalize edilmiş kesme gerilmesi 0,4'den büyük olduğu durumlarda sargı donatısı oranı arttıkça plastik dönme azalmaktadır.




Şekil 4.15. Plastik dönme (θ_p) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (ν_n) ve sargı donatısı oranı (ρ_s) ilişkisi.

4.1.6. Aşırı Gradyan Arttırma-beton birim kısalması

XGBoost-Optuna-beton birim kısalması


Model kurulduğunda algoritmayı en iyi yansıtan hiperparametreleri ölçmek için Optuna yöntemi kullanıldı. Optuna içinde sabit olan hiperparametreler; 'tree_method': 'hist', 'n_jobs': -1, 'random_state': 0, 'eval_metric': 'rmse', 'n_estimators': 1000, aralık içinden seçilen hiperparametreler; 'learning_rate', 0.005, 0.20, log=True, 'max_depth', 3, 8, 'subsample', 0.30, 0.90 'colsample_bytree', 0.30, 0.90, 'gamma', 1e-8, 5.0, log=True, 'reg_alpha', 1e-8, 10.0, log=True, 'reg_lambda', 1e-8, 10.0, log=True, Optimizasyon sonucunda en iyi hiperparametreler; learning_rate=0.022115888, max_depth=8, subsample 0.709069251, colsample_bytree=0.868775592, gamma=7.00076E-07, reg_alpha=5.13769E-07, reg_lambda=0.521520025 olarak belirlendi. Modele ait örnek ağaç görseli şekil 4.16.'da verildi.



Şekil 4.16. Beton birim kısılması aşırı gradyan arttırma-optuna modeli yüz üçüncü ağacın yapısı

4.1.7. SHAP Yorumlama-beton birim kısılması


SHAP’da yorumlama grafiklerinden önem grafiğinde modeldeki parametrelerin beton birim kısılması (ε_{cu}) üzerine etkileri gruplar halinde sıralanmaktadır. En yüksek etkiye sahip parametreler; perde uç bölgesinde sargı donatısı oranı (ρ_s) ve perde boyu (l_w) ikinci grup parametreler; eksenel yük oranı (P/P_o) ve perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t \cdot f_y / f_c$) ve diğerlerine nazaran daha az etkili olan üçüncü grup parametreler; normalize edilmiş kesme gerilmesi (ν_n), perde uç bölgesinde boyuna donatı oranı (ρ_b) ve etkin kesme boyu (L_v) olarak sıralanmaktadır (Şekil 4.17.).



Şekil 4.17. Beton birim kısılması (ε_{cu}) modelinin SHAP önem grafiği

SHAP’da yorumlama grafiklerinden özet grafiğinde modelin genel davranışı detaylı olarak sunulur. Her bir parametrenin artmasının ya da azalmasının beton birim kısılmasını (ε_{cu}) nasıl etkilediği renk değişimleriyle gösterilmektedir ve parametre çizgisinin kalınlığı SHAP aralığındaki veri yoğunluğunu gösterir (Şekil 4.18.). Perde uç bölgesinde sargı donatısı oranı (ρ_s), arttıkça beton birim kısılması artmakta ve orta düzey değerler beton birim kısılmasını artırma eğilimindedir. Perde boyu (l_w) azaldıkça beton birim kısılması artmakta ve orta düzey değerlerin etkisi zayıftır. Eksenel yük oranı (P/P_o) belirli bir seviyeden sonra arttıkça beton birim kısılmasının azalmasına sebep olmakta ve orta düzey değerler beton birim kısılmasını artırma eğilimindedir. Perde yatay gövde

donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) azaldıkça beton birim kısalması azalmakta ve orta düzey değerler beton birim kısalmasını artırma eğilimindedir. Normalize edilmiş kesme gerilmesi (v_n) için (değerlerin bir kısmında) azaldıkça beton birim kısalması artmakta ve orta düzey değerlerin etkisi zayıftır. Boyuna donatı oranı (ρ_b) azaldıkça beton birim kısalması azalmakta ve orta düzey değerler beton birim kısalmasını artırma eğilimindedir. Etkin kesme boyu (L_v) azaldıkça beton birim kısalması artmakta ve orta düzey değerler beton birim kısalmasını artırma eğilimindedir.




Şekil 4.18. Beton birim kısalması (ϵ_{cu}) modelinin SHAP özet grafiği

SHAP’da yorumlama grafiklerinden şelale grafiğinde tek bir tahminde parametrelerin etkisi gösterilir. Veri setinde yer alan dört farklı perde boyu özelinde diğer parametrelerin etkisini ölçmek amacıyla aynı değerdeki örneklerin şelale grafikleri çizdirildi. Perde boyu (l_w) 3 m ve 5 m olan perdelerde; perde uç bölgesinde sargı donatısı oranının (ρ_s), perde boyu arttıkça beton birim kısalmasına (ϵ_{cu}) pozitif katkısı azalmaktadır. Perde boyu (l_w) 2 m, 3 m ve 5 m olan perdelerde; etkin kesme boyunun (L_v) perde boyu arttıkça beton birim kısalmasına negatif katkı sağlamaktadır. Perde boyu (l_w) 2 m ve 3 m, olan perdelerde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımının ($\rho_t f_y / f_c$) (0,021 değeri) perde boyu arttıkça beton birim kısalmasına negatif katkısı artmaktadır. Perde boyu (l_w) 5 m ve 8 m, olan perdelerde; perde yatay gövde donatısı oranının, donatı çeliği akma

gerilmesinin beton basınç dayanımına oranı ile çarpımının ($\rho_t f_y / f_c$) (0,011 değeri) perde boyu arttıkça beton birim kısalmasına negatif katkısı azalmaktadır. Perde boyu (l_w) 2 m, 3 m, 5 m ve 8 m olan perdelerde; boyuna donatı oranının (ρ_b) perde boyu arttıkça beton birim kısalmasına negatif katkı sağlamaktadır (Şekil 4.19.).






Şekil 4.19. Beton birim kısalması (ε_{cu}) modelinin SHAP şelale grafikleri, perde boyu özelinde; (a) $l_w=2$ m, (b) $l_w=3$ m, (c) $l_w=5$ m ve (d) $l_w=8$ m.


SHAP’da yorumlama grafiklerinden bağımlılık grafiğinde; bir girdi değerinin doğrusal mı, yoksa daha karmaşık bir etkiye mi sahip olduğunu göstermenin yanı sıra etkileşimde olduğu bir diğer girdi değeriyle beraber çıktı üzerindeki etkisi de ortaya konulur.

Şekil 4.20. grafiğinde; perde boyu (l_w) ve normalize edilmiş kesme gerilmesi (v_n) arasındaki etkileşim görülmektedir. Perde boyu 2 m ve 3 m olan perdelerde normalize edilmiş kesme gerilmesinin orta düzey ve negatif katkı sağlayan değerleri yoğun olarak görülmektedir. Perde boyu 8 m olan perdelerde normalize edilmiş kesme gerilmesi arttıkça beton birim kısalması (ε_{cu}) azalmaktadır.




Şekil 4.20. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve normalize edilmiş kesme gerilmesi (v_n) ilişkisi.

Şekil 4.21. grafiğinde; etkin kesme boyunda (L_v) perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımının (ρ_{tf}/f_c) etkisi negatif katkı sağladığı durumlarda net olarak görülmektedir. Genel bir yorumdan ziyade farklı etkin kesme boylarına göre ρ_{tf}/f_c 'nin negatif katkısı beton birim kısalmasında (ε_{cu}) artma veya azalmaya sebep olmaktadır.




Şekil 4.21. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t \cdot f_y / f_c$) ilişkisi.

Şekil 4.22. grafiğinde; eksenel yük oranında (P/P_o) sargı donatısı oranına (ρ_s) göre bir gruplanma görülmektedir. Eksenel yük oranı 0,30'dan küçük olduğu durumlarda sargı donatısı oranının negatif ve pozitif katkısının beton birim kısalmasına (ε_{cu}) etkisi farklılık göstermektedir. Eksenel yük oranı 0,15'den küçük olduğu durumlarda sargı donatısı oranı attıkça beton birim kısalması azalmaktadır. Eksenel yük oranı 0,15-0,30 aralığında sargı donatısı oranı attıkça beton birim kısalması artmaktadır. Eksenel yük oranı 0,30'dan büyük olduğu durumlarda genellikle sargı donatısı oranı azaldıkça beton birim kısalması artmaktadır.




Şekil 4.22. Beton birim kısalması (ϵ_{cu}) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.23. grafiğinde; boyuna donatı oranında (ρ_b) sargı donatısı oranına (ρ_s) göre bir gruplanma olduğu görülmektedir. Boyuna donatı oranı 0,005 ve 0,010 değerlerinde sargı donatısı oranı arttıkça beton birim kısalması (ϵ_{cu}) azalmaktadır.




Şekil 4.23. Beton birim kısalması (ϵ_{cu}) modelinin SHAP bağımlılık grafiği; boyuna donatı oranı (ρ_b) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.24. grafiğinde; sargı donatısı oranında (ρ_s) eksenel yük oranının (P/P_o) etkisi farklı değerlere göre değişmektedir. Eksenel yük oranının orta düzey değerleri sargı donatısı oranına göre beton birim kısalması (ϵ_{cu}) üzerinde negatif veya pozitif etki göstermektedir.




Şekil 4.24. Beton birim kısalması (ϵ_{cu}) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve aksenal yük oranı (P/P_o) ilişkisi.

Şekil 4.25. grafiğinde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımında ($\rho_t f_y / f_c$) aksenal yük oranının (P/P_o) negatif katkı sağlayan değerlerinin beton birim kısalmasında (ϵ_{cu}) etkili olduğu görülmektedir.



Şekil 4.25. Beton birim kısalması (ϵ_{cu}) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve eksenel yük oranı (P/P_o) ilişkisi.

Şekil 4.26. grafiğinde; normalize edilmiş kesme gerilmesinde (v_n) perde boyuna (l_w) göre bir gruplanma görülmektedir. Normalize edilmiş kesme gerilmesi 0,15'den küçük olduğu değerlerde perde boyunun negatif katkısının beton birim kısalmasında (ϵ_{cu}) etkili olduğu görülmektedir. Normalize edilmiş kesme gerilmesi 0,30'dan büyük olduğu değerlerde perde boyunun pozitif katkısı ve orta düzey değerleri etkilidir.




Şekil 4.26. Beton birim kısalması (ε_{cu}) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (ν_n) ve perde boyu (l_w) ilişkisi.

4.1.8. Aşırı Gradyan Arttırma-çelik birim uzaması

XGBoost-Optuna-çelik birim uzaması


Model kurulduğunda algoritmayı en iyi yansıtan hiperparametreleri ölçmek için Optuna yöntemi kullanıldı. Optuna içinde sabit olan hiperparametreler; 'tree_method': 'hist', 'n_jobs': -1, 'random_state': 0, 'eval_metric': 'rmse', 'n_estimators': 1000, aralık içinden seçilen hiperparametreler; 'learning_rate', 0.005, 0.20, 'max_depth', 3, 8, 'subsample', 0.30, 0.90 'colsample_bytree', 0.30, 0.90, 'gamma', 1e-8, 5.0, log=True, 'reg_alpha', 1e-8, 10.0, log=True, 'reg_lambda', 1e-8, 10.0, log=True, Optimizasyon sonucunda en iyi hiperparametreler; learning_rate=0.024715, max_depth=7, subsample 0.363258, colsample_bytree=0.870579, gamma=1.01E-07, reg_alpha=0.000498, reg_lambda=0.00013 olarak belirlendi. Modele ait örnek ağaç görseli şekil 4.27.'de verildi.



Şekil 4.27. Çelik birim uzaması aşırı gradyan artırma-optuna modeli birinci ağacın kesiti

4.1.9. SHAP yorumlama-çelik birim uzaması


SHAP’da yorumlama grafiklerinden önem grafiğinde modeldeki parametrelerin çelik birim uzaması (ε_{su}) üzerine etkileri sırasıyla; perde uç bölgesinde sargı donatısı oranı (ρ_s), eksenel yük oranı (P/P_o), perde boyu (l_w), perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$), normalize edilmiş kesme gerilmesi (v_n) ve etkin kesme boyu (L_v) ve perde uç bölgesinde boyuna donatı oranı (ρ_b) olarak sıralanmaktadır (Şekil 4.28.).



Şekil 4.28. Çelik birim uzama (ε_{su}) modelinin SHAP önem grafiği

SHAP’da yorumlama grafiklerinden özet grafiğinde modelin genel davranışı detaylı olarak sunulur. Her bir parametrenin artmasının ya da azalmasının çelik birim uzamasını (ε_{su}) nasıl etkilediği renk değişimleriyle gösterilmektedir ve parametre çizgisinin kalınlığı SHAP aralığındaki veri yoğunluğunu gösterir (Şekil 4.29.). Perde uç bölgesinde sargı donatısı oranı (ρ_s) azaldıkça çelik birim uzaması azalmakta ve orta düzey değerler çelik birim uzamasını artırma eğilimindedir. Eksenel yük oranı (P/P_o) azaldıkça çelik birim uzaması artmakta ve orta düzey değerler çelik birim uzamasını azaltma eğilimindedir. Perde boyu (l_w) azaldıkça çelik birim uzaması artmakta ve orta düzey değerler çelik birim uzamasını artırma eğilimindedir. Perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) azaldıkça genel olarak çelik birim uzaması azalmakta ve orta düzey değerler çelik birim uzamasını artırma eğilimindedir. Normalize edilmiş kesme gerilmesi (v_n) azaldıkça

çelik birim uzaması artmakta ve orta düzey değerler çelik birim uzamasını azaltma eğilimindedir. Etkin kesme boyu (L_v) azaldıkça çelik birim uzaması artmakta ve orta düzey değerler çelik birim uzamasını azaltma eğilimindedir. Boyuna donatı oranı (ρ_b) azaldıkça çelik birim uzaması azalmakta ve orta düzey değerler çelik birim uzamasını artırma eğilimindedir.



Şekil 4.29. Çelik birim uzaması (ε_{su}) modelinin SHAP özet grafiği

SHAP’da yorumlama grafiklerinden şelale grafiğinde tek bir tahminde parametrelerin etkisi gösterilir. Veri setinde yer alan dört farklı perde boyu özelinde diğer parametrelerin etkisini ölçmek amacıyla aynı değerdeki örneklerin şelale grafikleri çizdirildi. Perde boyu (l_w) 3 m ve 5 m olan perdelerde; perde uç bölgesinde sargı donatısı oranının (ρ_s), perde boyu arttıkça çelik birim uzamasına (ε_{su}) pozitif katkısı azalmaktadır. Perde boyu (l_w) 2 m, 3 m ve 5 m olan perdelerde; etkin kesme boyunun (L_v) perde boyu arttıkça çelik birim uzamasına pozitif katkı sağlamaktadır. Perde boyu (l_w) 2 m ve 3 m, olan perdelerde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımının ($\rho_{tf}/f_c=0,021$) perde boyu arttıkça çelik birim uzamasına negatif katkısı azalmaktadır. Perde boyu (l_w) 5 m ve 8 m, olan perdelerde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımının ($\rho_{tf}/f_c=0,011$) perde boyu arttıkça beton çelik birim uzamasına negatif katkısı azalmaktadır. Perde boyu (l_w) 2 m, 5 m ve 8 m olan


perdelerde; boyuna donatı oranını (ρ_b) perde boyu arttıkça çelik birim uzamasına negatif katkı sağlamaktadır (Şekil 4.30.).






SHAP’da yorumlama grafiklerinden bağımlılık grafiğinde; bir girdi değerinin doğrusal mı, yoksa daha karmaşık bir etkiye mi sahip olduğunu göstermenin yanı sıra etkileşimde olduğu bir diğer girdi değeriyle beraber çıktı üzerindeki etkisi de ortaya konulur.

Şekil 4.31. grafiğinde; perde boyunda (l_w) eksenel yük oranının (P/P_o) negatif katkı sağlayan değerlerinin etkisi yoğun olarak görülmektedir. Perde boyu 2 m ve 3 m olan perdelerde eksenel yük oranı azaldıkça çelik birim uzaması (ϵ_{su}) artmaktadır. Perde boyu 8 m olan perdelerde eksenel yük oranı azaldıkça çelik birim uzaması azaltmaktadır.




Şekil 4.31. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; perde boyu (l_w) ve eksenel yük oranı (P/P_o) ilişkisi.

Şekil 4.32. grafiğinde; etkin kesme boyunda (L_v) sargı donatısı oranının (ρ_s) çelik birim uzamasına (ϵ_{su}) etkisi farklı durumlara göre değişmektedir.




Şekil 4.32. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; perde etkin kesme boyu (L_v) ve sargı donatısı oranı (ρ_s).

Şekil 4.33. grafiğinde; eksenel yük oranında (P/P_o) perde boyuna (l_w) göre bir gruplanma görülmektedir. Eksenel yük oranı 0,20'den küçük olduğu durumlarda genel olarak perde boyu arttıkça çelik birim uzaması (ϵ_{su}) azalmaktadır. Eksenel yük oranının diğer değerlerinde perde boyunun etkisi farklılık göstermektedir.




Şekil 4.33. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; eksenel yük oranı (P/P_o) ve perde boyu (l_w) ilişkisi.

Şekil 4.34. grafiğinde; boyuna donatı oranında (ρ_b) sargı donatısı oranına (ρ_s) göre bir gruplanma olduğu görülmektedir. Boyuna donatı oranı 0,005 değerinde sargı donatısı oranı arttıkça çelik birim uzaması (ϵ_{su}) azalmaktadır. Boyuna donatı oranı 0,02 değerinde sargı donatısı oranı arttıkça çelik birim uzaması artmaktadır.




Şekil 4.34. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; boyuna donatı oranı (ρ_b) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.35. grafiğinde; sargı donatısı oranında (ρ_s) eksenel yük oranının (P/P_o) etkisi farklı değerlere göre değişmektedir. Sargı donatısı oranı 0,002'den küçük olduğu değerlerde eksenel yük oranı arttıkça çelik birim uzaması (ϵ_{su}) artmaktadır. Diğer durumlarda genel olarak eksenel yük oranının orta düzey değerleri ve negatif katkı sağladığı değerler çelik birim uzaması üzerinde etkili olmaktadır.




Şekil 4.35. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; sargı donatısı oranı (ρ_s) ve eksenel yük oranı (P/P_o) ilişkisi.

Şekil 4.36. grafiğinde; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımında (ρ_{tf}/f_c) sargı donatısı oranına (ρ_s) göre bir gruplanma görülmektedir. Bu etkileşimin çelik birim uzamasına (ϵ_{su}) yansması ρ_{tf}/f_c 'nin farklı değerlerine göre değişmektedir.



Şekil 4.36. Çelik birim uzaması (ε_{su}) modelinin SHAP bağımlılık grafiği; perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve sargı donatısı oranı (ρ_s) ilişkisi.

Şekil 4.36. grafiğinde; normalize edilmiş kesme gerilmesinde (v_n) ve eksenel yük oranının (P/P_o) negatif katkı sağladığı değerlerin çelik birim uzaması (ε_{su}) üzerinde daha etkili olduğu görülmektedir.



Şekil 4.37. Çelik birim uzaması (ϵ_{su}) modelinin SHAP bağımlılık grafiği; normalize edilmiş kesme gerilmesi (ν_n) ve eksenel yük oranı (P/P_o) ilişkisi.


4.1.10. Modellerin performans değerlendirmesi

Çalışmada kurulan tüm modellerin tahmin-gerçek değer grafikleri (a) ve kalıntı grafikleri (b) aşağıda sıralandı. Karar Ağacı grafiğinde tek bir ağaç üzerinden model kurulduğu için saçılımı gruplaşmalar görülmektedir. Bu durum karar ağacının doğal yapısının etkisidir (Şekil 4.38a). Rastgele Arama modelinde birden fazla ağaç ile tahmin yapıldığı için Karar Ağacına kıyasla daha iyi bir performans ortaya çıkmaktadır (Şekil 4.39a). Uyarlanabilir Attırma grafiğinde de Karar Ağacına benzer bir durum görülmekte ve tahminin gerçek değeri yansıtmada başarısız olduğu görülmektedir (Şekil 4.40a). Bu durumun belirgin sebeplerinden biri algoritmada varsayılan ağaç derinliğinin 3 olarak belirlenmesi. Herhangi bir hiperparametre ayarı yapılmadığı için girdi parametreleri arasında net bir ilişki kurulmadan sonuca varılmasının yansıması olarak performans kötü çıkmaktadır. Aşırı Gradyan Arttırma modelinin (Şekil 4.41a) iyi performans gösterdiği ancak hiperparametre optimizasyonunun performansı iyileştirmede etkin olduğu görülmektedir. Her iki hiperparametre optimizasyon tekniğinin performansı da yakın olmakla beraber Optuna ile daha geniş bir aralık üzerinde inceleme yapılabilmüş ve hız olarak avantaj sağlamıştır (Şekil 4.42a-43a). Plastik dönme üzerine yapılan detaylı


inceleme neticesinde en iyi performans gösteren Aşırı Gradyan Arttırma-Optuna (XGBoost-Optuna) modeli beton birim kısalma ve çelik birim uzaması şekil değiştirme değerlerinin modellenmesinde kullanıldı (Şekil 4.44a-45a).

Modellere ait kalıntı grafiklerinde (Şekil 4.38b-39b-40b-41b-42b-43b-44b-45b) her bir modelin gerçek değer ve tahmin değeri arasındaki farklar ve saçılımın yoğun olduğu bölgeler gösterilmektedir.







Şekil 4.38. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile karar ağacı dağılım grafiği (a) ve kalıntı grafiği (b).




Şekil 4.39. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile rastgele orman dağılım grafiği (a) ve kalıntı grafiği (b).




Şekil 4.40. Plastik dönme (θ_p) ANSYS sonlu eleman değeri ile uyarlanabilir arttırma dağılım grafiği (a) ve kalıntı grafiği (b).




Şekil 4.41. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile aşırı gradyan artırma dağılım grafiği (a) ve kalıntı grafiği (b).




Şekil 4.42. Plastik dönme (θ_p), ANSYS sonlu eleman değeri ile aşırı gradyan arttırma-rastgele arama dağılım grafiği (a) ve kalıntı grafiği (b).



Şekil 4.43. Plastik dönme (θ_p) ANSYS sonlu eleman değeri ile aşırı gradyan artırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).



Şekil 4.44. Beton birim kısalması (ϵ_{cu}) ANSYS sonlu eleman değeri ile aşırı gradyan artırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).



Şekil 4.45. Çelik birim uzaması (ϵ_{su}) ANSYS sonlu eleman değeri ile aşırı gradyan artırma-optuna dağılım grafiği (a) ve kalıntı grafiği (b).

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Modeller oluşturulurken plastik dönme veri seti %70 eğitim %30 test, birim şekil değiştirme veri setleri %80 eğitim %20 test olarak bölündü. Modellerin başarısına karar verilirken MAE ve RMSE hata metrikleri, R^2 değerinin eğitim ve test veri setindeki tutarlılığına ve 10-cv R^2 'ye bakıldı. Eğitim veri setinde aşırı öğrenme durumunu gösteren belirgin özelliklerden biri eğitim veri seti R^2 değerinin, 1'e yakın sonuç vermesi ve test veri setindeki R^2 değeri ile arasında büyük farklılığın olması; hata metrikleri, MAE ve RMSE değerlerinin birbirinden çok farklı çıkması. RMSE değeri her zaman MAE değerine eşit veya ondan daha büyük olmalıdır. Bu, modelde kullanılan veri setindeki hataların benzer ve küçük değerlere sahip olduğunun göstergesidir. Fakat RMSE değeri MAE değerinden çok büyük olursa veri setindeki bazı noktalarda büyük ve aykırı hatalar yapıldığı görülür. AdaBoost modelindeki durum ise eksik öğrenmenin göstergesidir. Test veri seti belirleme katsayısı eğitim veri setinden daha az çıkmıştır (Çizelge 4.1.).

Çizelge 4.1. Plastik dönme modellerinin performans değerlendirmeleri

Model	MAE _{eğ}	RMSE _{eğ}	R^2 _{eğ}	MAE _{te}	RMSE _{te}	R^2 _{te}	10-cv R^2
Karar Ağacı-RS	0,003	0,005	0,931	0,004	0,006	0,877	0,849
Rastgele Orman	0,001	0,002	0,985	0,003	0,005	0,903	0,889
AdaBoost	0,008	0,009	0,740	0,008	0,009	0,727	0,694
XGBoost	0,001	0,002	0,988	0,003	0,005	0,916	0,898
XGBoost-RS	0,002	0,002	0,982	0,003	0,005	0,920	0,903
XGBoost- Optuna-SHAP	0,002	0,003	0,968	0,003	0,005	0,917	0,913

Çizelge 4.2. Beton birim kısalması modelinin performans değerlendirmeleri

Model	MAE _{eğ}	RMSE _{eğ}	R^2 _{eğ}	MAE _{te}	RMSE _{te}	R^2 _{te}	10-cv R^2
XGBoost- Optuna-SHAP	0,001	0,001	0,986	0,002	0,003	0,877	0,899

Çizelge 4.3. Çelik birim uzaması modelinin performans değerlendirmeleri

Model	MAE _{eğ}	RMSE _{eğ}	R^2 _{eğ}	MAE _{te}	RMSE _{te}	R^2 _{te}	10-cv R^2
XGBoost- Optuna-SHAP	0,002	0,003	0,990	0,005	0,005	0,919	0,926

Modelelerin performans değerlendirmesinde; eğitim ve test veri seti için hata metriklerinin (MAE, RMSE) ve R^2 'lerin birbirleriyle uyumlu olması ve 10-cv R^2 'nin başarılı bir sonuç ortaya koyması modellerin veri setini iyi yansıttığını göstermektedir.

Betonarme perdelerin şekil değiştirme değerleri; plastik dönme, beton birim kısalması ve çelik birim uzaması makine öğrenmesi modelleri ve bu modellerde yer alan pramatreler, regresyon değerlendirme kriterleri aşağıdaki çizelgede özetlendi.

Çizelge 4.4. Betonarme perdelerde şekil değiştirme makine öğrenmesi model detayları

Sınır Değeri	Model	Parametreler	R^2	10-cv R^2
θ_p	XGBoost-Optuna-SHAP	$l_w, L_v, P/P_o, \rho_s, \rho_t f_y/f_c, v_n$	0,954	0,913
ϵ_{cu}	XGBoost-Optuna-SHAP	$l_w, L_v, P/P_o, \rho_b, \rho_s, \rho_t f_y/f_c, v_n$	0,9655	0,899
ϵ_{su}	XGBoost-Optuna-SHAP	$l_w, L_v, P/P_o, \rho_b, \rho_s, \rho_t f_y/f_c, v_n$	0,9758	0,926

4.1.11. Denklemler

Toplamsal güç yasası regresyon modeli ile girdi değerleri ve çıktı değeri arasındaki ilişki ortaya kondu. Denklem yapısındaki ilişkiler Python'daki *scipy.optimize.curve_fit* doğrusal olmayan en küçük kareler yöntemi kullanılarak tahmin edildi. Python'da *scipy.optimize.curve_fit* gibi optimizasyon fonksiyonları kullanılarak denklem üretirken veri setindeki girdi değerleri MinMaxScaler [0, 1] gibi yöntemlerle ölçeklendirilmelidir. Bu şekilde optimizasyon algoritması kararlı hale gelerek her bir girdi değerini sayısal büyüklüğüne göre değil de katkısına göre dikkate almış olur.

Model sonucunda elde edilen tahmin değeri veri setine entegre edilerek yeni bir veri seti oluşturuldu. Bu veri setinden denklem üretildi. Daha sonra ANSYS sonlu eleman modelinden elde edilen ilk veri seti içinde denklem üretildi. Bu iki denklem birbirleri ile kıyaslandığında ML modelinin performans sınırlarını iyileştirdiği görüldü.

Denklemlerle hesaplanan çıktı değeri ve gerçek çıktı değeri arasındaki ilişki incelendiğinde negatif değerler görüldü (Şekil 4.46-47-48). Bunun nedeni, seçilen toplamsal güç yasası regresyon modelinin ve *scipy.optimize.curve_fit* doğrusal olmayan en küçük kareler yönteminin negatif öngörüler üretebilmesinden kaynaklanmaktadır. Model yapısında tahmin değeri için bir kısıt yer almaz, bu sebeple de tahmin değerinin fiziksel olarak 0'dan küçük olamayacağını bilmez. *scipy.optimize.curve_fit* yöntemi tüm veri noktaları üzerindeki ortalama hatayı (RMSE) en aza indirecek şekilde çalışır. Bu nedenle gerçek değer 0'a çok yakın olduğu durumlarda, algoritma genel uyumu iyileştirmek için, negatif terimlerin baskın gelmesine izin vererek tahmini 0'ın altına düşürebilir ve pozitif terimler bu negatif etkiyi dengeleyemediğinde sonuç eksi çıkar.

Çalışmada önerilen toplamsal güç yasası regresyon modeli denklemleri verinin büyük bir kısmındaki varyansı başarılı bir şekilde açıklamış olsada, modelin yapısı gereği çıktının pozitif olması gerektiği yönünde fiziksel bir kısıt barındırmamaktadır. Bu durum, özellikle düşük şekil değiştirme sınırların tahminlerinde negatif değerler üretebilmektedir. Bu nedenle, modellerin geçerliliği tahmin $\geq$ 0 bölgesi ile sınırlandırılmalıdır.

Plastik dönme için dağılım incelendiğinde (Şekil 4.46.) özellikle $lw=8$ m, $\rho_s < 0,003$ ve $P/P_o \geq 0,35$ durumlarında denklemlerle negatif değerler tahmin edilmektedir. Dağılım grafiğinde üstte ayrı bir grup olarak yer alan verilerin ise $lw=2$ m, perde uç bölgesinde sargı aralığı (s)= 50 mm ve $P/P_o < 0,1$ olarak görüldü. Grafik bütün olarak ele alındığında saçılımın; $lw=2$ ve 3 m, $P/P_o < 0,25$ ve $\rho_s > 0,003$ olduğu durumlarda daha yoğun olduğu görüldü.


Beton birim kısalması ve çelik birim uzamasında (Şekil 4.47-48) özellikle $lw=8$ m, $\rho_s < 0,003$, $\rho_b < 0,04$ ve $P/P_o \geq 0,35$ durumlarında denklemlerle negatif değerler tahmin edilmektedir. Şekil 4.47.'de saçılımın genellikle $lw=2$ ve 3 m, $\rho_s > 0,003$, $P/P_o > 0,10$ ve $\rho_b > 0,005$ olduğu durumlarda ve Şekil 4.48.'de saçılımın genellikle $lw=2$ ve 3 m, $\rho_s > 0,003$, $P/P_o < 0,25$ ve $\rho_b > 0,005$ olduğu durumlarda daha yoğun olduğu görüldü.

Çizelge 4.5. Betonarme perdelerin şekil değiştirme değerleri için toplamsal güç yasası modeli ile üretilen denklemler.


DENKLEM OLUŞTURMA YÖNTEMİ	
XGBoost-Optuna Modeli	
Sınır Değeri	Denklem
θ_b	$\theta_{p-M} = (0.0273) - 0.0088(l_w - 2)^{0.476} + 0.5 \times 10^{-4} (L_v - 6)^{1.168} - 0.0412 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{0.967} + 0.6928(\rho_s - 0.0012)^{0.638}$ $- 0.0349 \left(\left(\rho_i \frac{f_y}{f_c} \right) - 0.011 \right)^{2.600} - 0.0546(\nu_n - 0.0368)^{1.917}$
ε_{cu}	$\varepsilon_{cu-M} = (-0.0319) - 0.0045(l_w - 2)^{0.615} + 0.0388(L_v - 6)^{0.003} - 0.0719 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{3.933} + 0.0146(\rho_b - 0.005)^{0.585}$ $+ 0.0689(\rho_s - 0.0012)^{0.381} + 0.0174 \left(\left(\rho_i \frac{f_y}{f_c} \right) - 0.011 \right)^{0.332} - 0.0270(\nu_n - 0.0368)^{2.723}$
ε_{su}	$\varepsilon_{su-M} = (0.0369) - 0.0002(l_w - 2)^{2.248} - 0.0067(L_v - 6)^{0.461} - 0.0885 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{1.023} + 0.1391(\rho_b - 0.005)^{0.682}$ $+ 0.5610(\rho_s - 0.0012)^{0.502} + 0.0408 \left(\left(\rho_i \frac{f_y}{f_c} \right) - 0.011 \right)^{0.234} - 0.1362(\nu_n - 0.0368)^{1.257}$

Çizelge 4.5. (devam)


DENKLEM OLUŞTURMA YÖNTEMİ	
ANSYS Modeli	
Sınır Değeri	Denklem
θ_b	$\theta_{P-ANSYS} = (0.0273) - 0.0088(l_w - 2)^{0.478} + 0.8 \times 10^{-4} (L_v - 6)^{1.111} - 0.0416 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{0.946} + 0.6486(\rho_s - 0.0012)^{0.625}$ $- 0.0330 \left(\left(\rho_t \frac{f_y}{f_c} \right) - 0.011 \right)^{2.819} - 0.0591(\nu_n - 0.0368)^{2.006}$
ε_{cu}	$\varepsilon_{cu-ANSYS} = (-0.0276) - 0.0046(l_w - 2)^{0.608} + 0.0342(L_v - 6)^{0.003} - 0.0775 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{3.971} + 0.0176(\rho_b - 0.005)^{0.608}$ $+ 0.0673(\rho_s - 0.0012)^{0.377} + 0.0187 \left(\left(\rho_t \frac{f_y}{f_c} \right) - 0.011 \right)^{0.335} - 0.0302(\nu_n - 0.0368)^{2.670}$
ε_{su}	$\varepsilon_{su-ANSYS} = (0.0353) - 0.0002(l_w - 2)^{2.450} - 0.0067(L_v - 6)^{0.467} - 0.0899 \left(\left(\frac{P}{P_o} \right) - 0.0216 \right)^{1.021} + 0.1563(\rho_b - 0.005)^{0.694}$ $+ 0.5507(\rho_s - 0.0012)^{0.498} + 0.0456 \left(\left(\rho_t \frac{f_y}{f_c} \right) - 0.011 \right)^{0.237} - 0.1440(\nu_n - 0.0368)^{1.258}$



Şekil 4.46. Plastik dönme (θ_p) aşırı gradyan artırma-optuna modeli ile Çizelge 4.5.'te verilen plastik dönmenin (θ_{p-ML}) kıyaslanması (a) ve plastik dönme ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen plastik dönmenin ($\theta_{p-ANSYS}$) kıyaslanması (b).



Şekil 4.47. Beton birim kısalması (ϵ_{cu}) aşırı gradyan artırma-optuna modeli ile Çizelge 4.5.'te verilen Beton birim kısalması (ϵ_{cu-ML}) kıyaslanması (a) ve beton birim kısalması ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen beton birim kısalması ($\epsilon_{cu-ANSYS}$) kıyaslanması (b).



Şekil 4.48. Çelik birim uzaması (ϵ_{su}) aşırı gradyan artırma-optuna modeli ile Çizelge 4.5.'te verilen çelik birim uzaması (ϵ_{su-ML}) kıyaslanması (a) ve çelik birim uzaması ANSYS sonlu eleman yöntemi ile Çizelge 4.5.'te verilen çelik birim uzaması ($\epsilon_{su-ANSYS}$) kıyaslanması (b).

5. SONUÇ ve ÖNERİLER

Bu doktora çalışmasında, betonarme perdelerin şekil değiştirme sınırlarından plastik dönme (θ_p), nihai şekil değiştirme anında beton birim kısalması (ε_{cu}) ve nihai şekil değiştirme anında çelik birim uzaması (ε_{su}) değerleri makine öğrenmesi yöntemleriyle tahmin edildi. Çalışmada kullanılan veri, “Betonarme Perdelerin Hasar Sınırlarının Analitik Olarak Belirlenmesi” başlıklı yüksek lisans tezim kapsamında ANSYS ile oluşturulan 2, 3, 5 ve 8 metrelik perdelerin çeşitli parametreler altında yürütülen sayısal analizlerinden derlendi. Toplam 2600 analiz sonucunda elde edilen çıktılarda, veri setindeki inceleme neticesinde ML’de kullanılacak örnek sayısı 2548 olacak şekilde güncellendi.

Dört aşamalı boru hattında sırasıyla; veri analizi, modelleme–optimizasyon, değerlendirme–yorumlama ve denklem üretimi gerçekleştirildi. İlk aşamada veri setinin dağılım özellikleri incelendi. Korelasyon matrisi, Sertkaya (2018) ve literatürden yararlanılarak çıktı üzerinde daha etkin olan parametreler seçildi. Plastik dönme için: perde uç bölgesinde sargı donatısı oranı (ρ_s), eksenel yük oranı (P/P_o) ve perde boyu (l_w), normalize edilmiş kesme gerilmesi (ν_n) perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) ve etkin kesme boyu (L_v); beton birim kısalması ve çelik birim uzaması için: ρ_s , l_w , P/P_o , $\rho_t f_y / f_c$, ν_n , perde uç bölgesinde boyuna donatı oranı (ρ_b) ve L_v parametreleri seçildi.

İkinci aşamada, plastik dönme üzerinde ağaç tabanlı öğrenme algoritmasını esas alan dört yöntem; Karar Ağacı (Decision Tree-DT), Rastgele Orman (Random Forest-RF) ve Uyarlanabilir Arttırma (Adaptive Boosting-AdaBoost) ve Aşırı Gradyan Arttırma (Extreme Gradient Boosting-XGBoost) ile oluşturulan modeller herhangi bir hiperparametre optimizasyonu olmaksızın varsayılan değerleri dikkate alınıp karşılaştırmalı olarak incelendi. Ancak DT modelinde belirgin bir aşırı uyum ($R^2_{eg}=1$) ortaya çıktığı için Rastgele Arama (Randomized Search-RS) hiperparametre optimizasyonu yapıldı.

Üçüncü aşamada modeller, eğitim-test ayrımı altında genelleme başarısı odaklı karekök ortalama kare hata (RMSE), ortalama mutlak hata (MAE), belirleme katsayısı

(R^2) ve 10 katlı çapraz doğrulama (10-cv R^2) performans kriterleri ile değerlendirildi. İnceleme sonunda modellerin başarı sıralaması; XGBoost (10-cv $R^2=0,898$), Rastgele Orman (10-cv $R^2=0,889$), Karar Ağacı (10-cv $R^2=0,849$) ve AdaBoost (10-cv $R^2=0,694$) şeklindedir. Adaboost'un diğerlerine göre düşük performans göstermesindeki en belirgin sebep ağaç derinliğinin varsayılan olarak 3 alınmasıdır. En başarılı olan XGBoost modelinde; model veri uyumunu en iyi düzeye taşımak ve aşırı-eksik öğrenme riskini azaltmak için iki farklı hiperparametre optimizasyon tekniği RS ve Optuna kullanıldı. XGBoost-Optuna (10-cv $R^2=0,913$) modeli XGBoost-RS (10-cv $R^2=0,903$) modelinden daha iyi bir performans gösterdi. Nihai model olarak karar verilen XGBoost-Optuna, beton birim kısalması ve çelik birim uzaması tahmininde de kullanıldı. Seçilen modelin sonuçları SHAP analiziyle yorumlanarak değişkenlerin göreceli etkileri ve olası etkileşimleri ortaya kondu.

SHAP analizi sonucunda perde şekil değiştirmeleri üzerine parametrelerin etkisi aşağıda sıralanmaktadır.

- Perde plastik dönme açısı (θ_p) üzerinde parametrelerin etkisi sırasıyla; perde uç bölgesinde sargı donatısı oranı (ρ_s), eksenel yük oranı (P/P_o) ve perde boyu (l_w), normalize edilmiş kesme gerilmesi (v_n) daha az etkileyen parametreler ise perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı (ρ_{tf}/f_c) ve etkin kesme boyu (L_v) şeklinde sıralanmaktadır.

Bu parametrelerin plastik dönmeye etkileri; perde uç bölgesinde sargı donatısı oranı (ρ_s), arttıkça plastik dönme artmakta, eksenel yük oranı (P/P_o) arttıkça plastik dönme azalmakta, perde boyu (l_w) arttıkça plastik dönme azalmakta, normalize edilmiş kesme gerilmesi (v_n) yaklaşık 0,15 seviyesine kadar arttıkça plastik dönme artmakta ve bu seviyeden sonra arttıkça plastik dönme azalmakta, perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı (ρ_{tf}/f_c) genel olarak bir seviyeye kadar arttıkça plastik dönme artmakta ve bu seviyeden sonra arttıkça plastik dönme azalmakta ve etkin kesme boyu (L_v) genel olarak bir seviyeye kadar arttıkça plastik dönme artmakta ve bu seviyeden sonra arttıkça plastik dönme azalmakta şeklindedir.

Parametrelerin birbirleriyle etkileşiminin plastik dönmeye yansımaları incelendiğinde parametrelerin belirli aralıklarına göre farklı sonuçlar tespit edildi. Genel bir sonuç olarak; perde boyundaki (l_w) artışa bağlı olarak sargı donatısı oranı (ρ_s) arttıkça plastik dönmede azalmaya sebep olmaktadır.

- Beton birim kısalması (ϵ_{cu}) üzerinde parametrelerin etkisi sırasıyla; perde uç bölgesinde sargı donatısı oranı (ρ_s), perde boyu (l_w), eksenel yük oranı (P/P_o), perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı (ρ_{tfy}/f_c), normalize edilmiş kesme gerilmesi (ν_n), perde uç bölgesinde boyuna donatı oranı (ρ_b) ve etkin kesme boyu (L_v) olarak sıralanmaktadır.

Bu parametrelerin beton birim kısalmasına etkileri; perde uç bölgesinde sargı donatısı oranı (ρ_s) 0,006 seviyesine kadar arttıkça beton birim kısalması artmakta ve bu seviyeden sonra sabit etkilemekte, perde boyu (l_w) arttıkça beton birim kısalması azalmakta, eksenel yük oranı (P/P_o) 0,27 seviyesine kadar arttıkça beton birim kısalması artmakta ve bu seviyeden sonra arttıkça beton birim kısalmasını azaltmakta, perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı (ρ_{tfy}/f_c) arttıkça beton birim kısalması artmakta, normalize edilmiş kesme gerilmesi (ν_n) 0,15 seviyesine kadar arttıkça beton birim kısalması artmakta bu seviyeden sonra arttıkça beton birim kısalması azalmakta, boyuna donatı oranı (ρ_b) arttıkça beton birim kısalması artmakta, etkin kesme boyu (L_v) genel olarak bir seviyeye kadar arttıkça beton birim kısalması artmakta ve bu seviyeden sonra arttıkça beton birim kısalması azalmakta şeklindedir. Parametrelerin birbirleriyle etkileşiminin beton birim kısalmasına yansımaları incelendiğinde parametrelerin belirli aralıklarına göre farklı sonuçlar tespit edildi.

- Çelik birim uzaması (ϵ_{su}) üzerinde parametrelerin etkisi sırasıyla; perde uç bölgesinde sargı donatısı oranı (ρ_s), eksenel yük oranı (P/P_o), perde boyu (l_w), perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı (ρ_{tfy}/f_c), normalize edilmiş kesme gerilmesi (ν_n),

etkin kesme boyu (L_v) ve perde uç bölgesinde boyuna donatı oranı (ρ_b) olarak sıralanmaktadır.

Bu parametrelerin çelik birim uzamasına etkileri; perde uç bölgesinde sargı donatısı oranı (ρ_s) arttıkça çelik birim uzaması artmakta, eksenel yük oranı (P/P_o) arttıkça çelik birim uzaması azalmakta, perde boyu (l_w) arttıkça çelik birim uzaması azalmakta, perde yatay gövde donatısı oranının, donatı çeliği akma gerilmesinin beton basınç dayanımına oranı ile çarpımı ($\rho_t f_y / f_c$) genel olarak bir seviyeye kadar arttıkça çelik birim uzaması artmakta ve bu seviyeden sonra arttıkça çelik birim uzaması azalmakta, normalize edilmiş kesme gerilmesi (v_n) 0,15 seviyesine kadar arttıkça çelik birim uzaması artmakta bu seviyeden sonra arttıkça çelik birim uzaması azalmakta, etkin kesme boyu (L_v) arttıkça çelik birim uzaması azalmakta, boyuna donatı oranı (ρ_b) arttıkça çelik birim uzaması artmakta şeklindedir. Parametrelerin birbirleriyle etkileşiminin çelik birim uzamasına yansımaları incelendiğinde parametrelerin belirli aralıklarına göre farklı sonuçlar tespit edildi.

Son aşamada, modelin denklem formunu üretmek amacıyla toplamsal güç yasası regresyon modeli hem ML tahminleri üzerinde hem de gerçek ölçümlerde kurularak; ML yöntemiyle oluşturulan modelin etkisi incelendi. Böylece veri setini yansıtan ML tahminleri, pratikte kolayca kullanılabilir ve denetlenebilir bir ilişkiye dönüştürüldü. Toplamsal güç yasası regresyon modelinin yapısı gereği ortaya çıkan negatif tahmin değerlerinden dolayı modellerin geçerliliği tahmin ≥ 0 bölgesi ile sınırlandırıldı. ML Modelleme ile çıktı değerlerinin iyileştiği ve performans sınırlarını daha iyi yansıttığı görüldü.

Makine öğrenmesi modellerinin perde davranışını yansıtma noktasında uygulamalarla paralel bir sonuç verdiği görüldü. SHAP analiz yöntemiyle birçok parametrenin birbirleriyle etkileşimde olduğu tespit edildi. Ağaç tabanlı algoritmalarda etkileşimli olan parametreler dikkate alınarak model oluşturulduğu için veri setini en iyi yansıtan modelleme sisteminin bu olduğuna karar verildi. Denklem üretiminde, beton birim kısalması için yapılan çalışmada her iki veri setinin denklem formunda başarılı

olmadığı görüldü. Bu veri setinin birim kısalma davranışını yeterince yansıtmadığına karar verildi.

Bu doktora çalışması, bütüncül yaklaşımla hem tahmin doğruluğu hem de yorumlanabilirlik–aktarılabirlik açısından betonarme perdelerin şekil değiştirme sınırlarının belirlenmesine; veri setindeki örnek sayısında (2548) dikkate alındığında anlamlı bir katkı sundu.

- Betonarme perdelerde makine öğrenmesi modelleri kurulurken korelasyon matrisi tek başına kıstas olarak kabul edilmemeli, literatürle desteklenmeli. Korelasyonda etkisi düşük olarak belirlenen parametre diğer parametrelerle beraber dikkate alındığında daha yüksek bir etki gösterebilir.
- Beton birim kısalması için veri seti genişletilerek yeniden incelenmeli.
- Betonarme perdelerde perde boyu 8 metreden daha büyük perdeler için incelemeler yapılarak daha genel bir modelleme ortaya konmalıdır.

KAYNAKLAR

- Abdullah, S. A. and Wallace, J. W. 2019. Drift capacity of reinforced concrete structural walls with special boundary elements. *ACI Structural Journal*, 116(1), 183–204.
- Ahmed, S., Lee, Y., Hyun, S. H. and Koo, I. 2019. Unsupervised machine learning-based detection of covert data integrity assault in smart grid networks utilizing isolation forest. *IEEE Transactions on Information Forensics and Security*, 14(10), 2765-2777.
- Akiba, T., Sano, S., Yanase, T., Ohta, T. and Koyama, M. 2019. Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, 2623-2631.
- Aladsani, M., Burton, H., Abdullah, S. A. and Wallace, J. W. 2021. Machine learning driven drift capacity model for reinforced concrete walls. *ACI Convention Spring 2021-The Concrete Industry in the Era of Artificial*. 350, 16-20.
- Aladsani, M. A., Burton, H., Abdullah, S. A. and Wallace, J. W. 2022. Explainable machine learning model for predicting drift capacity of reinforced concrete walls. *ACI Structural Journal*, 119(3).
- Al-Mudhafar, W. J., Abbas, M. A. and Wood, D. A. 2022. Performance evaluation of boosting machine learning algorithms for lithofacies classification in heterogeneous carbonate reservoirs. *Marine and Petroleum Geology*, 145, 105886.
- Arlot, S. and Celisse, A. 2010. A survey of cross-validation procedures for model selection. *Statist. Surv.* 4, 40-79. DOI: 10.1214/09-SS054
- Arteta, C. A. 2015. Seismic response assessment of thin boundary elements of special concrete shear walls. PhD Thesis, Engineering – Civil and Environmental Engineering in the Graduate Division of the University of California, 190, Berkeley, United States of America.
- ASCE/SEI 41-13. 2013. Seismic Evaluation and Retrofit of Existing Buildings. American Society of Civil Engineers, 518, Reston, Virginia.
- Aydın, A. G. ve Tunçer, A. A. N. 2022. Aykırı değer tespit yöntemlerinin karşılaştırılması ve diğer ön işleme adımlarının otomatik makine öğrenmesi (automl) ile ilişkisinin incelenmesi. 14. Uluslararası Bilimsel Araştırmalar Kongresi, 21-22 Ağustos 2022, Bildiri Tam Metin Kitabı 106-112, Ankara.
- Bahri, Y., Dyer, E., Kaplan, J., Lee, J. and Sharma, U. 2024. Explaining neural scaling laws. *Proceedings of the National Academy of Sciences*, 121(27), 1-8.e2311878121.

- Bakouregui, A. S., Mohamed, H. M., Yahia, A. and Benmokrane, B. 2021. Explainable extreme gradient boosting tree-based prediction of load-carrying capacity of FRP-RC columns. *Engineering Structures*, 245, 112836.
- Barkhordari, M. S. and Massone, L. M. 2022. Failure mode detection of RC shear walls using ensemble deep neural networks. *International Journal of Concrete Structures and Materials*, 16(33).
- Bentéjac, C., Csörgő, A. and Martínez-Muñoz, G. 2021. A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54(3), 1937-1967.
- Bergstra, J. and Bengio, Y. 2012. Random search for hyper-parameter optimization. *The journal of machine learning research*, 13(1), 281-305.
- Bergstra, J., Bardenet, R., Bengio, Y. and Kégl, B. 2011. Algorithms for hyper-parameter optimization. *NeurIPS* 24, 2546–2554.
- Chen, BT., Chang, TP., Shih, JY. and Wang, J., 2009 Estimation of exposed temperature for fire-damaged concrete using support vector machine. *Computational Materials Science*, 44(3), 913-920.
- Chen, T. and Guestrin, C. 2016. Xgboost: A scalable tree boosting system. *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Proceedings Book, pp. 785-794, New York, United States of America.
- Chou, J.-S., Liu, C.-Y., Prayogo, H., Khasani, R. R., Gho, D. and Lalitan, G. G. 2022. Predicting nominal shear capacity of reinforced concrete wall in building by metaheuristics-optimized machine learning. *Journal of Building Engineering*, 61, 105046, 1-23.
- Chou, JS., Tsai, CF., Pham, AD. and Lu, YH., 2014. Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction Building Materials* 73, 771–80.
- Clauset, A., Shalizi, C. R. and Newman, M. E. J. 2009. Power-law distributions in empirical data. *SIAM Review*, 51(4), 661–703.
- Colab, <https://colab.research.google.com/>, Erişim Tarihi: 21.12.2023.
- DBYBHY. 2007. Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik. Bayındırlık ve İskan Bakanlığı, 166, Ankara.
- Dazio, A., Beyer, K. and Bachmann, H. 2009. Quasi-static cyclic tests and plastic hinge analysis of RC structural walls. *Engineering Structures*, 31(7), 1556-1571.
- Ding, J., Li, J., Xiao, C. and Qiao, B. 2024. Machine learning prediction model for boundary transverse reinforcement of shear walls. *Buildings*, 14(2), 427.

- Domingues, R., Filippone, M., Michiardi, P. and Zouaoui, J. 2018. A comparative evaluation of outlier detection algorithms: Experiments and analyses. *Pattern recognition*, 74, 406-421.
- Dong, J. and Chen, C. 2025, Hysteretic curve characteristics in rectangular shear walls predicted by machine learning. *Scientific Reports*, 15, 14114.
- Dunias, Z. S., Van Calster, B., Timmerman, D., Boulesteix, A.-L. and van Smeden, M. 2024. A comparison of hyperparameter tuning procedures for clinical prediction models: A simulation study. *Statistics in Medicine*, 43(6), 1119–1134.
- Eurocode 8. 2005. Design of Structures for Earthquake Resistance-Part 3: Assessment and Retrofitting of Buildings. Comité Européen de Normalisation, 89, Brussels, Belgium.
- Farzinpour, A., Dehcheshmeh, E. M., Broujerdian, V., Esfahani, S. N. and Gandomi, A. H. 2023. Efficient boosting-based algorithms for shear strength prediction of squat RC walls. *Case Studies in Construction Materials*, 18, e01928.
- FEMA 356. 2000. Prestandard and Commentary for the Seismic Rehabilitation of Buildings. Federal Emergency Management Agency, Washington, D.C..
- Géron, A. 2019. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. " O'Reilly Media, Inc.".851, Sebastopol, United States of America.
- GitHub, <https://github.com/>, Erişim Tarihi: 14.09.2025.
- González, MP. and Zapico JL., 2008. Seismic damage identification in buildings using neural networks and modal data. *Comput Struct.* 86, 416–426.
- Gui, G., Pan, H., Lin, Z., Li, Y. and Yuan, Z., 2017. Data-driven support vector machine with optimization techniques for structural health monitoring and damage detection. *KSCE J Civ Eng*, 523-534.
- Haro, A. G., Kowalsky, M., Chai, Y. H. and Lucier, G. W. 2018. Boundary elements of special reinforced concrete walls tested under different loading paths. *Earthquake Spectra*, 34(3), 1267-1288.
- Homafar, A., Nasiri, H. and Chelgani, S. C. 2022. Modeling coking coal indexes by SHAP-XGBoost: Explainable artificial intelligence method. *Fuel Communications*, 13, 100078.
- Jafari, A., Mirrashid, M., Hoult, R. D. and Zhou, Y. 2025. Plastic hinge length of RC shear walls: Practical approximation via machine learning and probabilistic assessment. *Engineering Failure Analysis*, 169, 109179.
- Ju, B. S., Kwag, S. and Lee, S. (2023). Performance-based drift prediction of reinforced concrete shear wall using bagging ensemble method. *Nuclear Engineering and Technology*, 55(8), 2747-2756.

Kaggle, <https://www.kaggle.com/>, Eriřim Tarihi: 14.09.2025.

Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., Gray, S., Radford, A., Wu, J. and Amodei, D. 2020. Scaling laws for neural language models. arXiv preprint arXiv:2001.08361. DOI: 10.48550/arXiv.2001.08361.

Kavzoęlu, T., ve ölkesen, İ. 2010. Karar ağaları ile uydu görüntülerinin sınıflandırılması. Harita Teknolojileri Elektronik Dergisi, 2(1), 36-45.

Kazaz, İ. 2010. Dynamic characteristics and performance assessment of reinforced concrete structural walls. PhD Thesis, The Graduate School of Natural and Applied Sciences of Middle East Technical University, 379, Ankara.

Kazaz, İ. 2011. Finite element analysis of shear-critical reinforced concrete walls. Computers and Concrete, 8 (2), 143-162.

Kazaz, İ. ve Gülkan, P. 2012. Süneklik düzeyi yüksek betonarme perdelerdeki hasar sınırları. İMO Teknik Dergi, 387, 6113-6140.

Kazaz, İ., Gülkan, P. and Yakut A. 2012. Performance limits for structural walls: an analytical perspective. Engineering Structures, 43, 105-119.

Kazaz, İ., Sertkaya, M. and Yakut, A. 2024. Effect of wall size on the rotation capacity of reinforced concrete structural walls. Journal of Structural Engineering, 150(4), 04024016.

Kazaz, İ., Yakut, A. and Gülkan, P. 2006. Numerical simulation of dynamic shear wall tests: A Benchmark Study. Computers and Structures, 84 (8), 549-562.

Khan, M. S., Peng, T., Akhlaq, H. and Khan, M. A. 2025. Comparative analysis of automated machine learning for hyperparameter optimization and explainable artificial intelligence models. IEEE Access, 13, 84966-84991.

Kuzubařlı, A., 2019. <https://ahmetkuzubasli.medium.com/neden-ilk-adresiniz-xgboost-75010416a583>, Eriřim Tarihi: 15.04.2019.

Lai, J. P., Lin, Y. L., Lin, H. C., Shih, C. Y., Wang, Y. P. and Pai, P. F. 2023. Tree-based machine learning models with optuna in predicting impedance values for circuit analysis. Micromachines, 14(2), 265.

Le Nguyen, K., Trinh, H. T., Banihashemi, S. and Pham, T. M. 2024. Machine learning approaches for lateral strength estimation in squat shear walls: A comparative study and practical implications. Expert Systems with Applications, 239, 122458.

Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A. and Talwalkar, A. 2018. Hyperband: A novel bandit-based approach to hyperparameter optimization. JMLR, 18, 1–52.

Liang, D. and Xue, F. 2023. Integrating automated ML and interpretability. Computers in Industry, 145, 103883.

- Liu, F. T., Ting, K. M. and Zhou, Z. H. 2008. Isolation forest. In 2008 eighth IEEE international conference on data mining, 413-422.
- Liu, X., Liu, T. and Feng, P. 2022. Long-term performance prediction framework based on XGBoost decision tree for pultruded FRP composites exposed to water, humidity and alkaline solution. *Composite Structures*, 284, 115184.
- Lundberg, S. M. and Lee, S. I. 2017. A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 4768 – 4777.
- Ma, C., Wang, W., Wang, S., Guo, Z. and Feng, X. 2023a. Prediction of shear strength of RC slender beams based on interpretable machine learning. *Structures*, 57, 105171.
- Ma, G., Qin, C., Hwang, H. J. and Zhou, Z. 2023b. Data-driven models for predicting tensile load capacity and failure mode of grouted splice sleeve connection. *Engineering Structures*, 289, 116236.
- Mangalathu, S., Jang, H., Hwang, S.-H. and Jeon, J.-S. 2020. Data-driven ML-based seismic failure mode identification of RC shear walls. *Engineering Structures*, 221, 111043.
- Mangalathu, S., Karthikeyan, K., Feng, D. C. and Jeon, J. S. 2022. Machine-learning interpretability techniques for seismic performance assessment of infrastructure systems. *Engineering Structures*, 250, 112883.
- Mangalathu, S., Shin, H., Choi, E. and Jeon, J. S. 2021. Explainable machine learning models for punching shear strength estimation of flat slabs without transverse reinforcement. *Journal of Building Engineering*, 39, 102300.
- Martins, D., 2021. <https://medium.com/data-science/xgboost-fine-tune-and-optimize-your-model-23d996fab663>, Erişim Tarihi: 14.05.2021.
- Massone, L. M., Jara, S. and Rojas, F. 2023. Experimental study on displacement capacity of reinforced concrete walls with varying cross-sectional slenderness. *Journal of Building Engineering*, 76, 107338.
- Meaney, C., Wang, X., Guan, J. and Stukel, T. A. 2025. Comparison of methods for tuning machine learning model hyper-parameters. *BMC Medical Research Methodology*, 25(1), 134.
- Mirzazade, A., Popescu, C. and Täljsten, B. 2023. Prediction of strain in embedded rebars for RC member, application of hybrid learning approach. *Infrastructures*, 8(4), 71.
- Mithrakumar, M., 2019. <https://medium.com/data-science/how-to-tune-a-decision-tree-f03721801680>, Erişim Tarihi: 12.11.2019.
- Moehle, J. P., Ghodsi, T., Hooper, J. D., Fields, D. C. and Gedhada, R. 2012. Seismic design of cast-in-place concrete special structural walls and coupling beams National Institute of Standards and Technology. (NIST GCR 11-917-11REV-1).

- Moradi, M. J. and Hariri-Ardebili, M. A. 2019. Developing a library of shear walls database and the neural network based predictive meta-model. *Applied Sciences*, 9(12), 2562.
- Muratlar, E., R., 2020. <https://www.veribilimiokulu.com/xgboost-nasil-calisir/>, Erişim Tarihi: 22.03.2020.
- Naderpour, H., Mirrashid, M. and Parsa, P. 2021. Failure mode prediction of reinforced concrete columns using machine learning methods. *Engineering Structures*, 248, 113263.
- Naser, M. Z. 2021. An engineer's guide to explainable Artificial Intelligence and Interpretable Machine Learning: Navigating causality, forced goodness, and the false perception of inference. *Automation in Construction*, 129, 103821.
- Ngo, N. T., Le, H. A. and Nguyen, Q. T. 2022. Axial strength prediction of steel tube confined concrete columns using a hybrid machine learning model. *Structures*, 36, 765-780.
- Nguyen, D. D., Tran, V. L., Ha, D. H., Nguyen, V. Q. and Lee, T. H. 2021. A machine learning-based formulation for predicting shear capacity of squat flanged RC walls. *Structures* 29, 1734-1747.
- Nguyen, H., Vu, T., Vo, T. P. and Thai, H. T. 2021. Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, 266, 120950.
- Oğuzlar, A. 2004. CART analizi ile hane halkı işgücü anketi sonuçlarının özetlenmesi. *İktisadi ve İdari Bilimler Dergisi*, 18(3-4), 79-90.
- Orakcal, K. and Wallace, J. W. (2006). Flexural modeling of reinforced concrete walls—Experimental verification. *ACI Structural Journal*, 103(2), 196–206.
- Tuychiev, B., 2019. <https://www.datacamp.com/tutorial/xgboost-in-python>, Erişim Tarihi: 08.11.2019.
- Pan, S., Zheng, Z., Guo, Z. and Luo, H. 2022. An optimized XGBoost method for predicting reservoir porosity using petrophysical logs. *Journal of Petroleum Science and Engineering*, 208, 109520.
- Pollalis, W., Kerby, C. and Pujol, S. 2024. On estimating the drift capacity of reinforced concrete walls with lap splices at their bases. *Bulletin of Earthquake Engineering*.
- PyCharm, 2022.2. <https://www.jetbrains.com/pycharm/>, Erişim Tarihi: 29.11.2024.
- Python 3.10. <https://www.python.org/>, Erişim Tarihi: 16.01.2022.
- Raschka, S. 2018. Model evaluation, model selection, and algorithm selection in machine learning. DOI: 10.48550/arXiv.1811.12808.

- Safaeian Hamzekolaei, N. and Barkhordari, M. S. 2024. Efficient ensemble learning-based models for plastic hinge length prediction of reinforced concrete shear walls. *Journal of Soft Computing in Civil Engineering*, 8(3), 128–154.
- Saitoğlu Sevimli, Y. 2015. Sınıflama ve Regresyon Ağaçları. Doktora Tezi. Marmara Üniversitesi Sosyal Bilimler Enstitüsü, 242, İstanbul.
- Salehi, H. and Burgueño, R., 2018. Emerging artificial intelligence methods in structural engineering. *Engineering structures*, 171, 170-189.
- Segura Jr, C. L. and Wallace, J. W. 2018. Seismic performance limitations and detailing of slender reinforced concrete walls. *ACI Structural Journal*, 115(3), 849-859.
- Segura, C. L., Arteta, C. A., Araujo, G. and Wallace, J. W. 2018, June. Flexural compression capacity of thin reinforced concrete structural walls. In *Proceedings of the 11th National Conference in Earthquake Engineering*, Earthquake Engineering Research Institute, Los Angeles, CA.
- Sertkaya, M., 2018. Betonarme Perdelerde Hasar Sınır Değerlerinin Analitik Olarak Belirlenmesi. Yüksek Lisans Tezi. Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü, 148, Erzurum.
- Sharma, U. and Kaplan, J. 2022. Scaling laws from the data manifold dimension. *Journal of Machine Learning Research*, 23(166), 1–34.
- Shegay, A. V., Motter, C. J., Elwood, K. J. and Henry, R. S. 2019. Deformation capacity limits for reinforced concrete walls. *Earthquake Spectra*, 35(3), 1189–1212.
- Shekhar, S., Bansode, A. and Salim, A. 2021, December. A comparative study of hyper-parameter optimization tools. In *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*, 1-6).
- Shekhar, S., Bansode, A. and Salim, A. 2022. A comparative study of hyper-parameter optimization tools. *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*. DOI: 10.1109/CSDE53843.2021.9718485.
- Shen, W. and Lin, D. K. 2018. A conjugate model for dimensional analysis. *Technometrics*, 60(1), 79-89.
- Shi, K., Shi, R., Fu, T., Lu, Z. and Zhang, J. 2024. A Novel Identification Approach Using RFECV–Optuna–XGBoost for Assessing Surrounding Rock Grade of Tunnel Boring Machine Based on Tunneling Parameters. *Applied Sciences*, 14(6), 2347.
- Song, Y. Y. and Ying, L. U. 2015. Decision tree methods: applications for classification and prediction. *Shanghai archives of psychiatry*, 27(2), 130.
- Srinivas, P. and Katarya, R. 2022. hyOPTXg: OPTUNA hyper-parameter optimization framework for predicting cardiovascular disease using XGBoost. *Biomedical Signal Processing and Control*, 73, 103456.

- Stumpf, M. P. H. and Porter, M. A. 2012. Critical truths about power laws. *Science*, 335(6069), 665–666.
- Su, R. K. L. and Wong, S. M. 2007. Seismic behaviour of slender reinforced concrete shear walls under high axial load ratio. *Engineering Structures*, 29(8), 1957-1965.
- Sulaiman, B. H., Ibrahim, A. M. and Imran, H. J. 2024. Study the efficiency of the XGBoost algorithm for squat RC wall shear strength prediction and parametric analysis. *Diyala Journal of Engineering Sciences*, 17(1), 103–123.
- Taffese, W. Z. and Sistonen, E., 2017. Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions. *Automation in Construction*, 77, 1-14.
- TBDY (Taslak). 2016. Türkiye Bina Deprem Yönetmeliği. Afet ve Acil Durum Yönetimi Başkanlığı, 360, Ankara.
- TBDY. 2018. Türkiye Bina Deprem Yönetmeliği. Afet ve Acil Durum Yönetimi Başkanlığı, 395, Ankara.
- Thai, H. T. 2022. Machine learning for structural engineering: A state-of-the-art review. *Structures*, 38, 448-491.
- Thomsen, J. H. and Wallace, J. W. 2004. Displacement-based design of slender reinforced concrete structural walls—Experimental verification. *Journal of Structural Engineering*, 130(4), 618–630.
- Tian, S., Ni, X. and Wang, Y. 2025. Seismic Shear Strength Prediction of Reinforced Concrete Shear Walls by Stacking Multiple Machine Learning Models. *Applied Sciences*, 15(5), 2268.
- Tirendaz Akademi. 2022.
<https://www.youtube.com/playlist?list=PLfMRLSpipmfuumcvO3fObVAUpSqYAcZmF>, Erişim Tarihi: 15.01.2022.
- Trinh, H. T., Pham, T. A., Tho, V. D. and Nguyen, D. H. 2024. The research explores the predictive capacity of the shear strength of reinforced concrete walls with different cross-sectional shapes using the XGBoost model. *PLOS ONE*, 19(11), e0312531.
- Tuna Deger, Z., Taskin, G. and Wallace, J. W. 2024. No more black-boxes: Estimate deformation capacity of non-ductile RC shear walls based on generalized additive models. *Bulletin of Earthquake Engineering*, 1-18.
- Wakjira, T. G., Alam, M. S. and Ebead, U. 2021. Plastic hinge length of rectangular RC columns using ensemble machine learning model. *Engineering Structures*, 244, 112808.
- Wallace, J. W. 2012. Behavior, design, and modeling of structural walls and coupling beams—Lessons from recent laboratory tests and earthquakes. *International Journal of Concrete Structures and Materials*, 6(1), 3–18.

- Wang, J., Cao, J. and Liu, Z. 2024. Unsupervised machine learning-based multi-attributes fusion dim spot subtle sandstone reservoirs identification utilizing isolation forest. *Geoenergy Science and Engineering*, 234, 212626.
- Welt, T. S. 2015. Detailing for compression in reinforced concrete wall boundary elements: Experiments, simulations, and design recommendations. University of Illinois at Urbana-Champaign, 530, United States of America.
- Welt, T. S., Massone, L. M., LaFave, J. M., Lehman, D. E., McCabe, S. L. and Polanco, P. 2017. Confinement behavior of rectangular reinforced concrete prisms simulating wall boundary elements. *Journal of Structural Engineering*, 143(4), 04016204.
- XGBoost, <https://xgboost.readthedocs.io/en/stable/index.html>, Eriřim Tarihi:14.09.2025.
- Xu, S., Zhu, J., Jiang, J. and Shui, P. 2020. Sea-surface floating small target detection by multifeature detector based on isolation forest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 704-715.
- Yahiaoui, A., Dorbani, S. and Yahiaoui, L. 2023. Machine learning techniques to predict the fundamental period of infilled reinforced concrete frame buildings. *Structures*, 54, 918-927.
- Yang, L. and Shami, A. 2020. On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316.
- Yang, I. T. and Prayogo, H. 2025. Interpretable Data-Augmented Machine Learning Framework for Robust Failure Mode Classification of RC Shear Wall. *Journal of Building Engineering*, 113960.
- Yangın, G. 2019. Xgboost ve Karar Ağacı Tabanlı Algoritmaların Diyabet Veri Setleri Üzerine Uygulaması. Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, 81, İstanbul.
- Yepmo, V., Smits, G., Lesot, M. J. and Pivert, O. 2024. Leveraging an Isolation Forest to Anomaly Detection and Data Clustering. *Data & Knowledge Engineering*, 151, 102302.
- Zaker Esteghamati, M., Flint, M. M. and Rodriguez-Marek, A. 2021. Application of surrogate models for performance-based evaluation of multi-story concrete buildings at early design. In *Proc. ICOSAR 2021*.
- Zhang, H., Cheng, X., Li, Y. and Du, X. 2022. Prediction of failure modes, strength, and deformation capacity of RC shear walls through machine learning. *Journal of Building Engineering*, 50, 104145.
- Zhou, Q., Zhu, F., Yang, X., Wang, F., Chi, B. and Zhang, Z. 2017. Shear capacity estimation of fully grouted reinforced concrete masonry walls using neural network and adaptive neuro-fuzzy inference system models. *Construction and building materials*, 153, 937-947.

- Zhu, H. and Randolph, M. F. 2011. Numerical analysis of a cylinder moving through rate-dependent undrained soil. *Ocean Engineering*, 38(7), 943-953.
- Zhu, Y. F., Yao, Y., Huang, Y., Chen, C. H., Zhang, H. Y. and Huang, Z. 2022. Machine learning applications for assessment of dynamic progressive collapse of steel moment frames. In *Structures* 36, 927-934.

