



**FRP SARGILI BETON ELEMANLARIN EKSENEL BASINÇ
DAYANIMININ TAHMİNİNDE FARKLI MAKİNE ÖĞRENİMİ
YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

Wajahat SAADAT

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2025

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Wajahat SAADAT

19/05/2025

FRP SARGILI BETON ELEMANLARIN EKSENEL BASINÇ DAYANIMININ
TAHMİNİNDE FARKLI MAKİNE ÖĞRENİMİ YÖNTEMLERİNİN
KARŞILAŞTIRILMASI
(Yüksek Lisans Tezi)

Wajahat SAADAT

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Haziran 2025

ÖZET

Bu araştırma hem yapısal güvenliği hem de tasarım verimliliğini artırmak amacıyla lifli polimer sargılı beton elemanların eksenel dayanımını tahmin etmek için makine öğrenimi modellerin verimliliğini karşılaştırmayı amaçlamaktadır. Ampirik hesaplamalar ve deneysel çalışmalar gibi geleneksel yöntemler genellikle önemli ölçüde zaman ve çaba gerektirir. Bu süreci kolaylaştırmak için çalışma, önceki araştırmalardan elde edilen verilere dayalı tahmin modelleri oluşturmak için Doğrusal Regresyon (DR), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA) gibi gelişmiş makine öğrenimi tekniklerini uygulamaktadır. Veriler, numune boyutları, beton dayanımı, FRP çekme dayanımı, sargı konfigürasyonları ve eksenel yük kapasiteleri gibi değişkenleri içerir. Veri ön işleme, eksik değerlerin ele alınmasını, aykırı değerlerin yönetilmesini ve özelliklerin normalleştirilmesini içermektedir. Boyut azaltma, bir torbalama modeli kullanılarak özellik önem analizi ve korelasyon analizi yoluyla gerçekleştirilmiştir. Modeller Ortalama Mutlak Hata, Ortalama Karesel Hata, Ortalama Karesel Hatanın Kökü ve R^2 skoru gibi temel performans ölçütleri kullanılarak değerlendirilmiştir. 85:15 eğitim-test ayrımı kullanılmış ve hiper parametreler grid arama yoluyla optimize edilmiştir. Sonuçlar, Doğrusal Regresyonun 0,781 R^2 skoru ile doğrusal olmayan ilişkileri yetersiz temsil ettiğini göstermektedir. RO modeli, karmaşık ilişkileri daha iyi yakalayarak 0,985 R^2 skoru elde etmiş; YSA modeli ise 0,991 R^2 ile en yüksek doğruluğu sağlamıştır. Bu durum, karmaşık örüntüleri diğer modellerden daha etkili bir şekilde yakalayabildiği için YSA ve RO'nun eksenel dayanımı tahmin etmek için özellikle uygun olduğunu göstermektedir. Bulgular, karmaşık makine öğrenimi modellerinin, geleneksel doğrusal yaklaşımlara kıyasla FRP sargılı elemanların eksenel mukavemetini tahmin etmek için daha doğru ve verimli bir yöntem sağladığını göstermektedir.

Bilim Kodu : 91130
Anahtar Kelimeler : Sargılı beton, lifli polimer, doğrusal regresyon, rastgele orman, yapay sinir ağları
Sayfa Adedi : 91
Danışman : Dr. Öğretim Üyesi Nalan KAYA

COMPARISON OF DIFFERENT MACHINE LEARNING METHODS IN PREDICTING
THE AXIAL COMPRESSIVE STRENGTH OF FRP CONFINED
CONCRETE ELEMENTS

(M. Sc. Thesis)

Wajahat SAADAT

GAZI UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2025

ABSTRACT

This research aims to develop machine learning models for predicting the axial strength of concrete wrapped in Fiber-Reinforced Polymer (FRP), with the goal of improving both structural safety and design efficiency. Traditional methods, such as empirical calculations and experimental testing, often require significant time and effort. To streamline this process, the study applies advanced machine learning techniques namely, Linear Regression, Random Forest, and Artificial Neural Networks (ANN) to create predictive models based on data obtained from previous research. The data includes variables such as specimen dimensions, concrete strength, FRP tensile strength, wrap configurations, and axial load capacities. Data preprocessing involved handling missing values, managing outliers, and normalizing features. Dimensionality reduction was achieved through feature importance analysis using a bagging model, as well as correlation analysis. The models were evaluated using key performance metrics such as Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and R^2 score. An 85:15 train-test split was used, and hyperparameters were optimized through grid search. The results indicate that Linear Regression, with an R^2 score of 0.781, inadequately captures nonlinear relationships. The RO model achieved a better fit with an R^2 score of 0.985 due to its ability to model complex interactions, while the ANN model demonstrated the highest accuracy with an R^2 score of 0.991. This suggests that ANN and Random Forest are particularly well-suited for predicting axial strength, as it can capture intricate patterns more effectively than the other models. The findings demonstrate that complex machine learning models provide a more accurate and efficient method for predicting the axial strength of FRP-wrapped concrete compared to traditional linear approaches.

Science Code : 91130

Key Words : Confined concrete, fiber-reinforced polymer, linear regression, random forest, artificial neural networks

Page Number : 91

Supervisor : Assist. Prof. Dr. Nalan KAYA

TEŞEKKÜR

Saygıdeğer danışmanım, Dr. Öğretim Üyesi Nalan KAYA'ya, süreç boyunca bana verdiği destek için en içten teşekkürlerimi sunarım. Ayrıca, tezime yönelik yoğun ve faydalı değerlendirme ve yorumlarıyla tezimi geliştirmeme katkı sağlayan Dr. Öğretim Üyesi Eda Avanoğlu SICACIK'a ve Yüksek İnşaat Mühendisi Gürhan TOKGÖZ'e de teşekkür ederim. Her zaman yanımda olan, bana inanan ve beni cesaretlendiren harika arkadaşım Dur SAMAND'a teşekkür ederim.

Kariyerimde başarılı olmamı görmek için sevgi, dualar ve iyi dileklerini esirgemeyen anne ve babam, Farzana BİBİ ve Muhammad SAADAT'a teşekkür ederim. Onların sevgisi ve dilekleri, hayatın her alanında elimden gelenin en iyisini yapmam için bana daima cesaret vermiştir.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
RESİMLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. MODELLER	9
2.1. Doğrusal Regresyon	9
2.1.1. Doğrusal regresyonun çalışma prensibi	10
2.1.2. Doğrusal regresyonun anlamlılığı	10
2.2. Rastgele Orman	11
2.2.1. Rastgele ormanın çalışma prensibi	12
2.2.2. Rastgele ormanın önemi.....	12
2.3. Çok Katmanlı Algılayıcı – Yapay Sinir Ağı	13
2.3.1. Çok katmanlı algılayıcı – yapay sinir ağı çalışma prensibi	14
2.3.2. Çok katmanlı algılayıcının önemi	14
3. LİTERATÜR TARAMASI	17
4. METODOLOJİ.....	23
4.1. Veri Toplama ve Ön İşleme	24
4.2. Veri Analizi	29
4.2.1. Kütüphaneler.....	29

	Sayfa
4.2.2. İstatistiksel parametreler	33
4.2.3. Parametre sayısı ve veri türü	34
4.2.4. Verideki eğilimler	34
4.2.5. Pearson korelasyon ısı haritası.....	39
4.2.6. Etiket kodlayıcı	42
4.2.7. Standart ölçekleyici.....	42
4.3. Makine Öğrenmesi Model Seçimi	45
4.4. Model Eğitimi ve Değerlendirilmesi.....	47
4.4.1. K-kat çapraz doğrulama (k-fold cross-validation).....	47
4.4.2. Hiper parametreler	50
4.4.3. Değerlendirme metrikleri.....	54
4.4.4. Gerçek ve tahmini değerler çizimi.....	57
5. ARAŞTIRMA BULGULARI	59
5.1. Eğitim Kayıp Eğrisi.....	59
5.2. Doğrusal Regresyon	60
5.3. Rastgele Orman	62
5.4. Çok Katmanlı Algılayıcı	63
6. SONUÇ.....	67
KAYNAKLAR	71
EKLER.....	81
EK-1. Önceki literatürden elde edilen tam veri seti.....	82
ÖZGEÇMİŞ	91

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Tüm veriler	26
Çizelge 5.1. Sonuçların özeti	65
Çizelge 1.1. Yaygın liflerin özellikleri	82



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Doğrusal regresyon modeli.....	10
Şekil 2.2. Rastgele orman modeli	11
Şekil 2.3. Çok katmanlı algılayıcı.....	13
Şekil 4.1. Veri temsili	28
Şekil 4.2. Özellik önem grafiği.....	29
Şekil 4.3. İstatistiksel parametreler.....	33
Şekil 4.4. Parametre sayısı ve veri türü.....	34
Şekil 4.5. Tipe göre beton dayanımı	35
Şekil 4.6. Sargılanmış beton dayanımı ve frp katman sayısı	36
Şekil 4.7. Sargılanmamış beton dayanımı ve sargılanmış beton dayanımı.....	38
Şekil 4.8. Pearson korelasyon ısı haritası.....	40
Şekil 4.9. Etiket kodlayıcı kodu.....	42
Şekil 4.10. Sütun ölçekleme kodu.....	43
Şekil 4.11. Özelliklerin dağılımı.....	44
Şekil 4.12. Özelliklerin dağılımı (ölçeklendirilmiş)	44
Şekil 4.13. K-kat çapraz doğrulama kodu.....	48
Şekil 4.14. K-kat çapraz doğrulama sonuçları	49
Şekil 4.15. Rastgele orman hiperparametreler'in kodu	51
Şekil 4.16. Çok katmanlı algılayıcı (çka) hiper parametreler'in kodu.....	53
Şekil 4.17. Değerlendirme parametreleri	54
Şekil 4.18. Gerçek ve tahmini değerler grafik kodu	57
Şekil 5.1. Eğitim kaybi eğrisi.....	59
Şekil 5.2. Gerçek ve tahmin edilen değerler grafiği (doğrusal regresyon)	61
Şekil 5.3. Gerçek ve tahmin edilen değerler grafiği (rastgele orman).....	62

Şekil	Sayfa
Şekil 5.4. Gerçek ve tahmin edilen değerler grafiği	64
Şekil 5.5. Yapay zeka modellerinin performans metrikleri	66



RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 1.1. Beton kolonların frp ile sargılanması	2



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

b_i	i. katsayı
b_0	0. katsayı
ϵ	Hata terimi veya artık (residual)
σ	Standart sapma
$\min$	Minimum
$\max$	Maksimum
r	Pearson korelasyon katsayısı
iter	İterasyon
init	Başlangıç (ilk değer)
R^2	R-kare değeri

Kısaltmalar

Açıklamalar

AFRP	Aramid lifli polimer
AI	Artificial intelligence
YZ	Yapay zeka
ANN	Artificial neural network
YSA	Yapay sinir ağı
CFRP	Karbon lifli polimer
CFST	Concrete filled steel tubular (beton dolgulu çelik boru)
CNN	Convolutional neural network (evrimsel sinir ağları)
DT	Decision tree (karar ağaçları)
FRP	Fiber reinforced polymer (lifli polimer)
GFRP	Cam lifli polimer
LR	Linear regression

Kısaltmalar**Açıklamalar**

DR	Doğrusal regresyon
MAE	Mean absolute error (ortalama mutlak hata)
ML	Machine learning (makine öğrenimi)
MLP	Multilayer perceptron
ÇKA	Çok katmanlı algılayıcı
MSE	Mean squared error (ortalama kare hata)
RC	Reinforced concrete (donatili beton)
RF	Random forest
RO	Rastgele orman
RNN	Recurrent neural networks (tekrarlayan sinir ağları)
RMSE	Root mean squared error (kök ortalama kare hata)
SVM	Support vector machine (destek vektör makineleri)
SVR	Support vector regression (destek vektör regresyonu)

1. GİRİŞ

Son yıllarda, çevresel bozulma, yetersiz bakım ve çağdaş tasarım standartlarına uyum sağlama ihtiyacı gibi faktörler nedeniyle mevcut yapıların iyileştirilmesi zorunluluğu önem kazanmıştır [1-3]. Bir binanın performansını korumak için, genellikle yapısal elemanlarını güçlendirmek gerekir [4]. Beton mantolama yaygın bir güçlendirme yöntemidir [5,6], ancak bu zorlukların üstesinden gelmek için, Lifli Polimerler sargısı, yapısal olarak tehlikeye atılmış binaların harici olarak güçlendirilmesi için bir başka popüler çözüm olarak ortaya çıkmıştır [7,8,9]. Yüksek dayanım-ağırlık oranı, geometri üzerinde daha az etki, hızlı ve basit uygulama ve korozyona karşı dayanıklılık gibi dikkat çekici özellikleri, onları tercih edilen bir seçim haline getirmiştir [10,11]. Güçlendirme için cam, karbon ve aramid dahil olmak üzere çeşitli elyaf türleri kullanılır [6,12]. Lifli Polimer levhalar, yerinde ekonomik, verimli ve zaman kazandıran uygulamaları nedeniyle inşaat sektöründe büyük ilgi görmüştür [13-16].

Lifli Polimer kompozit malzemeler üç ana bileşenden oluşur: elyaflar, polimerler ve çeşitli katkı maddeleri ve dolgu maddeleri [17]. Lifli Polimer kompozitlerde, yüksek dayanım ve sertliğe sahip sürekli lifler, nispeten daha düşük bir modüle ve elyaftan daha yüksek nihai gerilmeye sahip bir polimerik matris kullanılarak emprenye edilir. Liflerin hangi yönde ilerleyeceği, lifler yük taşıyan bileşen olduğu için kompozit elemana uygulanan gerilim tarafından belirlenir. [17]

Beton elemanların GFRP veya CFRP ile sagılanması, dayanımını, dayanıklılığını ve yapısal performansını artırmada etkili bir yöntemdir. [18,19]. FRP'ler, yüksek çekme dayanımı, hafiflik, düşük bakım maliyetleri, düşük termal iletkenlik, kimyasal ortamlarda korozyona dayanıklılık ve elektromanyetik direnç gibi korozyon çeliğe göre avantajlara sahiptir [20-23].



Resim 1.1. Beton kolonların frp ile sargılanması

Makine öğrenmesi, erken teorik kavramlardan modern yapay zeka uygulamalarını destekleyen dönüştürücü bir teknolojiye evrilen uzun bir geçmişe sahiptir. Makine öğrenmeleri'nin kökleri 1950'lere dayanır; bu dönemde Alan Turing, makine zekası kavramını ortaya atmış ve bir makinenin insan benzeri zeka sergileyip sergileyemeyeceğini değerlendirmek için Turing Testi'ni tanıtmıştır. Aynı zamanlarda, Frank Rosenblatt, derin öğrenmenin temelini atan erken bir yapay sinir ağı olan Perceptron Modeli'ni geliştirmiştir [24]. Ek olarak, Bayes öğrenmesi gibi olasılıksal modeller 1960'larda popülerlik kazanmaya başlamış ve karar alma ile desen tanıma gibi yapay zeka uygulamalarını etkilemiştir [25].

Bu erken ilerlemelere rağmen, makine öğrenmesi 1970'ler ve 1980'lerde sınırlı hesaplama gücü ve aşırı iddialı beklentiler nedeniyle zorluklarla karşılaşmıştır. Bu dönem, "Yapay Zeka Kışı" olarak bilinir ve yapay zeka araştırmalarına yapılan yatırımların ve ilginin azaldığı bir zaman dilimini gösterir. Ancak bu dönemde önemli bazı gelişmeler yaşanmıştır. Örneğin, 1986 yılında Geoffrey Hinton ve çalışma arkadaşları tarafından geliştirilen Geri Yayılım (Backpropagation) Algoritması, sinir ağlarının eğitiminde önemli bir ilerleme sağlamıştır

[26]. Ayrıca, Karar Ağaçları ve Uzman Sistemler (Expert Systems) gibi kural tabanlı yapay zeka teknikleri, gerçek dünya problemlerini çözmek için yaygın olarak kullanılmıştır [27].

1990'lara gelindiğinde, makine öğrenmesi veri odaklı yaklaşımlara yönelmiştir. Bu dönemde Destek Vektör Makineleri (SVM) ve Rastgele Orman (RO) ile Boosting Algoritmaları gibi topluluk yöntemleri (ensemble methods) geliştirilmiştir. Bu teknikler, sınıflandırma doğruluğunu ve öngörü yeteneklerini artırmıştır [28]. Ayrıca, Pekiştirmeli Öğrenme (Reinforcement Learning) de 1990'larda popüler hale gelerek makinelerin deneme-yanılma yöntemiyle en iyi karar verme politikalarını öğrenmesine olanak sağlamıştır [29]. Bu dönem, Makine öğrenmelerinin endüstride yaygın olarak benimsenmeye başladığı bir süreç olmuştur.

2010'lu yıllar, derin öğrenmenin patlamasıyla makine öğrenmesini devrim niteliğinde bir teknolojiye dönüştürmüştür. Evrimsel Sinir Ağları, görüntü işleme alanında büyük ilerlemeler kaydederken, Tekrarlayan Sinir Ağları ise sıralı veri analizi için önemli gelişmeler sunmuştur. Büyük veri, artan hesaplama gücü ve GPU hızlandırma teknikleri, daha karmaşık Makine öğrenme modellerinin verimli bir şekilde eğitilmesini sağlamıştır [30]. Derin öğrenme modellerinin doğal dil işleme, otonom araçlar ve tıbbi teşhis gibi alanlardaki başarısı, makine öğrenmesinin modern yapay zeka uygulamalarındaki rolünü pekiştirmiştir [31].

Günümüzde makine öğrenmesi, Otomatik makine öğrenmesi (AutoML) gibi yeni trendlerle evrimini sürdürmektedir. AutoML, model geliştirme sürecini basitleştirirken, Açıklanabilir Yapay Zeka (XAI), makine öğrenme kararlarının daha şeffaf ve anlaşılır olmasını sağlamaktadır. Ayrıca, Kuantum makine öğrenmesi (Quantum Machine Learning) gibi gelişmekte olan alanlar, kuantum hesaplama ile yararlanarak Makine öğrenimi'nin yeteneklerini daha da ileriye taşıma potansiyeline sahiptir [38]. Makine öğrenimi ilerledikçe mühendislik, sağlık ve finans gibi alanlardaki uygulamaları genişlemeye devam edecek ve Yapay Zeka destekli çözümlerin geleceğini şekillendirecektir.

Son yıllarda, makine öğrenmesi (MO), inşaat ve yapı mühendisliği alanında güçlü bir araç olarak öne çıkmıştır. Bu teknoloji, örüntü tanıma, öngörüselleştirme ve optimizasyon gibi gelişmiş yetenekler sunmaktadır [39]. Geleneksel ampirik ve analitik yaklaşımlar, özellikle FRP sargılı beton gibi kompozit sistemlerde gizli örüntüler içeren çok değişkenli

verileri işlerken yetersiz kalabilmektedir. Buna karşılık, makine öğrenmesi algoritmaları doğrusal olmayan ve çok değişkenli ilişkileri ele almakta oldukça etkilidir. Bu algoritmalar, tarihsel verilerden öğrenerek karmaşık ilişkileri tespit edebilir ve yüksek doğrulukta tahminler üretebilir [40].

FRP sargılı beton gibi kompozit malzemeleri içeren yapısal sistemler, yükleme altında karmaşık davranışlar sergiler. Bu durum, beton özellikleri ile dış sarma arasındaki etkileşimden kaynaklanır [41]. Bu tür karmaşıklıklar, eksenel basınç dayanımı gibi yapısal tepkilerin tahmini için veri odaklı yaklaşımları etkili hale getirmektedir [40].

Makine öğrenmesinin birçok uygulaması arasında, FRP sargılı betonun nihai durumunun tahmini dikkat çeken bir örnektir. Bu durum, makine öğrenmesi yöntemlerinin yapı mühendisliği alanını nasıl yeniden şekillendirdiğini göstermektedir [42]. FRP sargılı beton davranışını tahmin etmekte makine öğrenmesinin kullanılmasının önemli bir nedeni, çok çeşitli koşullar ve malzeme konfigürasyonları arasında genelleme yapabilmesidir. Örneğin; farklı sarma oranları, çeşitli FRP malzeme türleri ve çeşitli geometrileri içeren veri kümeleri, her durum için ayrı ayrı denklemler türetilmesine gerek kalmadan makine öğrenmesi algoritmalarıyla etkili şekilde işlenebilmektedir. Bu durum, deneysel veriler arttıkça geliştirilmeye devam edilebilen, veriye dayalı ve uyarlanabilir genelleştirilmiş tahmin modellerinin oluşturulmasını imkan verir [43]. Bu yüzden, FRP sargılı betonun performansını tahmin edebilmek için sade ve verimli bir modele gerek vardır [44].

Analitik modeller geliştirerek FRP sargılı betonun basınç davranışını tahmin etmek için çeşitli çalışmalar yapılmıştır [45-62]. Bununla birlikte, modellerin doğruluğu konusunda belirsizlikler ve şüpheler bulunmuştur çünkü nispeten az sayıda test sonucu veya girdi değişkeni içeren bir veritabanı kullanmışlardır. Ayrıca verilerdeki çok yönlü ilişkileri yakalama kapasitesinden de yoksundurlar [63]. Makine öğrenmesi stratejileri, FRP sargılı betonun nihai davranışını tahmin etmek için güçlü bir yaklaşım olarak ortaya çıkmıştır [64-70]. Bununla birlikte, bu modeller tüm önemli faktörlerin etkisini içermeyen, hesaplama açısından karmaşık modellerdi veya büyük boyutlu veritabanlarını işlemek için verimli değillerdi. Bu nedenle, FRP sargılı betonun nihai basınç davranışını tahmin etmek için daha doğru ve verimli teknikler gereklidir [71]. Ayrıca, makine öğrenmesi model doğrulama ve yorumlanabilirlik açısından önemli avantajlar sunmaktadır. Çapraz doğrulama, değişken

önem sıralaması ve duyarlılık analizi gibi teknikler, model çıktıları üzerindeki bireysel parametrelerin etkisinin daha iyi anlaşılmasını sağlamaktadır [72].

Son yıllarda, hesaplama araçları ve açık kaynaklı yazılımlardaki gelişmeler, makine öğrenmesi modellerinin inşaat mühendisleri ve araştırmacılar tarafından daha erişilebilir hale gelmesini sağlamıştır. Python'un Scikit-learn, TensorFlow ve Keras gibi kütüphaneleri ile MATLAB gibi platformlar, modellerin verimli şekilde eğitilmesi, test edilmesi ve doğrulanması için güçlü altyapılar sunmaktadır [73]. Bu yapay zeka teknolojilerinin yaygınlaşması, mühendislikte karmaşık olayların modellenmesi gibi uygulamaların benimsenmesini hızlandırmıştır.

Makine öğrenmesi modelleri, ayrıca yapısal malzeme çalışmalarında sıkça karşılaşılan heterojen ve eksik veri setleriyle başa çıkmada da önemli avantajlara sahiptir. FRP sargılı beton üzerine yapılan birçok deneysel çalışmada, farklı sınır koşulları, beton dayanımları, FRP türleri ve sarılma yöntemleri kullanılmıştır. ML algoritmaları, eksik ya da gürültülü verilerden eğilimleri çıkarabilme yeteneği sayesinde, tamamen kontrollü laboratuvar ortamlarına olan bağımlılığı azaltmaktadır [74]. Bu yetenek, öngörü modellerinin daha sağlam ve genellenebilir olmasını sağlamakta, aynı zamanda gerçek dünya değişkenliğini geleneksel deterministik yöntemlere kıyasla daha doğru yansıtmaktadır.

Denetimli öğrenme teknikleri, özellikle Yapay Sinir Ağları (YSA), Rastgele Orman (RO) ve Doğrusal Regresyon (DR) gibi yöntemler, FRP sargılı betonun davranışını modellemede kayda değer başarılar ortaya koymuştur [72]. Basitliği ve doğrusal olmaması nedeniyle, Yapay Sinir Ağı (YSA), FRP sargılı betonun davranışını tahmin etmek için en yaygın olarak kullanılan yaklaşım olmuştur [75]. Fakat, eğitim süreci, YSA kullanarak sağlam, doğru ve verimli tasarım ilişkileri sağlamak için kritik konulardan biridir [76]. Yapay Sinir Ağı (YSA) – Çok Katmanlı Algılayıcı (ÇKA), verilerdeki karmaşık doğrusal olmayan ilişkileri modelleme ve giriş verilerinden ilgili nitelikleri otomatik olarak elde etme avantajlarına sahiptir [77]. Karar ağacı tabanlı algoritmalar ailesine ait olan bir diğer popüler topluluk öğrenme algoritmasıdır [78]. RO'nın avantajları, azaltılmış aşırı uyum, sağlamlık, otomatik özellik seçimi ve paralel olarak birden fazla ağacın eğitilmesindeki verimlilik olmuştur [78].

Literatür taramasına dayanarak, FRP sargılı betonun nihai dayanımının doğru bir şekilde tahmin edilmesi için Doğrusal Regresyon (DR), Yapay Sinir Ağı (YSA) – Çok Katmanlı

Algılayıcı (ÇKA) ve Rastgele Orman'nın (RO) uygulanmasında bugüne kadar çok az çalışma yapılmıştır [71]. Bu araştırma boşluğunu gidermek için, bu çalışmada bu modeller FRP sargılı betonun eksenel dayanımını tahmin etmek için kullanılmıştır.

Araştırmanın önemi

FRP sargılı betonun eksenel dayanımını doğru tahmin etmek, yapı güvenliğini sağlamak ve malzeme kullanımını en iyi şekilde planlamak için çok önemlidir. Makine öğrenmesi modellerinde son yıllarda yaşanan gelişmeler, daha doğru ve verimli tahminler yapılmıştır. Bu gelişmeler sayesinde, eksenel dayanım uzun ve zahmetli deneysel testlere ihtiyaç duyulmadan daha hassas şekilde tahmin edilebilmektedir. Karbon ve cam FRP'ler gibi FRP malzemeleri, betonun dayanımını, sünekliğini ve basınç yükleri altında dayanıklılığını arttırdığı için betonu sargılamak için giderek daha fazla kullanılmaktadır [71]. FRP sargılı betonun basınç davranışının doğru tahmini, beton yapıların tasarımını optimize etmek ve yapıların güvenlik standartlarını ve performans gereksinimlerini karşılamasını, bunun sonucunda malzeme maliyetinin ve çevresel etkinin azaltılması gibi çeşitli nedenlerden dolayı çok önemlidir. [71] Güçlendirme ve onarım için FRP kompozitlerinin kullanılması, modern inşaat uygulamalarında çok önemli olan mevcut beton elemanların restorasyonu için uygun maliyetli bir çözüm sunar. Önceki çalışmalar, FRP'nin beton elemanların yük taşıma kapasitesini ve sünekliğini önemli ölçüde artırabildiğini ve geleneksel malzemelerden daha hafif ve daha kolay uygulanabileceğini göstermiştir [18-20].

Birçok çalışma, beton basınç dayanımını tahmin etmek için makine öğrenimi modellerini kayda değer bir başarıyla uygulamıştır [79]. Makine öğrenimi, verilerdeki karmaşık ilişkileri modellemek için sağlam bir çerçeve sağlayarak potansiyel olarak doğru tahminlere yol açar [80]. Bu ilerlemelere rağmen, aynı çalışmada hem DR gibi basit modeller hem de YSA ve RO gibi karmaşık modeller üzerine yapılan araştırmaların sayısı sınırlıdır. Çoğu çalışma, girdi değişkenlerinin modeller içinde nasıl etkileşime girdiğini derinlemesine araştırmadan yüksek tahmin doğruluğuna ulaşmayı vurgulamaktadır. [79]

Bu çalışmada, FRP sargılı betonun eksenel dayanımını tahmin etmek için üç makine öğrenimi modeli, Doğrusal Regresyon (DR), Rastgele Orman (RO) ve Çok Katmanlı Algılayıcı – Yapay Sinir Ağı (ÇKA-YSA) kullanılmıştır. Belirlenen girdi parametreleri, önceki araştırmaların sonuçlarını kullanarak FRP sargılı betonu tasarlamak için

kullanılmıştır. Bu amaca ulaşmak için, geometrik parametreler, beton ve FRP kompozitlerinin mekanik özellikleri gibi çok çeşitli girdi değişkenleri dikkate alınmıştır. Önerilen modeller, FRP sargılı betonun aksenal dayanımını tahmin etmek için geliştirilmiştir.

Tezin kapsamı

Bu araştırmanın temel amaçları şunlardır:

- FRP sargılı betonun aksenal dayanımını tahmin etmek için doğru ve güvenilir yapay zeka modelleri geliştirmek.
- Makine öğrenimi modellerinin performansını doğruluk, hesaplama verimliliği ve sağlamlık açısından değerlendirmek ve karşılaştırmak, temel DR modeli, topluluk tabanlı RO modeli veya daha karmaşık ÇKA-YSA modeli arasında en yüksek doğruluğa sahip modeli belirlemek
- Önceki deneysel çalışmalardan elde edilen verilerden yararlanarak yapay zeka modellerini eğitmek ve doğrulamak; tahmin ile deneysel sonuçlar arasında güçlü bir korelasyon sağlamak.
- Girdi verilerinin kalitesini ve güvenilirliğini artırmak için beş kat çapraz doğrulama, eksik değerleri silme ve aykırı değerlerin etkisini azaltma gibi çeşitli veri ön işleme tekniklerini kullanmak. Bu ön işleme adımlarının birincil amacı, yetersiz uyum ve aşırı uyum risklerini en aza indirmek ve böylece makine öğrenimi modellerinin genelleme yeteneğini geliştirmektir.
- Karmaşık problemleri daha verimli ve etkili bir şekilde çözme potansiyellerini göstererek makine öğrenimi ve yapay zeka tekniklerinin yapı mühendisliğinde benimsenmesini teşvik etmektir.



2. MODELLER

Bu çalışmada, değişen model karmaşıklığı seviyelerine göre sonuçları değerlendirmek için en az karmaşık olandan en karmaşık olana kadar üç makine öğrenimi modeli kullanılmıştır. Seçilen modeller şunlardır:


- Doğrusal Regresyon (DR)
- Rastgele Orman (RO)
- Çok Katmanlı Algılayıcı (ÇKA) – Yapay Sinir Ağı (YSA)

2.1. Doğrusal Regresyon

Doğrusal Regresyon, gözlemlenen verilere doğrusal bir denklem uydurarak bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modelleyen temel bir istatistiksel yöntemdir [81]. Basit doğrusal regresyon olarak bilinen en basit haliyle model, yanıt değişkenini düz bir çizgi üzerinden tahmin etmek için tek bir tahmin edici değişken kullanır [82]. Birden fazla tahmin edici değişken dahil edildiğinde, model çoklu doğrusal regresyona genişler ve bu da daha karmaşık ilişkilerin bir hiper düzlem şeklinde yakalanmasına olanak tanır [83]. Bir doğrusal regresyon modelinin denklemi şu şekilde ifade edilebilir:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + \epsilon$$

Burada y tahmin sonuç, x tahmin edici değişkenler, b_i katsayılar, b_0 kesişim ve ϵ hata terimi veya artıktır [84]. Bu denklem, kalıntıları en aza indirecek şekilde optimize edilerek doğrunun veya düzlemin gözlemlenen verilere en iyi şekilde uyması sağlanır.



Şekil 2.1. Doğrusal regresyon modeli

2.1.1. Doğrusal regresyonun çalışma prensibi

Modelin birincil amacı, tahmin edilen ve gerçek değerler arasındaki farkı en aza indiren katsayılar (ağırlıklar) için en uygun değerleri bulmaktır. Bu fark genellikle karesel artıkların toplamını hesaplayan ve bu hatayı azaltmak için modelin katsayılarını ayarlayan "en küçük kareler" yöntemi kullanılarak en aza indirilir [85]. Alternatif olarak, özellikle büyük veri kümeleri veya yüksek boyutlu uzaylar için gradyan inişi gibi optimizasyon yöntemleri kullanılabilir. Gradyan inişinde algoritma, maliyet fonksiyonunun her bir katsayıya göre gradyanını (kısmi türevlerini) hesaplayarak katsayıları tahmin hatasını azaltacak yönde iteratif olarak ayarlar [86]. Bu teknikler, en iyi uyan bir çizgi veya hiper düzlem elde etmeye yardımcı olarak modeli yeni veriler üzerinde gelecekteki tahminler için sağlam hale getirir.


2.1.2. Doğrusal regresyonun anlamlılığı

Doğrusal Regresyonun basitliği ve yorumlanabilirliği, değişkenler arasındaki ilişkilerin ölçülmesi ve tahmin edilmesi gereken alanlarda onu oldukça değerli kılmaktadır. Özellikle ekonomi, finans, sağlık, mühendislik görevleri ve sosyal bilimlerde popülerdir [87]. Modeldeki her bir katsayı basit bir yorumlama sağlar: diğer değişkenler sabit tutularak bir tahminci değişkendeki bir birimlik artış için hedef değişkende beklenen değişikliği temsil eder. Bu yorumlanabilirlik, değişkenlerin sonucu nasıl etkilediğini netleştirdiği için karar vericiler için çok önemlidir [88].

Doğrusal Regresyon, hesaplama verimliliği ve basitlik gibi çeşitli güçlü yönleri sahiptir, bu da onu küçük veri kümeleri ve ön veri analizi için ideal hale getirir [90]. Bununla birlikte, başta tahmin ediciler ile hedef değişken arasında doğrusal bir ilişki varsayımı olmak üzere, tüm veri kümelerinde geçerli olmayabilecek önemli sargılamaları vardır [83]. Ayrıca model, regresyon çizgisini bozabilen ve tahmin doğruluğunu etkileyebilen aykırı değerlere karşı duyarlıdır [84]. Doğrusal Regresyon ayrıca homoskedastisite (hataların sabit varyansı), hataların bağımsızlığı ve artıkların normal bir dağılım izlediğini varsayar; bu varsayımlar ihlal edilirse model geçerliliğini etkileyebilir [88].

2.2. Rastgele Orman

Rastgele Orman hem sınıflandırma hem de regresyon görevlerine uygulanabilen tahminler yapmak için karar ağaçlarından oluşan bir "orman" oluşturan çok yönlü ve yaygın olarak kullanılan bir topluluk öğrenme algoritmasıdır [91]. Model kararlılığını ve doğruluğunu artırmak için "bagging" veya "bootstrap aggregation" adı verilen bir süreçte birden fazla ağacı birleştirerek bireysel karar ağaçlarını geliştirir [81]. Ormandaki her ağaç, eğitim verilerinin farklı bir alt kümesi üzerinde eğitilir ve örnekleme, ağaçlar arasında çeşitlilik sağlayan değiştirme ile gerçekleştirilir [89]. Rastgele Orman, tahminleri birden fazla ağaçta toplayarak bireysel karar ağaçlarının sargılamalarını, özellikle de aşırı uyumu ele alır [92].



Şekil 2.2. Rastgele orman modeli

2.2.1. Rastgele ormanın çalışma prensibi

Model, sınıflandırmada çoğunluk oyunu olarak veya regresyonda tahminlerin ortalamasını alarak çalışır, varyansı etkili bir şekilde azaltır ve görünmeyen veriler üzerinde genelleştirilebilirliği artırır [93]. Her bir karar ağacını oluştururken, Rastgele Orman ayrıca her bölünmede rastgele bir özellik alt kümesi seçer, bu da ağaçları süslemeye yardımcı olur ve modelin verilerdeki çeşitli kalıpları yakalamasını sağlar [91]. Bu mekanizma, Rastgele Orman'ın özellikle verilerin gürültülü veya yüksek boyutlu olduğu senaryolarda tek karar ağaçlarından daha iyi performans göstermesini sağlar [81].

2.2.2. Rastgele ormanın önemi

Rastgele Orman'ın önemi, karmaşık veri kümelerini minimum parametre ayarlamasıyla ele alma yeteneğinde yatmaktadır. Büyük özellik uzaylarını yönetebilir, eksik değerleri tolere edebilir ve dengesiz verilerle etkili bir şekilde başa çıkabilir [91]. Parametrik olmayan bir model olarak Rastgele Orman, herhangi bir özel veri dağılımı varsaymaz ve bu da onu görüntü sınıflandırma, tıbbi teşhis ve finansal risk analizi gibi karmaşık görevler için ideal hale getirir [92]. Ayrıca RO, özellikleri tahminlere katkılarına göre sıralayan bir özellik önem metriği üretebilir. Bu özellik, yüksek boyutlu verilerde özellik seçimi ve model yorumlanabilirliğinin iyileştirilmesi için oldukça değerlidir [89].


Rastgele Orman'ın büyük avantajı, bireysel karar ağaçlarında yaygın bir sorun olan aşırı uyuma karşı dayanıklılığıdır [91]. Birden fazla ağacı bir araya getirerek model, doğruluğu korurken gürültülü verilerde aşırı uyum riskini azaltır [81]. Bununla birlikte, özellikle çok sayıda ağaç oluştururken veya büyük veri kümeleriyle uğraşırken yüksek hesaplama maliyeti gibi sınırlamaları da vardır [92]. Rastgele Ormanların eğitilmesi daha yavaş olabilir ve önemli miktarda bellek tüketebilir, bu da onları gerçek zamanlı uygulamalar için daha az ideal hale getirir. Bir başka sınırlamada yorumlanabilirliktir; özellik önemi sağlamasına rağmen, her bir ağacın ve bir bütün olarak topluluğun iç işleyişini yorumlamak daha basit modellerden daha zordur [93].

2.3. Çok Katmanlı Algılayıcı – Yapay Sinir Ağı

Çok Katmanlı Algılayıcı, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı içeren çoklu nöron katmanları ile karakterize edilen bir yapay sinir ağı sınıfıdır [94]. Her katman, girdi verilerini bir dizi dönüşüm yoluyla işleyen ve ağı veriler içindeki karmaşık kalıpları ve ilişkileri öğrenmesini sağlayan birbirine bağlı düğümlerden (nöronlar) oluşur [88]. Çok Katmanlı Algılayıcılar, bilginin döngüler olmaksızın tek yönde (girişten çıkışa) aktığı ileri beslemeli bir mimari kullanır ve bu da onları RNN'lerden ayırır. [95]

Çok Katmanlı Algılayıcılar (ÇKA), eksel kuvveti tahmin etmek gibi regresyon görevleri için kullanılan en yaygın YSA türüdür. ÇKA esnektir ve girdi özellikleri ile hedef değişken arasındaki karmaşık doğrusal olmayan ilişkileri yakalayabilir. Malzeme özellikleri, geometrik özellikler ve FRP özellikleri gibi çeşitli özellikleri işleyebilirler. [94]

Birçok ÇKA'da temel yapı taşı nörondur. Her nöron giriş sinyallerini alır, bunları belirli ağırlıklarla çarpar ve toplar. Bu toplam daha sonra sigmoid veya "Rectified Linear Unit" (ReLU) fonksiyonu gibi bir aktivasyon fonksiyonu aracılığıyla işlenir [96]. Aktivasyon fonksiyonu, ağı verilerdeki örüntüleri ve ilişkileri tanımasına izin vererek karmaşık, doğrusal olmayan sorunları ele almasını sağlar. Bu yetenek ÇKA'yı nesneleri farklı kategorilerde sınıflandırmak veya sayısal değerleri tahmin etmek gibi görevler için kullanışlı hale getirir.



Şekil 2.3. Çok katmanlı algılayıcı

2.3.1. Çok katmanlı algılayıcı – yapay sinir ağı çalışma prensibi

ÇKA'nın eğitim süreci, tahmin edilen ve gerçek sonuçlar arasındaki farkı en aza indirmek için kullanılan geri yayılım adı verilen bir yöntemi içerir [97]. Başlangıçta, model nöronlar arasındaki bağlantılara rastgele ağırlıklar atar. İleri geçiş sırasında, giriş verileri ağ boyunca yayılır ve çıktı hesaplanır. Hata (veya kayıp) daha sonra regresyon görevleri için ortalama karesel hata veya sınıflandırma görevleri için çapraz entropi gibi bir kayıp fonksiyonu kullanılarak tahmin edilen çıktı ile gerçek hedef değer karşılaştırılarak hesaplanır [90].

Geriye yayılma aşamasında model, hesaplamanın zincir kuralını kullanarak her bir ağırlığın genel hatayı nasıl etkilediğini hesaplar. Gradyan olarak bilinen bu hesaplamalar, her bir ağırlığın hataya ne kadar katkıda bulunduğunu göstererek modelin öğrenmesine yardımcı olur [86]. Ağırlıklar daha sonra stokastik gradyan inişi (stochastic gradient descent) veya Adam gibi optimizasyon teknikleri kullanılarak ayarlanır, bu da ağırlıkları hatayı azaltacak şekilde adım adım günceller [98]. Bu süreç, model hatayı en aza indiren en iyi ağırlık kümesini bulana kadar tekrarlanır ve ÇKA'nın yeni veriler üzerinde doğru tahminler yapmasına olanak tanır.

2.3.2. Çok katmanlı algılayıcının önemi

ÇKA'nın önemi, karmaşık, doğrusal olmayan ilişkileri modelleme yeteneklerinde yatmaktadır ve bu da onları geniş bir uygulama yelpazesi için güçlü araçlar haline getirmektedir [25]. Çok Katmanlı Algılayıcılar görüntü ve konuşma tanıma, doğal dil işleme ve finansal tahmin gibi çeşitli alanlarda kullanılabilir [95]. Büyük veri kümelerinden öğrenme kapasiteleri, sınıflandırma, regresyon ve fonksiyon yaklaşımı gibi görevlerde iyi performans göstermelerini sağlar.

ÇKA aynı zamanda derin öğrenmede de önemli bir rol oynar ve sırasıyla uzamsal ve sıralı verileri içeren görevler için uzmanlaşmış olan CNN'ler ve RNN'ler gibi daha karmaşık modeller için temel mimari olarak hizmet eder [86]. ÇKA'nın uyarlanabilirliği ve ölçeklenebilirliği, onları hem araştırmacılar hem de uygulayıcılar için popüler bir seçim haline getirmekte ve çeşitli alanlarda giderek karmaşıklaşan sorunların üstesinden gelmelerine olanak sağlamaktadır.

Güçlü yönlerine rağmen ÇKA'nın da limitleri vardır. Performansları, özellikle küçük veri kümeleriyle uğraşırken veya model çok karmaşık olduğunda aşırı uyum gibi sorunlar nedeniyle engellenebilir [90]. Bırakma, ızgara arama veya 5 katlı çapraz doğrulama (5 fold cross validation) teknikleri gibi düzenli hale getirme teknikleri genellikle aşırı uyumu azaltmak için kullanılır [99]. Ek olarak, ÇKA hesaplama açısından yoğun olabilir ve özellikle büyük ölçekli uygulamalarda eğitim için önemli hesaplama kaynakları gerektirir [86].





3. LİTERATÜR TARAMASI

Birçok çalışma, çeşitli modelleme teknikleri kullanarak FRP sargılı beton elemanların eksenel dayanımını tahmin etmeyi amaçlamıştır. Chen ve arkadaşları [100], FRP sargılı betonun eksenel dayanımını tahmin etmek için YSA kullanarak bir model geliştirmiştir. Beton dayanımı, FRP tipi ve deneysel verilere dayalı sargı konfigürasyonları gibi faktörleri analiz etmişlerdir. Bununla birlikte, çalışmada az sayıdaki veri kümesi nedeniyle aşırı uyum riski artmış ve bu da modelin daha az genelleştirilebilir hale gelmesine neden olmuştur. Ayrıca, alakasız verileri kaldırarak modeli geliştirebilecek gelişmiş özellik seçim teknikleri uygulanmamıştır.

Alhusban ve diğerleri [101] FRP sargılı betonun eksenel yük kapasitesini tahmin etmek için geleneksel regresyon yöntemleriyle birlikte destek vektör regresyonunu kullanmıştır. Modelleri birkaç temel faktörü bir araya getirmiş ve güçlü tahmin performansı göstermiştir, ancak modelleri bulgularının kapsamını sınırlayan tek bir veri kümesi üzerine kurulmuştur. Bu çalışmada Doğrusal Regresyon, Rastgele Orman ve Yapay Sinir Ağı- Çok Katmanlı Algılayıcı kullanılarak ele alınan farklı makine öğrenimi algoritmaları arasında daha karşılaştırmalı analizler yapılması önerilmiştir.

Ali ve diğerleri [45] tahmin doğruluğunu artırmak için doğrusal regresyon ile makine öğrenimi tekniklerini birleştiren hibrit bir modelleme yaklaşımını araştırmıştır. Daha kalın FRP tabakaları, eksenel deformasyonda azalmaya neden olmakla birlikte, taşıma kapasitesini %15'e kadar artırmıştır. Ayrıca, cam lifli polimer (GFRP) sarımının, aramid lifli polimer (AFRP) sarımına kıyasla %25 daha yüksek eksenel deformasyon sergilediği gözlemlenmiştir. Bu hibrit model umut verici olsa da karmaşıktı ve pratik senaryolarda yorumlanmasını ve uygulanmasını zorlaştırıyordu.

Onyelowe ve diğerleri tarafından yapılan çalışma. [47], AI modelleri kullanarak Karbon lifli polimer sargılı beton kolonların basınç dayanımını tahmin etmektedir. Araştırma, FRP kalınlığı, çekme dayanımı ve elastik modül gibi faktörlerin eksenel dayanımı nasıl etkilediğini incelemektedir. Makine öğrenimi algoritmaları da dahil olmak üzere yapay zeka modelleri, doğruluk açısından geleneksel analitik modelleri aşan öngörücü çerçeveler oluşturmak için kullanılmaktadır. Sonuçlar, yapay zekanın sargılı betonun doğrusal olmayan davranışını ele alma potansiyelini ortaya koymakta ve yapı mühendisliğinde kullanılan

öngörücü modellerin güvenilirliğini artırmaktadır. Çalışma, CFRP sargılı kolonlar için tasarım standartlarına yapay zeka tabanlı yaklaşımların dahil edilmesine yönelik önerilerle sonuçlanmaktadır.

Allahyarsharahi ve diğerleri [48], betonarme kirişlerde FRP'nin kesme katkısını tahmin etmek için Makine öğrenmesi tekniklerini araştırmıştır. Çalışmada FRP sargının kirişlerin kesme kapasitesine katkısı incelenmiş de, destek vektör makineleri ve sinir ağları da dahil olmak üzere uygulanan yöntemler ve yapay zeka araçları, FRP sargılı kirişlerin eksenel yük taşıma davranışını modellemek için değerli bilgiler sunmuştur. Çalışma, Makine öğrenmesi modellerinin, homojen olmayan gerilme dağılımı ve değişen malzeme özellikleri gibi FRP sargılama etkileriyle ilişkili değişkenlik ve karmaşıklıkları etkili bir şekilde ele alabileceğini doğrulamaktadır.

Xu ve diğerleri. [49] çalışmalarında, FRP sargılı beton dolgulu çelik boru kolonların eksenel dayanımını tahmin etmek için sayısal simülasyonu Makine öğrenmesi teknikleriyle birleştirmiştir. YSA ve RO gibi makine öğrenmesi modelleri deneysel veriler üzerinde eğitilerek hem eş merkezli hem de eksantrik yükleme altında yük taşıma kapasitesinin doğru tahmin edilmesini sağlamıştır. Bulgular, FRP sargılamanın CFST kolonlarının eksenel dayanımını ve sünekliğini önemli ölçüde artırdığını ortaya koymaktadır. Ayrıca, çalışma, geometrik ve malzeme parametreleri arasındaki karmaşık ilişkileri yakalamada makine öğrenmesi modellerinin verimliliğini vurgulamakta ve onları tasarım optimizasyonu için vazgeçilmez kılmaktadır.

Ghazouani ve diğerleri. [50], Aramid Lifli Polimer (AFRP) sargılı beton silindirlerin eksenel basınç davranışını araştırmıştır. Çalışma hem nihai dayanım hem de eksenel gerinimi tahmin etmek için yapay zeka tabanlı teknikler kullanarak gelişmiş gerilme-gerinim modelleri sunmaktadır. Deneysel sonuçlar ile yapılan karşılaştırma, özellikle yüksek gerinim oranları ve eksantrik yükleme içeren senaryolarda bu yapay zeka modellerinin doğruluğunu göstermektedir.

Bahrami ve diğerleri [51], FRP sargılı dairesel beton kolonların basınç dayanımını tahmin etmek için öngörücü makine öğrenmesi modelleri geliştirmeye çalışmışlardır. Araştırma, FRP sargılama oranları, çekme dayanımı ve beton sınıfı gibi temel parametrelerin rolünü göstermektedir. Çalışmada kullanılan makine öğrenmesi modelleri Gauss süreç regresyonu,

Destek Vektör Makineleri, Yapay Sinir Ağı (YSA), optimize edilmiş SVM ve optimize edilmiş GPR modelleridir.

Radu ve diğerleri. [52] çalışmalarında, korozyona uğramış RC kolonlarının performansını modellemek için gradyan artırma ve destek vektör regresyonu dahil olmak üzere makine öğrenmesi algoritmalarını kullanmıştır. Çalışmada korozyon seviyeleri, FRP kalınlığı ve sargılama oranları gibi değişkenleri içeren tahmini modeller oluşturulmuştur. Sonuçlar, FRP güçlendirmesinin korozyonun eksenel kapasite üzerindeki olumsuz etkilerini etkili bir şekilde azalttığını ve makine öğrenmesi tekniklerinin geleneksel yöntemlere kıyasla oldukça doğru tahminler sağladığını göstermiştir.

Koodiani ve diğerleri [53], çalışmalarında FRP sargılı betonun basınç dayanımını tahmin etmek için YSA'ları kullanmışlardır. Çalışmada, mevcut ampirik modeller değerlendirilmiş ve YSA tabanlı geliştirmeler önerilmiştir. Beton dayanımı, FRP çekme dayanımı ve sargılama oranı çalışmadaki anahtar girdi parametreleridir. Kalibre edilmiş AI tabanlı denklemlerin mühendislik tasarım uygulamaları için sağlam bir alternatif sunduğunu ve daha yüksek güvenlik ve performans standartları sağladığı belirtilmiştir.

Chen ve diğerleri [54], eksenel yükler altında FRP sargılı dairesel kolonların davranışını tahmin etmede YSA ve SVR'nin karşılaştırmalı bir analizini yapmışlardır. Araştırma, FRP çekme dayanımı, katman kalınlığı ve beton sınıfı gibi parametreleri kapsayan bir deneysel veri tabanından yararlanmıştır.

Wang ve diğerleri. [55], eksenel basınç altında kısmen FRP sargılı beton elemanların için yeni bir gerilme-gerinim modeli önermiştir. Model, çekme dayanımı ve sargı konfigürasyonu gibi FRP sargılarının özelliklerini dahil ederek maksimum gerilmeleri ve gerilmeleri tahmin etmiştir. Araştırma ayrıca, kısmen sargılı sistemlerde doğrusal olmayan davranışları yakalamada AI tekniklerinin esnekliğini vurgulamakta ve geleneksel modellere kıyasla gelişmiş tahmin doğruluğu sunmaktadır.

Raza ve diğerleri [56], GFRP sargılı beton kolonların eksenel yük taşıma kapasitesini tahmin etmek için YSA'yı kullanmıştır. YSA modelini eğitmek için kolon boyutları, FRP çekme dayanımı ve beton basınç dayanımı gibi girdi parametrelerini dikkate alan kapsamlı bir

deneysel veri seti kullanılmıştır. YSA modeli, doğruluk ve tutarlılık açısından geleneksel tahmin denklemlerinden daha iyi performans göstermiştir.

Cascardi ve diğerleri [57], FRP sargılı dairesel beton elemanların basınç dayanımını tahmin etmek için bir YSA modeli geliştirmiştir. Çalışma, FRP'nin tipi ve kalınlığının yanı sıra çekirdek betonun basınç dayanımı da dahil olmak üzere temel tasarım parametrelerini içermektedir. YSA modeli, deneysel veriler kullanılarak doğrulanmış ve ampirik denklemlere kıyasla üstün performans göstermiştir.

Nadimi Shahraki ve diğerleri [58], FRP sargılı betonarme elemanların eksenel ve eğilme dayanımını değerlendirmek için AI teknikleriyle güçlendirilmiş gerilme-şekil değiştirme tabanlı bir analitik yöntem önermiştir. Önerilen yöntem ile FRP sargılamasının neden olduğu doğrusal olmayan gerilme-şekil değiştirme ilişkisi, tahmin hassasiyetini artıran AI modelleri ile belirlenmiştir.

Isleem ve diğerleri [59], FRP sargılı eksantrik yüklü elemanların basınç dayanımını tahmin etmek için karar ağaçları ve rastgele ormanlar da dahil olmak üzere makine öğrenmesi modellerinin kullanımını incelemiştir. Çalışmada, FRP sargılamasının eksenel dayanım üzerindeki etkisini değerlendirilmiş ve FRP modülü ve sargı konfigürasyonları gibi önemli parametreler incelenmiştir. Makine öğrenmesi modelleri, özellikle karmaşık yükleme senaryoları altında, geleneksel modellere kıyasla yapısal davranışı tahmin etmede üstün performans göstermiştir.

Onyelowe ve diğerleri [60], CFRP sargılı betonun basınç dayanımını modellemek için AI tekniklerini kullanmıştır. Araştırma, öngörücü modeller geliştirmek için elemanın geometrisi, FRP kalınlığı ve beton basınç dayanımı gibi çok çeşitli parametreleri kapsamaktadır. Çalışmanın sonuçları, FRP'nin kalınlığı ve çekme dayanımının, sargılı kolonların basınç dayanımını önemli ölçüde etkilediğini göstermiştir. Ayrıca, Yapay Sinir Ağı (YSA) modeli, tahminleri daha doğru yaptığı için; Evrimsel Polinom Regresyonu (EPR) ve Genetik Programlama (GP) modellerinden daha başarılı bulunmuştur. Ancak, EPR ve GP modelleri kapalı formda denklemler içerdiğinden manuel hesaplamalar için pratik ve kullanışlıdır.

Liu ve diğerkleri. [61], FRP sargılı CFST kolonların eksenel basınç dayanımını tahmin etmek için veri odaklı modeller geliştirmiştir. Çalışmada sınırlı deneysel veri kümelerinin zorlukları ele alınarak sentetik veri artırımı, makine öğrenimi modellerinin eğitimini geliştirmek için kullanılmıştır. Araştırma, FRP sargısının hem mukavemet hem de süneklik üzerindeki önemli etkisini vurgulamakta ve rastgele ormanlar ve gradyan artırma gibi makine öğrenimi modellerinin tahmin doğruluğunu göstermektedir. Çalışmada, FRP sargılı CFST yapıların tasarımında yapay zeka odaklı optimizasyonun dahil edilmesine yönelik pratik öneriler sunulmuştur.

Berradia ve diğerkleri [62], enine çelik donatı ve FRP sargılı dairesel normal dayanımlı beton silindirlerin eksenel yük taşıma kapasitesini sinir ağlarını kullanarak belirlemişlerdir. Araştırma, FRP çekme dayanımı ve sargılama oranları girdi parametreleri olmuştur. Deneysel doğrulama ile modelin çeşitli kolon konfigürasyonlarında eksenel yük taşıma kapasitesini doğru bir şekilde tahmin ettiğı belirtilmiştir.

Bu çalışmaların tamamı, betonun eksenel yükleme altındaki eksenel kapasitesini tahmin etmek için kullanılan yapay zekâ modelleri üzerine anlamlı katkılar sunmaktadır. Ancak, bazı eksiklikler mevcuttur. Çalışmaların çoğunda, kullanılan algoritmaların nasıl optimize edildiğine dair ayrıntılı bir açıklama bulunmamaktadır; bu durum, modellerin tutarlılığı konusunda soru işaretleri doğurmaktadır. Bazı araştırmalarda, modele tekrarlayan parametreler dâhil edilmiştir; bu da sonuçlarda gürültüye neden olabilmektedir. Ayrıca, bazı modellerde hiperparametre ayarlaması veya optimizasyon stratejilerine hiç değinilmemiştir; bu durum, farklı veri kümeleri üzerinde yetersiz performans ve kararsız tahminlere yol açabilir. Bazı çalışmalarda ise, temel modeller test edilmeden doğrudan ileri düzey yapay zekâ modelleri kullanılmıştır. Buna karşılık, bu araştırmada temelden ileri düzeye kadar üç farklı model kullanılmış ve hangisinin en iyi performansı gösterdiği değerlendirilmiştir. Doğru sonuçlar elde edebilmek için, beş katlı çapraz doğrulama, hiperparametre optimizasyonu ve değerlendirme metrikleri gibi çeşitli veri ön işleme teknikleri uygulanmıştır. Bu ön işleme adımlarının temel amacı, eksik öğrenme (underfitting) ve aşırı öğrenme (overfitting) risklerini azaltarak makine öğrenmesi modellerinin genelleme yeteneğini artırmaktır. Bu sayede, %99'a varan doğruluk oranlarına ulaşılmıştır.



4. METODOLOJİ

Bu yöntem bölümü, FRP sargılı betonun eksenel basınç dayanımının makine öğrenmesi teknikleri kullanılarak modellenmesi amacıyla benimsenen sistematik süreci açıklamaktadır. Önerilen çalışma akışı, önceki araştırmalardan elde edilen verilerin toplanmasını, verideki aykırı değerlerin giderilmesi için ön işleme sürecini ve betonun basınç dayanımı, FRP katman sayısı ve kolon çapı gibi en etkili parametreleri belirlemek amacıyla korelasyon analizine dayalı özellik seçimini içermektedir.

Ham veri kümesi, Python kütüphaneleri kullanılarak sistematik bir şekilde temizlenmiş; tutarsız veriler elenmiş ve sayısal istikrar sağlamak amacıyla veri normalizasyonu uygulanmıştır. Veri kümesindeki eğilimler, dağılım (scatter) grafikleri ve dağılım eğrileri yardımıyla görselleştirilerek, girdi değişkenleri ile hedef değişken arasındaki ilişkilerin anlamlı bir şekilde anlaşılması sağlanmıştır. Ardından, veri eğitim ve test alt kümelerine ayrılarak modellerin genellenebilirliği değerlendirilmiştir. Model performansı; MAE, MSE, RMSE ve R^2 gibi standart regresyon değerlendirme ölçütleri kullanılarak ölçülmüş ve böylece tahmin doğruluğu kapsamlı bir şekilde analiz edilmiştir.

Veri, bu araştırmada FRP sargılı betonun eksenel dayanımının tahmin edilmesi sürecinde en önemli adımdır. Çünkü tüm süreç toplanan, analiz edilen ve modellerde kullanılmak üzere hazırlanmış veriye dayanmaktadır. Yapay zeka modellerinin doğruluğu ve güvenilirliği, kullanılan verinin kalitesine, tamamlanmışlığına ve ilişkili olmasına son derece bağlıdır. Bu çalışmada, FRP sargılı betonun boyutları, beton dayanımı, FRP kat sayısı, malzeme özellikleri ve davranışına ilişkin veriler kritik öneme sahiptir, çünkü bunlar sargılı beton elemanların eksenel basınç dayanımını etkileyen temel faktörleri içermektedir. Veriler yalnızca tahmin modelleri kurmak için bir temel sağlamakla kalmaz, aynı zamanda gerçek dünya koşullarını ve davranışlarını yansıtarak anlamlı sonuçlara ulaşmak için önemli bir bileşen haline gelir. Verinin güçlü bir şekilde işlenmesi aşamasında, özellik seçimi, veri temizliği vb. gibi adımlar atılır ve bu, verinin yapay zeka modelleri için eğitim ve doğrulukla temsil edilmesi için hazır hale getirilmesini sağlar ve giriş değişkenleri ile hedef çıktı olan eksenel dayanım arasındaki ilişkiyi doğru bir şekilde yansıtır. Uygun veri seçimi yapılmadan, modeller doğru tahminler oluşturma kapasitesinden yoksun kalır, bu da verinin bu araştırmanın başarısında oynadığı merkezi rolü vurgulamaktadır.

4.1. Veri Toplama ve Ön İşleme

Bu araştırma için veri, çeşitli araştırma makalelerinden derlenmiştir. Tez kapsamında verileri dikkate alınan çalışmalar aşağıda özetlenmiştir.

Benzaid ve diğerleri [102], karbon lifli polimer (CFRP) sargılı beton elemanları eksenel basınç yükü altında test etmişlerdir. Çalışma kapsamında dikkate alınan parametreler, kompozit katmanların sayısı ve betonun basınç dayanımıdır. Etkili çevresel FRP kopma gerinimi ve etkili yanal sargılama basıncının etkisi araştırılmıştır. Tüm test elemanları (30 adet) eksenel basınç altında kırılana kadar yüklenmiş ve numunelerin eksenel ve enine yönlerdeki davranışları incelenmiştir. Test sonuçları, CFRP sargısının beton elemanların eksenel dayanımı ve sünekliğini önemli ölçüde artırdığını göstermiştir.

Özbakkaloğlu ve diğerleri [103], eksenel basınç altında lifli polimer sargılı normal ve yüksek dayanımlı beton elemanların eksenel gerilme-şekil değiştirme davranışı üzerine deneysel bir çalışma yapmıştır. Beton elemanların çapı 152,5 mm ve yüksekliği 305 mm olan toplam 24 adet FRP sargılı beton silindir üretilmiş ve test edilmiştir. Test parametreleri arasında beton basınç dayanımı, FRP malzemesinin türü, FRP kalınlığı ve yükleme modeli yer almıştır. Sonuçlarda, belirli bir sargılama oranı f_{cc}/f_{co} için, hem dayanım artırma hem de şekil değiştirme artırma oranlarının sargılanmamış beton dayanımının artmasıyla azaldığı kaydedilmiştir. Ayrıca, ortalama FRP sargı kopma gerilmesi de artan beton dayanımı ile azalmaktadır.

Thomas ve diğerleri [104], beton basınç dayanımı ve sargılama yönteminin sargılı beton numuneler üzerindeki etkisini incelemişlerdir. Toplam 55 lifli polimer (FRP) sargılı beton numune eksenel basınç altında test edilmiştir. Tüm numuneler 152 mm çapında ve 305 mm yüksekliğinde silindirler olup karbon FRP ile sargılanmıştır. Çalışma kapsamında eksenel yük etkisinde elemanların eksenel ve yanal davranışı, eksenel gerilme-gerinim ilişkisi ve yanal gerinim davranışını incelenmiştir.

Akogbe ve diğerleri [105] eksenel basınç yüklemesine tabi tutulan karbon FRP sargılı beton silindirlerin basınç dayanımı üzerindeki boyut etkisini incelemişlerdir. Farklı boyutlarda 24 beton silindir eleman test edilmiştir. Tüm elemanlarda yanal sargılama basıncı aynı olup ve küçük numuneler bir kat karbon FRP ile, orta ve büyük numuneler sırasıyla iki ve üç kat

karbon FRP ile sargılanmıştır. Test sonuçları, tüm sargılanmış numuneler için basınç dayanımında önemli bir artış olduğunu ve ayrıca küçük ve orta numunelerin basınç dayanımlarının neredeyse aynı olduğunu, büyük numuneler için ise biraz daha düşük olduğunu göstermektedir. Bu sonuçlar, silindir boyutundan bağımsız olarak FRP sargılı numunelerin basınç dayanımı üzerinde boyut etkisinin olmadığını göstermektedir.

Karabinis ve diğerleri [106], karbon FRP sargılanmış, yükseklik/çap oranı 1,6 olan 22 adet silindirik numunenin davranışını incelemişlerdir. Numuneler, kırılana kadar eksenel yüke maruz bırakılmıştır. Karbon FRP ile sargılamanın, betonun dayanımını ve özellikle sünekliğini önemli ölçüde artırdığı görülmektedir. Bu çalışmada, çelikle sargılı beton için önerilen ve uygulanan gerilme-gerinim modeli, FRP sargılı betonun dilatasyon özelliklerini içerecek şekilde değiştirilmiş ve kalibre edilmiştir.

Cui ve diğerleri [107], tek eksenli basınç altında her biri 150 mm çapında, 300 mm yüksekliğinde toplamda 112 adet silindir beton elemanı test etmişlerdir. Test değişkenleri arasında FRP katmanlarının sayısı, FRP'nin dayanımını ve rijitliği, beton dayanımını yer almıştır. Sonuçlar, beton dayanımını artmasıyla, FRP sargısının kopmasında dayanımın artışı, enerji yutma kapasitesi, süneklik faktörü ve iş enerjisi endeksinin önemli ölçüde azaldığını göstermiştir. Beton sünekliği ile FRP kopma gerinimi arasında pozitif bir korelasyon bulunmuştur.

Lam ve diğerleri [108], çeşitli testler (Kupon çekme testleri, Yarıлма testleri ve Basınç testleri) altında iki tip FRP (karbon FRP ve cam FRP) malzemesinin nihai çekme gerilmelerini araştırmışlardır. Veriler öncelikle ASTM standartlarına uygun titiz deneysel kurulumlarla bulunan gerilme özelliklerini, gerilme-gerinim davranışlarını ve gerinim ölçümlerini kapsamıştır. Ele alınan toplam numune sayısı 18'dir. Sonuçlar, FRP kırılma dayanımının, betonu saran FRP'nin eğriliğinden ve çatlamış betonun düzensiz şekilde deformasyonundan etkilendiğini göstermiştir.

Touhari ve diğerleri [109], eksenel basınç yüklemesine maruz kalan FRP sargılı beton silindirlerin davranışını araştırmışlardır. Karbon lifli polimer (CFRP) ve cam lifli polimer (GFRP) olmak üzere 2 tip FRP kullanılarak sargılanan toplam 54 adet FRP sargılı eleman eksenel basınç altında test edilmiştir. Beton dayanımı, FRP kompozit tipi ve FRP katman sayısı gibi çeşitli parametrelerin etkileri incelenmiştir. Elde edilen sonuçlar, CFRP sargılı

beton elemanların, GFRP sargılı beton elemanlara kıyasla nihai basınç dayanımlarının daha yüksek olduğunu göstermiştir.

Tepfers ve diğerleri [110], yüksek elastisite modülüne sahip karbon lifli polimerler (CFRP) ile sargılanmış betonun davranışını incelemişlerdir. Bu çalışmada, farklı CFRP katman sayısı ve farklı beton dayanımına sahip elemanlar monotonik eksenel basınç yükü etkisinde test edilmiştir. Test edilen toplam numune sayısı 24'tür. Deneyler sonucunda elemanların gerilme-gerinim ve hacimsel gerinim eğrilerini, nihai eksenel ve yanal gerinimleri, kırılma modları incelenmiştir.

Rodsin ve diğerleri [111] FRP ile sargılanmış düşük dayanımlı beton elemanların davranışını araştırmıştır. 24 adet beton eleman, bir, iki veya üç kat FRP kullanılarak sargılanmıştır. Çalışmada, elemanların gerilme-gerinim eğrileri, nihai basınç dayanımları, eksenel ve yanal gerilmeleri, kırılma modları incelenmiştir. Deneyler sonucunda, FRP'nin yük taşıma kapasitesini ve sünekliği artırmada, sargılama seviyeleri ve beton dayanımına bağlı olarak değişen oranlarda etkili olduğu belirtilmiştir.

Yukarıdaki çalışmalardan hangi verilerin kullanıldığı Tablo 3-1'de özetlenmiştir.

Çizelge 4.1. Tüm veriler

Çalışma	Numune Sayısı	FRP Çeşidi	Beton Dayanımı
Benzaïd ve diğerleri [102]	30	CFRP,	Normal Dayanımlı Beton
Özbakkaloğlu ve ark. [103]	24	CFRP, AFRP	Normal ve Yüksek Dayanımlı Beton
Thomas ve diğerleri [104]	55	CFRP	Normal ve Yüksek Dayanımlı Beton
Akogbe ve diğerleri [105]	24	CFRP	Normal Dayanımlı Beton

Çizelge 4.1. (devam) Tüm veriler

Çalışma	Numune Sayısı	FRP Çeşidi	Beton Dayanımı
Karabinis ve diğerleri [106]	22	CFRP	Normal Dayanımlı Beton
Cui ve diğerleri [107]	112	CFRP	Normal ve Yüksek Dayanımlı Beton
Lam ve diğerleri [108]	18	CFRP, GFRP	Normal Dayanımlı Beton
Touhari ve diğerleri [109]	54	CFRP, GFRP	Normal Dayanımlı Beton
Tepfers ve diğerleri [110]	24	CFRP	Yüksek Dayanımlı Beton
Rodsin ve diğerleri [111]	24	GFRP	Normal Dayanımlı Beton

Yukarıda bahsedilen araştırma makalelerinden alınan tüm veriler bir araya getirilerek, bu analiz için faydalı olan tabloların derlendiği bir Excel dosyası oluşturulmuştur. Excel dosyası daha sonra bir CSV dosyasına dönüştürülmüştür.

Python'da yapay zeka modelleri kodlanırken, birden çok sayfa, formül ve biçimlendirme ile desteklenen Excel dosyaları daha karmaşıktır, CSV dosyaları ise daha basittir, sıralı metin dosyaları olarak veriler satır ve sütunlar halinde düzenlenir. CSV dosyaları evrensel olarak okunabilir ve CSV dosyalarında yapay zeka ve makine öğrenmeleri için verilerin işlenmesi daha hızlıdır. Excel dosyaları, daha küçük veri setleri veya ileri düzey özelliklerin gerektiği durumlar için kullanışlı olabilir ancak daha yavaş yüklenir ve daha fazla belleğe ihtiyaç duyar. CSV dosyaları, sadelikleri, performansları ve 'pandas' ve 'numpy' gibi kütüphanelerle uyumlu olmaları nedeniyle yapay zeka projeleri için genellikle tercih edilmektedir. Bir Excel dosyasını CSV dosyasına dönüştürmek için 'pandas' kütüphanesi kullanılır. Süreç, Excel dosyasını 'Pandas' kullanarak okuma ve ardından bir CSV dosyasına kaydetmeyi içerir.


Tez kapsamında yukarıda belirtilen çalışmalardan eksiksiz bir veri seti toplandı. Bu veriler, beton numune boyutları, FRP çekme dayanımı, sargılı ve sargısız beton dayanımı, FRP katman sayısı, malzeme dayanımı, FRP sargı konfigürasyonları ve eksenel yük kapasiteleri ile ilgili deneysel bilgileri içermektedir. Bu parametreler, tezin ilerleyen sayfalarında açıklanan Pearson korelasyon Isı Haritasında görülebileceği gibi, çıktı parametresi yani FRP sargılı beton dayanımı üzerinde en büyük etkiye sahip oldukları için seçilmiştir. Zaten kullanılan giriş parametrelerinden türetilen (örneğin, mevcut parametrelerin oranı gibi) parametreler, verimliliği ve doğruluğu artırmak amacıyla model eğitim sürecinde hariç tutulmuştur. Verilerin bir temsili Şekil 3.1'den görülebilir ve verilerin tamamına Ek 1'den ulaşılabilir.

Type	Naming Scheme	Diameter	Height	Fiber tensile strength	Fiber sheet thickness	Unconfined Concrete Strength	No of FRP Layers	FRP circumferential failure strain	Confined Concrete Strength	Strengthening ratio	Axial strain of the unconfined concrete at peak stress	Ultimate strain of FRP-confined concrete	Ratio
0	Carbon	I.RCC.1.1L	160.0	320	4300.0	1.0	29.51	1.0	13.15	50.59	1.714	3.77	15.93 4.225
1	Carbon	I.RCC.2.1L	160.0	320	4300.0	1.0	29.51	1.0	13.16	49.17	1.666	3.77	14.75 3.912
2	Carbon	I.RCC.1.3L	160.0	320	4300.0	3.0	29.51	3.0	14.06	70.83	2.400	3.77	22.22 5.893
3	Carbon	I.RCC.2.3L	160.0	320	4300.0	3.0	29.51	3.0	12.42	71.88	2.435	3.77	23.74 6.297
4	Carbon	I.PCC.1.1L	160.0	320	4300.0	1.0	25.93	1.0	13.12	39.63	1.528	2.73	12.78 4.681

Şekil 4.1. Veri temsili

Tez kapsamında önemli özelliklerin belirlenmesi için üç farklı kriter dikkate alınmıştır:

- Korelasyon matrisi
- Rastgele Orman özellik önem grafiği (Şekil 3.2)
- Eksik veriye sahip sütunlar, eksik değerlerin enterpolasyon ile doldurulmasının veri setine fazla gürültü eklemesi nedeniyle değerlendirme dışı bırakılmıştır.



Şekil 4.2. Özellik önem grafiği

Doğrulama ve yapay veri üretimi aşırılıkları önlediği için yapılmamış, bu da sonuçların doğruluğunu etkileyen bir sorun yaratmıştır. Toplamda 331 veri noktası kullanılmıştır. Sinir Ağları ve Rastgele Orman için, 5-katlı doğrulama ile birleşik grid araması, modellerin doğru bir şekilde ayarlanmasını ve genel geçerliliğinin test edilmesini sağlar, bu da veri setinin etkili kullanımını sağlar. Bu yöntem, aşırı öğrenme riskini azaltmaya yardımcı olur ve veri seti boyutu orta düzeyde olsa bile güvenilir performans ölçümleri sağlar. Lineer Regresyon modeline ek bir optimizasyon uygulanmasa da, modelin basitliği ve daha düşük veri gereksinimleri, daha karmaşık modellere göre veri seti boyutuna daha az duyarlı olmasını sağlar. Verilerin iyi işlenmiş ve yeterince çeşitlenmiş olması koşuluyla, 331 değerli veri boyutu, üç modelde de doğru ve güvenilir tahminler elde etmek için yeterlidir. Literatürde yer alan benzer çalışmalarda da yakın sayıda veriler kullanılmıştır. [52] [112-114].

4.2. Veri Analizi

Bu bölümde çalışma kapsamında gerçekleştirilen veri analizi ve veri analizi için kullanılan Python kütüphaneleri özetlenmiştir.

4.2.1. Kütüphaneler

Python kütüphaneleri, belirli bir görevi yerine getirmek veya yaygın karşılaşılan problemleri sıfırdan kod yazmadan çözmek amacıyla geliştirilmiş, önceden yazılmış fonksiyonlar, sınıflar ve metodlar içeren kod koleksiyonlarıdır. Python kütüphaneleri, tekrarlanan faaliyetler için test edilmiş çözümlerini kullanarak temel sorunu çözüme ulaştırmaya yardım

eder. Veri işleme, bilimsel hesaplamalar, makine öğrenimi, veri görselleştirme, web geliştirme vs. birkaç farklı alanda uygulama sahasına sahiptir. Kütüphaneler zamandan tasarruf ve tutarlılık sağlarlar. Python kütüphaneleri yaygın olarak üretkenliği artırır, çünkü kullanıma hazır araçlar sunarak programlamayı kolaylaştırır ve hızlandırır.

Veri işleme

Pandas ve NumPy, veri manipülasyonu, analiz ve sayısal hesaplama için geniş çapta kullanılan iki temel Python kütüphanesidir. İkisi de bu araştırmada, FRP sargılı betonun eksenel dayanımını tahmin etmek için gerekli verilerin işlenmesi, analiz edilmesi ve hazırlanması için önemli bir rol oynamıştır.

Pandas

Veri manipülasyonu ve analiz için güçlü bir kütüphanedir. İki temel veri yapısı sunar: Veri Çerçevesi (DataFrame) ve Seri (Series), bu da yapılandırılmış verilerin, tablolar gibi verimli bir şekilde ele alınmasını sağlar. Bu araştırmada, Pandas, veri setini düzenli bir formata dönüştürmek için kullanıldı, böylece veri temizleme ve ön işleme daha kolay hale getirildi. Eksik verilerin işlenmesi, gereksiz verilerin filtrelenmesi, eğitim ve test alt kümelerine ayırma işlemleri Pandas kullanılarak gerçekleştirildi. Pandas, endeksleme ve dönüşümler yaparak, makine öğrenme modellerine veri girmeden önce verileri hazırlamaktadır.

NumPy

Sayısal hesaplamalar üzerine odaklanmış bir kütüphanedir. Çok boyutlu diziler ve matrisler için destek sağlamanın yanı sıra bu diziler üzerinde çalışacak matematiksel işlevler de sağlar. Bu araştırmada, NumPy, verilerin matematiksel operasyonlarını gerçekleştirmek, özellikleri normalize etmek, dizileri makine öğrenme algoritmaları ile uyumlu hale getirmek veya kök ortalama kare hata gibi ölçümleri hesaplamak için kullanılmıştır. NumPy dizileri, büyük sayısal veri kümelerini verimli bir şekilde işlemek için de temel bir araçtır ve model eğitimi ve değerlendirilmesi sırasında kritik bir rol oynamaktadır.

Veri görselleştirme

Matplotlib ve Seaborn, veri görselleştirmesi için en yaygın kullanılan Python kütüphaneleridir. Her iki kütüphane de çalışma kapsamında kullanılmıştır; veri kümesindeki sonuçların ve modellerin görsel olarak temsil edilmesine yardımcı olmuştur ve FRP sargılı betonun eksenel dayanımını tahmin etmede makine öğrenimi modellerinin performansının daha iyi yorumlanmasına olanak sağlamıştır.

Matplotlib

Matplotlib çeşitli görseller, istatistiksel animasyonlar ve etkileşimli çizimler oluşturmak için bir kütüphanedir. Matplotlib, dağılma grafikleri, çizgi grafikler ve eğitim kaybı eğrileri gibi görselleştirmeleri oluşturmak için kullanılmıştır. Bu çalışmada gösterilen eğitim kaybı grafiği, Matplotlib kullanılarak çizilmiştir. Bu görselleştirme ile modelin eğitim sırasında nasıl daha iyi tahminler yaptığı ve belirli bir epoch sayısından sonra nasıl istikrara kavuştuğunu açıkça görülmüştür. Matplotlib'in grafik özelleştirme konusundaki esnekliği (örneğin, eksen etiketlerini, başlıkları ve lejantları ayarlamak) bize görsel açıdan çekici ve bilgilendirici grafikler oluşturma imkanı sunmuştur, bu da bulguların daha etkili bir şekilde iletilmesine yardımcı olmuştur.

Seaborn

Matplotlib üzerine kurulu olup, görsel olarak çekici ve istatistiksel olarak anlamlı grafikler oluşturmayı kolaylaştırır. Yüksek düzeyli bir arayüze sahiptir ve keşifsel veri analizi için özellikle tasarlanmıştır. Bu araştırmada, Seaborn, farklı özellikler arasındaki ilişkileri analiz etmek veya gerçek ve tahmin edilen değerlerin dağılımlarını karşılaştırmak için çift grafikler, ısı haritaları veya kutu grafikler gibi görselleştirmeleri oluşturmak için kullanılmıştır. Seaborn'un, modellerin tahminlerini gerçek sonuçlarla karşılaştırmak için kolayca istatistiksel katmanları ekleyebilme yeteneği, tahminleri doğrulamada faydalı olmuştur.

Scikit-learn

Python için verimli araçlar sunan, makine öğrenimi için sağlam ve yaygın olarak kullanılan bir kütüphanedir. FRP sargılı betonun eksenel dayanımını tahmin eden bu araştırmada, Scikit-Learn verileri işlemek, makine öğrenimi modellerini eğitmek ve performanslarını standartlaştırılmış ölçütlerle değerlendirmek için kullanıldı. Bu kütüphane, analiz için akıcı ve tekrarlanabilir bir iş akışı sağlamıştır ve modelin tahmin doğruluğu ve etkinliği hakkında güvenilir sonuçlar çıkarmayı kolaylaştırmıştır.

Veri ön işleme aşamasında, Scikit-Learn özellik ölçeklendirme, veri kümelerini ayırma gibi görevler için kullanılmıştır. Makine öğrenimi modelleri, sayısal özellikler standartlaştırıldığında en iyi performansı sergilediği için, Scikit-Learn'un StandardScaler'i özellikleri normalize etmek için kullanılmıştır, bu da eğitimi daha istikrarlı bir hale getirmiştir. Ayrıca, train_test_split veri kümesini; eğitim ve test kümelerine ayırmak için kullanılmıştır, böylece modelin performansı, görünmeyen verilerle doğrulanabilir hale gelmiştir.

Model eğitimi için, Scikit-Learn; Linear Regresyon, Rastgele Orman Regressörü ve Çok Katmanlı Perceptron (ÇKA) gibi modellerin temel uygulamalarını sunmuştur. Scikit-Learn araştırmada bu modellerin, eksenel dayanımın tahmin edilmesindeki etkinliklerini analiz etmek için kullanılmıştır. Scikit-Learn'un model nesneleri, eğitim ve tahmin için basit yöntemler sağlar ve uygulamayı verimli ve yönetilebilir kılar. Scikit-Learn, grid aramasıyla modelin ayarlarını (hiper parametreleri) kolayca yapmayı kolaylaştırır. Bu yöntem, farklı parametre kombinasyonlarını düzenli bir şekilde test edip, en iyi model ayarlarını bulmak için kullanılmıştır.

Değerlendirme sürecinde, Scikit-Learn; R^2 skoru, Ortalama Mutlak Hata, Ortalama Kare Hata ve Kök Ortalama Kare Hata gibi önemli metrikler ile modelin doğruluğunu ve performansını ölçmeye yardımcı olur, bunlar modelin tahmin doğruluğunu ölçmede kritiktir. Bu ölçütler, modellerin performanslarını karşılaştırmayı sağlayarak, hangisinin doğruluk ve hata oranlarına dayanarak eksenel dayanımı en iyi tahmin ettiğini net bir şekilde anlamayı mümkün kılar. Scikit-Learn'un standartlaştırılmış değerlendirme araçları sayesinde, her

model etkin bir şekilde kıyaslanmış ve tahminlerin başarısı objektif bir şekilde değerlendirilmiştir.

4.2.2. İstatistiksel parametreler

Çalışma kapsamında öncelikle tüm önemli istatistiksel parametreler hesaplanmıştır. Şekil 3.3'te görüldüğü gibi, kodun başında; veri sayısı, ortalama, standart sapma (std), minimum (min), maksimum (max) ve yüzdelikler (25%, 50%, 75%) gibi istatistiksel ölçümleri hesaplamak, veri setinin dağılımını ve değişkenliğini anlamak için başlangıçta önemli bir fikir verir. Bu değerler, veri ön işleme ve model eğitimi için merkezi eğilimleri, yayılmayı ve aralığı belirler. Örneğin, ortalama ve std ortalama değeri ve varyansı gösterirken, min ve max uç değerleri gösterir, potansiyel sapmaları belirlemeye yardımcı olur. Yüzdelikler (örneğin, 25%, 50%, 75%) veri dağılımı hakkında bilgi verir, değerlerin aralık boyunca nasıl yayıldığını gösterir. Bu anlayış, ölçekleme, normalize etme veya eksik verilerle başa çıkma konularında bilinçli kararlar almaya olanak tanır, bu da modelin doğruluğunu ve performansını artırmak için kritik adımlardır.

	Diameter	Height	Fiber tensile strength	Fiber sheet thickness	Unconfined Concrete Strength	No of FRP Layers	FRP circumferential failure strain	Confined Concrete Strength	Strengthening ratio	Axial strain of the unconfined concrete at peak stress
count	331.000000	331.000000	331.000000	331.000000	331.000000	287.000000	236.000000	329.000000	330.000000	323.000000
mean	158.450151	312.069486	2176.923021	0.428187	54.846405	2.149826	22.412076	71.306565	1.913662	3.679876
std	21.273574	36.263238	1727.358292	0.589144	28.648515	1.206853	29.103218	45.001836	0.788968	6.965628
min	100.000000	200.000000	325.000000	0.117000	5.000000	0.000000	0.500000	1.120000	0.000000	0.170000
25%	152.000000	305.000000	405.000000	0.138500	35.050000	1.000000	1.187500	42.500000	1.238080	0.247000
50%	152.000000	305.000000	849.000000	0.170000	47.760000	2.000000	10.235000	70.100000	1.697500	0.340000
75%	160.000000	320.000000	3800.000000	0.330000	79.900000	3.000000	28.525000	99.700000	2.580000	2.840000
max	300.000000	600.000000	4410.000000	3.000000	112.000000	6.000000	117.140000	198.400000	4.220000	33.900000

Şekil 4.3. İstatistiksel parametreler

4.2.3. Parametre sayısı ve veri türü

RangeIndex: 331 entries, 0 to 330			
Data columns (total 14 columns):			
#	Column	Non-Null Count	Dtype
---	-----	-----	-----
0	Type	331 non-null	object
1	Naming Scheme	319 non-null	object
2	Diameter	331 non-null	float64
3	Height	331 non-null	int64
4	Fiber tensile strength	331 non-null	float64
5	Fiber sheet thickness	331 non-null	float64
6	Unconfined Concrete Strength	331 non-null	float64
7	No of FRP Layers	331 non-null	int64
8	FRP circumferential failure strain	236 non-null	float64
9	Confined Concrete Strength	329 non-null	float64
10	Strengthening ratio	330 non-null	float64
11	Axial strain of the unconfined concrete at peak stress	323 non-null	float64
12	Ultimate strain of FRP-confined concrete	329 non-null	float64
13	Ratio	267 non-null	float64

Şekil 4.4. Parametre sayısı ve veri türü

Yukarıdaki Şekil 3.4, csv dosyasındaki verilerin null olmayan sayısını gösteriyor. Bu, kullanıcıya verinin genel bir görünümünü verir. Verinin ne kadarının mevcut olduğunu ve ne kadarının eksik olduğunu gösterir. Beton numunelerinin null olmayan sayısı ne kadar düşükse, sonuçlar o kadar doğru olur.


Bazı veri değerleri, orijinal veri setinden türediği için hariç tutulmuştur. Örneğin, şekil 3.4'te görüldüğü gibi, değişken 10 (Güçlendirme oranı, sargılı ve sargısız beton dayanımının oranı olarak tanımlanır) ve değişken 13 (Gerinim oranı, sargılı ve sargısız beton geriniminin oranı olarak tanımlanır) zaten veri setinde bulunan mevcut değişkenlerin hesaplanmış oranlarıdır. Bu tür türetilmiş değişkenler gereksizdir çünkü bu bilgiler, modelin kendisi tarafından gerektiğinde çıkarılabilir. Eğer kullanılsaydı, veri setine gürültü ekleyerek modelin tahmin doğruluğunu düşürürdü.

4.2.4. Verideki eğilimler

Bir veri setine yapay zeka modelleri uygulanmadan önce, genel veri eğilimleri çeşitli grafiklerle görselleştirilir. Bu görselleştirmeler, verinin davranışını ve karakteristiklerini anlamada yardımcı olmaktadır. Dağılım grafikleri, histogramlar veya çizgi grafikler gibi

grafikler çizilerek verilerdeki farklı modeller, ilişkiler veya anormallikler belirlenebilir. Bu süreç, normalize etme, değişken seçimi veya eksik verilerle başa çıkma gibi ön işleme adımlarına yönelik bilinçli kararlar almaya yardım eder. Bu trendleri anlamak, modelin güvenilir ve ilgili verilerle eğitilmesini sağlamak için normalizasyon, özellik seçimi veya eksik verilerin işlenmesi gibi ön işleme adımlarıyla ilgili bilinçli kararlar almayı mümkün kılar.

Türe göre beton dayanımı:



Şekil 4.5. Tipe göre beton dayanımı


Şekil 3.5'te sargı işleminde kullanılan farklı malzemeler (karbon, cam ve aramid) arasında sargılı beton dayanımını karşılaştırılmıştır. Bu grafikteki önemli noktalar şunlardır:

- Y eksenini, sargılı beton dayanımını megapaskal (MPa) cinsinden temsil eder.
- Her kutu, bir malzeme türüne karşılık gelir ve o malzeme için beton dayanım değerlerinin dağılımını gösterir.
- Her kutudaki orta çizgi, o kutunun medyan sargılı beton dayanımını gösterir.
- Kutu kenarları, birinci (Q1) ve üçüncü (Q3) çeyrekleri gösterir ve bunlar, veri setinin orta %50'sini içeren aralığı (İQR) oluşturur.

- Kutu dışına çıkan çizgiler, Q1 ile Q3 arasındaki 1,5 katlık İQR'yi kapsayan veriyi gösterir ve bu aralığın dışındaki noktalar (daireler olarak gösterilen) istatistiksel olarak sapma olarak kabul edilir.
- Veri setinde bulunan çalışmalardan elde edilen Aramid'in medyan (ortanca değer) dayanımı en yüksek gibi görünürken, karbon onu takip eder. Cam, çok daha düşük dayanım gösterirken geniş bir aralık sunar.

Bu grafik, her bir malzeme türü için beton dayanımının değişkenliğini ve merkezî eğilimini görselleştirir ve hangi malzemenin sargılı beton dayanımı açısından en iyi performansı gösterdiğine dair öngörüler ortaya koyar.

FRP katman sayısına karşı sargılanmış beton dayanımı




Şekil 4.6. Sargılanmış beton dayanımı ve frp katman sayısı

Şekil 3.6'da görülen grafiğe "violin plot" denir. Violin plot, bir kutu grafiği ve bir kernel yoğunluk grafiğinin birleşimidir ve sürekli bir değişkenin (bu durumda, sargılı beton dayanımı) farklı kategoriler (örneğin, FRP katmanlarının sayısı) arasındaki dağılımını gösterir. Grafikte önemli noktalar şunlardır:

- Y eksenli sargılı beton dayanımını megapaskal (MPa) cinsinden temsil eder ve x eksenli FRP katman sayısını (0'dan 6'ya kadar) gösterir.
- Her "violin" şekli belirli bir FRP katman sayısı için beton dayanımının dağılımını temsil eder.
- Violin'in daha geniş kısımları, veri noktalarının daha yüksek yoğunlukta olduğunu, dar olan kısımlar ise daha az sık görülen veri değerlerini gösterir.
- Her violin'in içindeki kesikli yatay çizgi, belirli bir FRP katman sayısı için medyan sargılı beton dayanımını temsil eder.
- FRP katman sayısı arttıkça, beton dayanımının dağılımı genellikle daha yüksek değerlere kayar ve medyan dayanım artar.
- Dağılım (değişkenlik), özellikle 4 katmandan sonra beton dayanımında azalır.

Bu durum, daha fazla FRP katmanı eklemenin sargılı betonun dayanımını artırdığını göstermektedir.



Şekil 4.7. Sargılanmamış beton dayanımı ve sargılanmış beton dayanımı

Şekil 3.7’de sunulan grafiğe "Joint Plot" (veya Scatter Plot ile Marjinal Histogramlar) denir. Bir scatter grafiğini, histogramlar veya kernel yoğunluk grafikleri ile birleştirir. Grafikteki önemli noktalar şunlardır:

- Orta kısımda yer alan ana grafik, Sargısız Beton Dayanımı (x eksen) ile Sargılı Beton Dayanımı (y eksen) arasındaki ilişkiyi gösteren bir scatter plot'tur. Grafik bireysel veri noktalarını gösterir ve genel pozitif korelasyonu işaret eden bir eğri çizgisi verir.
- Ana grafiğin üst ve sağındaki marjinal histogramlar, sargısız beton dayanımı ve sargılı beton dayanımı'nın ayrı ayrı dağılımlarını gösterir.

- Grafik, sargısız beton dayanımı arttıkça sargılı beton dayanımının da arttığını, iki değişken arasında genellikle doğrusal bir ilişki olduğunu gösteriyor.


Bu görselleştirme, her iki beton dayanım türünün bireysel dağılımlarını ve aralarındaki ilişkiyi anlamayı kolaylaştırır.

4.2.5. Pearson korelasyon ısı haritası

Pearson korelasyon ısı haritası, çoklu değişkenler arasındaki doğrusal ilişkileri görsel olarak gösterir (Şekil 3.8). Pearson korelasyon katsayısı (r olarak gösterilir), iki değişken arasındaki ilişki gücünü ve yönünü gösterir, -1 ile +1 arasında değişir:

- $r=+1$: Mükemmel pozitif korelasyon (bir değişken arttıkça diğer değişken de artar).
- $r=-1$: Mükemmel negatif korelasyon (bir değişken arttıkça diğer değişken azalır).
- $r=0$: Hiçbir korelasyon (değişkenler bağımsızdır).

Isı haritası, korelasyonun gücünü göstermek için bir renk gradyanı kullanır; sıcak renkler (örneğin, koyu yeşil) genellikle daha yüksek pozitif korelasyonu ve soğuk renkler (örneğin, koyu kahverengi) daha yüksek negatif korelasyonu temsil etmektedir.



Şekil 4.8. Pearson korelasyon ısı haritası

Sargılı beton dayanımı; geometrik, malzeme ve sargı ile ilgili faktörlerden etkilenir, ancak en önemlileri aşağıda maddeler halinde açıklanmıştır:

Çap vs. sargılı beton dayanımı

Şekil 3.8'e göre, elemanın çapı ve sargılı beton dayanımı arasında negatif korelasyon vardır ve eleman çapı arttıkça sargılı beton dayanımının hafifçe azaldığını gösterir. Daha büyük çaplı elemanlarda, sargının etkinliğini daha azdır, çünkü FRP katmanları tarafından uygulanan yanal sargı basıncı, daha büyük kesitleri sınırlamada daha az verimli hale gelebilir. Sargı etkisi; daha küçük kesitlerde, yanal sargı basıncının daha uniform bir şekilde uygulandığı yerlerde daha belirgindir.

Yükseklik vs. sargılı beton dayanımı

Şekil 3.8'de görüldüğü gibi, eleman boyutları arttıkça sargılama etkisi azalır. Eleman uzunluğu arttıkça, elemanlarda burkulma ve narinlik etkileri daha fazla olacağından, FRP ile

yapılan güçlendirmenin verimliliği azalabilir. Ayrıca, düşey deformasyonlar, gerilmenin düzensiz dağılmasına yol açarak toplam sargı etkisini azaltabilir.

Lif çekme dayanımı vs. sargılı beton dayanımı

Şekil 3.8’de sunulan verilere göre, lif çekme dayanımı ile sargılı beton dayanımı arasında pozitif korelasyon vardır. Daha yüksek çekme dayanımına sahip FRP malzemesi, basınç dayanımını iyileştirerek sargı basıncını artırır. Ancak, sınırlı korelasyon, diğer faktörlerin (örneğin FRP katmanlarının sayısı) de önemli bir rol oynadığını göstermektedir.

Sargılanmamış beton dayanımı vs. sargılı beton dayanımı

Şekil 3.8’de görüldüğü üzere, 0.66 değeri, orta derecede güçlü bir pozitif doğrusal ilişki olduğunu gösterir. Bu da, sargılanmamış betonun dayanımı arttıkça, FRP sargılı betonun dayanımının da genellikle arttığını gösterir. Ancak bu değer çok yüksek bir korelasyon (örneğin 0.9 gibi) olmadığı için, tek bir girdinin sonucu belirlemediği görülmektedir. Yani, FRP sargılı betonun dayanımı; lif çekme dayanımı, lifli polimer katman sayısı ve güçlendirme oranı gibi birçok farklı girdinin birlikte etkisiyle oluşmaktadır.

FRP katman sayısı vs. sargılı beton dayanımı

Şekil 3.8’de görüldüğü gibi, pozitif bir korelasyon, FRP katman sayısındaki artışın sargılı beton dayanımını artırdığını gösterir. Daha fazla FRP katmanı, sargı basıncını artırarak eksenel yükleri daha yüksek dayanımla karşılar. Uygulanan katman sayısı ne kadar fazlaysa, yanal basınç o kadar yüksek olur ve bu da dayanımı iyileştirir. Bununla birlikte, ek katmanlar belirli bir eşiğin ötesinde daha az etki gösterebilir.

Genel olarak, sargılı beton dayanımı, sargısız betonun dayanımı ve FRP katmanlarının sağladığı sargı derecesine önemli ölçüde bağlıdır. İstenen performans seviyelerine ulaşmak için uygun malzemeler, geometri ve FRP düzenleme şekli seçilerek tasarımların optimize edilmesine sağlanır.

4.2.6. Etiket kodlayıcı

Bu araştırmada incelenen elemanların sargılanmasında üç tip FRP kullanılmıştır: karbon lif, cam lif ve aramid lif. Bu lif türleri başlangıçta vektör veya dize değerleri (yani karakter verileri) olarak temsil edildiğinden, hesaplama işlemi için sayısal forma dönüştürülmeleri gerekiyordu. Bu nedenle; karbon, cam ve aramid liflere sırasıyla 1, 2 ve 3 değerleri atanarak etiket kodlaması yapılmıştır.

```
X = df[['type', 'diameter', 'height', 'fiber_tensile_strength',
        'fiber_sheet_thickness', 'unconfined_concrete_strength',
        'axial_strain', 'ultimate_strain', 'strengthening_ratio']].copy(deep=True)
y = df[['confined_concrete_strength']].copy(deep=True)

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.15, random_state=42)
```

Şekil 4.9. Etiket kodlayıcı kodu

Şekil 3.9 ‘da görüldüğü gibi, kodda tüm eğitim değişkenleri x olarak kaydedilir ve tahmin edici değişken y olarak kaydedilir. Bu x ve y değerleri X_train, X_test ve Y_train, Y_test olarak dönüştürülür ve test boyutu 0.15 olarak ayarlanır, bu da eğitime verilerinin %85’inin ve model testinde kullanılan verilerin %15’inin olduğunu göstermektedir. Y_test ve Y_predicted değerleri, modelin doğruluğunu kontrol etmek için karşılaştırılır. Rastgele durumu “random state” parametresi, eğitim ve test kümeleri arasındaki rastgeleliği kontrol eder. Rastgele durumu belirli bir numaraya sabitleyerek, sonuçlar tekrar edilebilir hale gelir; aynı kodun her çalıştırılmasında veri aynı şekilde bölünür.

4.2.7. Standart ölçekleyici

Makine öğrenmesinde ölçekleme (scaling), verilerin dönüştürülerek tüm özelliklerin benzer aralıklarda olmasının sağlanmasıdır. Bu işlem özellikle mesafe hesaplamalarına dayanan algoritmalar (örneğin doğrusal regresyon, en yakın komşu algoritması, yapay sinir ağları gibi) için çok önemlidir. Çünkü bu tür algoritmalar, giriş özelliklerinin ölçeklerinden etkilenebilir. Ölçekleme sayesinde, herhangi bir özelliğin sadece büyük sayılar içerdiği için

diğerlerinden daha etkili olması önlenir ve model tüm özellikleri eşit şekilde değerlendirebilir.


```
scaling_columns = ['diameter', 'height', 'fiber_tensile_strength', 'fiber_sheet_thickness',
                  'unconfined_concrete_strength', 'axial_strain', 'ultimate_strain', 'strengthening_ratio']
scaler = StandardScaler()
X_train[scaling_columns] = scaler.fit_transform(X_train[scaling_columns])
X_test[scaling_columns] = scaler.transform(X_test[scaling_columns])
```

Şekil 4.10. Sütun ölçekleme kodu


Standard Scaler, verideki tüm özelliklerin daha dengeli hale getirilmesini sağlayan bir yöntemdir. Bazen veri setindeki farklı elemanlar farklı değer aralıklarına sahip olabilir. Örneğin, bir elemanın değerleri 100–300 arasında olabilirken, başka bir eleman sadece 0 ile 1 arasında değişebilir. Böyle bir veri doğrudan modele verilirse, büyük sayılar içeren özellikler daha fazla ağırlık kazanabilir; oysa bu özelliklerin gerçekte daha önemli olması gerekmez.

Bunu önlemek için Standard Scaler algoritması kullanılır. Bu algoritma, her elemandaki her değerden önce o elemanın ortalamasını (mean) çıkarır, sonra sonucu standart sapmaya (standard deviation) böler. Standart sapma, sayıların ne kadar yayıldığını gösteren bir ölçüdür. Bu işlem sonucunda her elemanın ortalaması 0, standart sapması ise 1 olur.

Şekil 3.11’de ölçekleme yapılmamış orijinal veriler gösterilmiştir. Histogramlarda her özelliğin değerlerinin nasıl dağıldığı görülmektedir. Bazı özellikler çok geniş bir aralıkta, bazıları ise çok dar bir aralıkta yayılmıştır. Şekil 3.12’de ise Standard Scaler uygulandıktan sonra tüm özelliklerin 0 etrafında daha dengeli ve merkezi bir şekilde dağıldığı gözlemlenmektedir. Bu durum, makine öğrenmesi modellerinin veriyi daha iyi anlamasını ve tahminler yapmasını sağlar.



Şekil 4.11. Özelliklerin dağılımı



Şekil 4.12. Özelliklerin dağılımı (ölçeklendirilmiş)

Kodda, ölçekleme işlemi sklearn kütüphanesinin preprocessing modülündeki StandardScaler kullanılarak yapılmaktadır. Öncelikle, fit_transform fonksiyonu eğitim verisine uygulanır (Şekil 3.10). Bu yöntem, eğitim setindeki her bir özelliğin ortalamasını ve standart sapmasını hesaplar ve ardından bu değerleri kullanarak veriyi ölçeklendirir. Yani, her bir özellikten ortalama çıkarılır ve sonuç standart sapmaya bölünür. Böylece veriler 0 ortalama ve 1 standart sapma olacak şekilde merkezlenmiş olur. Test verisine ise aynı ölçekleme işlemi, transform fonksiyonu ile uygulanır. Bu aşamada, eğitim verisinden öğrenilen ortalama ve standart sapma değerleri tekrar hesaplanmaz, doğrudan test verisine uygulanır.

Makine öğrenmesi modellerinin eğitimi sırasında ölçekleme çok önemlidir, çünkü algoritmalarda yakınsamanın (convergence) daha hızlı ve sağlıklı olmasına yardımcı olur. Ayrıca, büyük sayısal değerlere sahip özelliklerin modele daha fazla etki etmesini önleyerek, tüm özelliklerin öğrenme sürecine eşit şekilde katılmasını sağlar.

4.3. Makine Öğrenmesi Model Seçimi

Daha önce de belirtildiği gibi, FRP sargılı betonun eksenel dayanımını tahmin etmek için üç model seçildi: Doğrusal Regresyon, Rastgele Orman ve Yapay Sinir Ağları (YSA). Bu modeller, verilerdeki hem doğrusal hem de karmaşık, doğrusal olmayan ilişkileri ele almak için kapsamlı bir yaklaşım gösterir. Seçim nedenleri aşağıda detaylandırılmıştır.

Doğrusal regresyon, regresyon görevleri için temel ve yaygın olarak kullanılan bir istatistiksel yöntemdir. Doğrusal regresyon, bağımsız değişkenler (özellikler) ile bağımlı değişken (elemanların eksenel dayanımı) arasında doğrusal bir ilişki varsayar. Hedef değeri, aşağıda belirtilen formda doğrusal bir denklemle tahmin eder:

$$y = a + bx_0 + cx_1 + dx_2 + \dots$$

Bu denklemde, 'a', 'b', 'c' katsayıları her bir giriş özelliğinin (örneğin, eleman boyutları, FRP özellikleri) katkısını temsil ederken, 'x_n' belirtilen özellik değerlerini gösterir. Basitliğine rağmen doğrusal regresyon, daha karmaşık modellerle karşılaştırılmak üzere faydalı bir başlangıç noktasıdır. Araştırmaya bu tür basit bir modelle başlamak, özelliklerle eksenel dayanım arasındaki olası doğrusal ilişkiyi değerlendirmek için uygun bir adımdır.

Doğrusal regresyonun iyi çalışması durumunda, problem aşırı karmaşık modellere ihtiyaç duymaz. Çoğu tahmin modeli görevinde doğrusal regresyon, anlaşılabilirliği ve yorumlanabilirliği nedeniyle kullanılır. Ayrıca, verilerdeki doğrusal kalıpları belirlemeye olanak tanır, bu da değişkenler arasındaki ilişkileri anlamak için bir temeldir.

Çalışmada kullanılan bir diğer model, Rastgele Orman (Random Forest) modelidir. Rastgele Orman, karar ağaçlarına dayanan bir birleşik öğrenme yöntemidir ve giriş özellikleri ile hedef değişken arasındaki doğrusal olmayan ilişkileri yakalamada oldukça etkilidir. Doğrusal regresyonun aksine, Rastgele Orman, özellikler ile hedef arasında belirli bir ilişki varsaymaz; bunun yerine, farklı veri kümeleri kullanılarak birçok karar ağacı inşa eder ve bu ağacın tahminlerini ortalılar. Bu yöntem, değişkenler arasındaki etkileşimlerin karmaşık ve doğrusal olmadığı yüksek boyutlu verilerle çalışırken çok güçlüdür. Örneğin, FRP sargılı betonun aksel dayanımını tahmin ederken, FRP kalınlığı, beton dayanımı ve eleman geometrisi gibi özellikler arasındaki ilişkiler doğrusal olmaktan uzaktır ve Rastgele Orman bu karmaşıklıkları farklı veri parçaları üzerine yerleştirilen birçok karar ağacı ile çözebilir.

Rastgele Orman'ın bir diğer önemli avantajı, aşırı öğrenmeye (overfitting) karşı dayanıklı olmasıdır. Aşırı öğrenme, bir modelin eğitim verilerine fazla uyarlanarak yeni, görülmemiş verilerde kötü performans göstermesi durumudur. Rastgele Orman, bu riski ortadan kaldırarak, birçok ağacın tahminlerini ortalayarak aşırı öğrenme olasılığını azaltır. Ayrıca, Rastgele Orman, özellik önemi ölçümleri sağlar ve modelin aksel dayanımı tahmin etmede hangi giriş değişkenlerinin en etkili olduğunu belirlemesine imkân verir. Bu, mühendislik uygulamaları için özellikle değerlidir, çünkü her bir değişkenin rolünü anlamak, tasarım ve karar verme süreçlerini bilgilendirir. Rastgele Orman modeli, doğrusal olmayan örüntüleri öğrenme yeteneği, aşırı uyum riskine karşı dayanıklı yapısı ve değişken önemini etkili şekilde belirleyebilmesi nedeniyle çalışmada tercih edilmiştir.

Yapay Sinir Ağları (YSA), en karmaşık ve doğrusal olmayan ilişkileri öğrenme yeteneği gibi özellikleri nedeniyle tez kapsamında model seçimine dahil edilmiştir. YSA'lar, insan beyninin yapısına ve işleyişine dayanan bir tür makine öğrenimi modelidir. Bir dizi nörondan oluşur, burada her bir nöron bir önceki ve sonraki katmandaki nöronlarla bağlantılıdır. Her bağlantının gücü, tahmin hatasını minimize etmek amacıyla eğitim sırasında ayarlanır. YSA'lar, verilerdeki temel desenleri yakalamakta zorlanan geleneksel modeller için özellikle uygundur. Bu araştırmada, FRP sargılı betonun aksel dayanımı, beton elemanın

geometrisi, malzeme özellikleri gibi birçok bağımlı faktörden etkilenebilir. YSA'lar, bu karmaşık kalıpları öğrenmek için bir dizi nöron ve doğrusal olmayan aktivasyon fonksiyonları aracılığıyla çalışabilir ve verilerdeki en karmaşık ilişkileri modellemek için bu yeteneklere sahiptir.

Ayrıca, YSA'ların mimarisi oldukça esnektir. Bu nedenle YSA'lar ; katman sayısı, her katmandaki nöron sayısı ve diğer hiper parametreleri, örneğin öğrenme hızını ve aktivasyon fonksiyonlarını düzenleyerek belirli bir probleme uyarlanabilir. Bu esneklik, YSA'ları değişkenler arasındaki karmaşık etkileşimleri yakalamada güçlü bir araç haline getirir. Ayrıca, yeterli veri ile YSA'lar yüksek doğruluk sağlayabilir, bu da onları karmaşık desen ve ilişkilerin yer aldığı görevler için ideal bir seçenek haline getirir.

4.4. Model Eğitimi ve Değerlendirilmesi

Bu araştırmada, ana hedefimiz, FRP sargılı betonun aksenal dayanımını tahmin eden makine öğrenimi modellerinin geliştirilmesi ve değerlendirilmesidir. Model eğitimi süreci; giriş değişkenleri ile hedef değer arasındaki ilişkileri ve örüntüleri öğrenmeleri amacıyla, önceden işlenmiş veri kümelerinin makine öğrenmesi algoritmalarına sunulmasını içermektedir. Çalışmada kullanılan her model (doğrusal regresyon, rastgele orman ve yapay sinir ağları) verilerle eğitilmiş; R^2 , MAE, MSE ve RMSE gibi değerlendirme metrikler kullanılarak, modellerin tahmin doğruluğu ve performansı değerlendirilmiştir. Bu yaklaşım, modellerin detaylı bir şekilde karşılaştırılmasına imkân tanır ve veri setinin özelliklerini ne kadar iyi yansıttıklarını anlamamıza olanak verir.

4.4.1. K-kat çapraz doğrulama (k-fold cross-validation)

K-kat çapraz doğrulama, makine öğrenmesinde modellerin performansını ve güvenilirliğini değerlendirmek için yaygın olarak kullanılan bir tekniktir. Bu araştırmada, üç farklı algoritmaya uygulanmıştır: Doğrusal Regresyon, Rastgele Orman ve Multilayer Perceptron (ÇKA). Süreç, veri setinin beş eşit parçaya (fold) bölünmesiyle başlar. "Shuffle" parametresi ayarlandığında, veriler bölünmeden önce rastgele karıştırılır, bu da model değerlendirmesinde yanlılığı ortadan kaldırır. Ayrıca, "random state" parametresi verilerin tekrarlanabilir bir şekilde karıştırılmasını sağlar; yani kod her çalıştırıldığında aynı rastgele bölünmeler yapılır, bu da tutarlı sonuçlar için önemlidir.

```

k = 5 # Number of folds
best_val_loss = float('inf') # Initialize best validation loss to a large value
best_model = None

kf = KFold(n_splits=k, shuffle=True, random_state=42)

for fold, (train_idx, val_idx) in enumerate(kf.split(new_X_train)):
    print(f"Training fold {fold + 1}/{k}")

    X_train_fold, X_val_fold = new_X_train.iloc[train_idx], new_X_train.iloc[val_idx]
    y_train_fold, y_val_fold = new_y_train.iloc[train_idx], new_y_train.iloc[val_idx]

    linear = LinearRegression()

    linear.fit(X_train_fold, y_train_fold.to_numpy().ravel())

    y_val_pred = linear.predict(X_val_fold)

    val_loss = mean_squared_error(y_val_fold, y_val_pred)
    print(f"Fold {fold + 1} Validation Loss: {val_loss}")

    if val_loss < best_val_loss:
        best_val_loss = val_loss
        best_model = linear

linear = best_model

print(f"Best model with validation loss {best_val_loss} is saved.")

```

Şekil 4.13. K-kat çapraz doğrulama kodu

Şekil 3.13'te K-kat çapraz doğrulama kodu gösterilmiştir. Her K-Kat Çapraz Doğrulama sürecindeki her bir iterasyonda, bir fold (bölüm) doğrulama veri seti olarak seçilirken, diğer dört fold modelin eğitimi için kullanılır. Eğitim ve doğrulama veri setleri, `kf.split(new_X_train)` yöntemi ile belirlenir. Burada `new_X_train`, veri setinin özelliklerini içerir. Bu adımda, eğitim ve doğrulama veri alt kümeleri oluşturulur. Daha sonra, modelin yeni bir örneği oluşturulur ve `fit()` yöntemi kullanılarak eğitim verileriyle eğitilir. Bu adım, modelin, özellikler ile hedef değişken arasındaki ilişkileri öğrenmesini içerir.

Model eğitildikten sonra, performansı doğrulama seti üzerinde test edilerek değerlendirilir. Model, doğrulama verileriyle tahminler yapar ve bu tahminlerin doğruluğu ortalama kare hata yöntemiyle hesaplanarak ölçülür. Doğrulama kaybı (validation loss), modelin ne kadar

iyi çalıştığını sayısal olarak gösterir; düşük bir kayıp, daha iyi bir doğruluk anlamına gelir. Bu süreçte en önemli nokta, tüm katlamalar (folds) arasından en iyi performansı gösteren modelin belirlenmesidir. Her katlamadan sonra kod, o anki doğrulama kaybının daha önce kaydedilen en iyi kayıptan düşük olup olmadığını kontrol eder. Eğer düşükse, `best_val_loss` güncellenir ve mevcut model `best_model` olarak kaydedilir. Böylece, K-Kat Çapraz Doğrulama tamamlandığında, doğrulama verileri üzerinde en iyi sonucu veren model seçilmiş olur.

Beş katlamanın (folds) sonunda, en düşük doğrulama kaybını veren model nihai model olarak seçilir ve yeni, görülmemiş veriler üzerinde tahmin yapmaya başlanır. K-Kat Çapraz Doğrulama yöntemi, modelin değerlendirmesini daha verimli hale getirir, aşırı öğrenme (overfitting) riskini düşürür ve en iyi modelin belirlenmesini kolaylaştırır. Bu yöntemde her model, farklı veri grupları üzerinde test edildiği için, modelin gerçek dünyadaki performansı hakkında daha güvenilir bir değerlendirme yapılmaktadır. Bu nedenle, doğrusal regresyon, rastgele orman ve çok katmanlı algılayıcı üzerine bu tekniği uygulamak, model değerlendirmelerinin güvenilirliğini artırır ve genel makine öğrenimi görevlerinin performansını optimize eder. Böylece daha doğru tahminler üretir ve modelin yeteneklerine olan güveni artırır.

```
Training fold 1/5
Fold 1 Validation Loss: 664.2915899905751
Training fold 2/5
Fold 2 Validation Loss: 572.3557202643648
Training fold 3/5
Fold 3 Validation Loss: 520.979354968257
Training fold 4/5
Fold 4 Validation Loss: 484.9967324442195
Training fold 5/5
Fold 5 Validation Loss: 305.32945187763875
Best model with validation loss 305.32945187763875 is saved.
```

Şekil 4.14. K-kat çapraz doğrulama sonuçları

Yukarıdaki grafikten (Şekil 3.14) görülebileceği üzere, birinci katmanda doğrulama kaybı yaklaşık 664.29 olarak rapor edilmiştir. Katmanlar ilerledikçe, doğrulama kaybında genel

bir azalma trendi gözlemlenmektedir: ikinci katmanda 572.36, üçüncü katmanda 520.98, dördüncü katmanda 485.00 ve sonunda beşinci katmanda 305.33'e düşüyor. Bu trend, modelin her bir iterasyonda performansını geliştirdiğini ve eğitim verilerinden etkin bir şekilde öğrenmekte olduğunu göstermektedir. Azalan kayıp değerleri, modelin tahminlerinin gerçek değerlere giderek daha yakın olduğunu gösterir.

"Doğrulama kaybı 305.3 olan en iyi model kaydedildi" ifadesi, modelin beşinci katmanda en iyi performansı gösterdiğini ve en düşük doğrulama kaybını elde ettiğini belirtir. Eğitim verisinin farklı bölümlerinde başarılı tahminler yapmış olduğu için bu sonuç, modelin yeni görülmemiş verilerle de iyi çalışabileceğini göstermektedir.

4.4.2. Hiper parametreler

Hiper parametreler, modelin nasıl öğrendiğini etkileyen, makine öğrenmesi modelleri için eğitimden önce ayarlanan dışsal değerlerdir. Model, parametrelerden farklı olarak, bunları eğitim sırasında değiştirmez; hiper parametreler önceden belirlenir ve modelin performansını, karmaşıklığını ve genelleme yeteneğini doğrudan etkiler. Bu çalışmada, kod GridSearchCV kullanarak hiper parametre ayarlaması yapılmaktadır. GridSearchCV, belirlenen hiper parametrelerin farklı kombinasyonlarını dener ve en iyi sonucu veren ayarları bulur. Bu işlem sırasında, farklı hiper parametrelerle birçok model oluşturulur ve çapraz doğrulama (Cross validation) kullanılarak hangi ayarların en iyi performansı sağladığı belirlenir.

Rastgele orman kodu

Şekil 3.15'te yer alan kod, Rastgele Orman Regressor modeline yönelik hiperparametre ayarlaması gerçekleştirmektedir ve bunun için GridSearchCV yöntemini kullanmaktadır. Burada, Rastgele Orman modelinin bazı ayarları (hiperparametreleri) optimize edilmektedir.

```

param_grid = {
    'n_estimators': [100, 200, 300],
    'max_depth': [10, 20, 30, None],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'bootstrap': [True, False]
}

rf_cv = GridSearchCV(RandomForestRegressor(), param_grid, cv=5, scoring='r2')
rf_cv.fit(X_train, y_train.to_numpy().ravel())

print(f"Best Hyperparameters: {rf_cv.best_params_}")

```

Best Hyperparameters: {'bootstrap': True, 'max_depth': 30, 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 100}

Şekil 4.15. Rastgele orman hiperparametreler'in kodu

Şekil 3.15'te yer alan hiperparametrelerin her birinin anlamı aşağıda açıklanmıştır.

- *n_estimators*: Bu hiperparametre, ormandaki ağaç sayısını belirler. Daha fazla ağaç, genellikle daha iyi doğruluk gösterir, ancak aynı zamanda daha fazla işlem gücü gerektirir.
- *max_depth*: Bu hiperparametre, her ağacın maksimum derinliğini sınırlar. Derinlik arttıkça model daha karmaşık olur ve aşırı öğrenme (overfitting) riski artar.
- *min_samples_split*: Bir düğümü bölmek için gerekli minimum örnek sayısını belirler; dallanmayı kontrol eder.
- *min_samples_leaf*: Bir yaprak oluşturmak için gerekli minimum örnek sayısını belirler.
- *Bootstrap*: Bu parametre, her ağacı oluştururken örnekleme yöntemini belirler. True olarak ayarlandığında, her ağaç farklı rastgele seçilmiş verilerle oluşturulur. Bootstrap örnekleme, bir veri setinden değişimle rastgele veri noktaları seçme tekniğidir; bu parametre bazı noktaların birden fazla kez seçilebileceği, bazılarının ise hiç seçilmeyeceği anlamına gelir. Bu parametre, Rastgele Orman içindeki her ağacı biraz farklı yaparak modelin daha çeşitli ve genellenebilir olmasına yardımcı olur, aşırı öğrenme (overfitting) riskini azaltır.

Bu yöntem, her bir hiperparametre için farklı değerlerin yer aldığı bir ızgara (grid) oluşturur. Çalışma kapsamında geliştirilen kod, aşağıda belirtilen farklı kombinasyonları dener.

- Ağaç sayısı: 100, 200, 300
- Maksimum derinlik: 10, 20, 30 veya limitsiz

- `min_samples_split` ve `min_samples_leaf` için farklı değerler
- Bootstrap özelliğini açık veya kapalı olarak test eder.

Bu sayede, modelin en iyi performans gösterdiği hiper parametreler bulunur ve sonuç olarak daha doğru tahminler yapılabilir.

`GridSearchCV` kullanarak, kod bu hiper parametre kombinasyonlarının her biri için Rastgele Orman modelini eğitir ve 5 katlı çapraz doğrulama ($cv=5$) kullanarak modelin performansını değerlendirir. Yani her parametre kombinasyonu için veri seti 5 farklı parçaya bölünür, model 4 parçada eğitilir ve kalan parçada test edilir. Bu işlem, doğru bir değerlendirme sağlamak için beş kez tekrarlanır.

Optimize edilen ana performans ölçütü, modelin hedef değişkeni ne kadar iyi tahmin ettiğini ölçen R-kare (R^2) skorudur. R-kare değeri ne kadar yüksekse, model verideki değişkenliği o kadar iyi açıklar. Çapraz doğrulama işlemi tamamlandıktan sonra, `GridSearchCV` en iyi performansı veren hiper parametre kombinasyonunu belirler.

Son olarak, kod en iyi hiper parametreleri ekrana yazdırır. Bu parametre kombinasyonu, dataset ve tanımlanan grid'e dayalı olarak Rastgele Orman modelinin en iyi performansı göstermesini ve tahminlerde daha iyi sonuçlar almasını sağlar. Genel olarak, bu kod Rastgele Orman modelini otomatik olarak iyileştirir, böylece en iyi sonuçları alır.

Çok katmanlı algılayıcı (çka) kodu

Bu kod, ÇKA Regressor adlı yapay sinir ağı modelinin en iyi hiper parametrelerini bulmak için tasarlanmıştır. Amaç, Rastgele Orman gibi `GridSearchCV` yöntemini kullanarak ÇKA'nın ayarlarını en iyi şekilde yapmak ve eğitim verisinde en yüksek doğruluğa ulaşmaktır. Kod, `param_grid` adlı bir sözlük içinde denenecek farklı hiper parametre değerlerini tanımlar. `GridSearchCV`, bu değerlerin tüm kombinasyonlarını test ederek hangi ayarların en iyi model performansını verdiğini bulur.

```

param_grid = {
    'hidden_layer_sizes': [(100, 500, 100), (200, 300)],
    'learning_rate_init': [0.001, 0.01, 0.1],
    'max_iter': [500, 1000],
}

mlp_cv = GridSearchCV(MLPRegressor(), param_grid, cv=5, scoring='r2')
mlp_cv.fit(X_train, y_train.to_numpy().ravel())

print(f"Best Hyperparameters: {mlp_cv.best_params_}")

```

Şekil 4.16. Çok katmanlı algılayıcı (çka) hiper parametreler'in kodu

Şekil 3.16'da görüldüğü gibi, denenen Hiper parametreler şunlardır:

- *Hidden_layer_sizes (gizli katman boyutları):*
 - Yapay sinir ağındaki gizli katmanların yapısını belirler.
 - Örneğin, (100, 500, 100) üç gizli katman içerir ve sırasıyla 100, 500 ve 100 nörona sahiptir.
 - Bu yapı, modelin karmaşık ilişkileri öğrenme yeteneğini etkiler.
- *Learning_rate_init (başlangıç öğrenme oranı):*
 - Modelin her adımda ne kadar hızla öğrendiğini belirler.
 - Daha düşük değerler daha yavaş ama daha istikrarlı bir öğrenme süreci sağlar.
- *Max_iter (maksimum iterasyon sayısı):*
 - Modelin kaç kez eğitimden geçeceğini belirler.
 - Sonsuz döngüleri önlemek için bir sınır koyar.

GridSearchCV, eğitim verisi üzerinde 5 katlı çapraz doğrulama (cv=5) yapar. Yani, veri 5 parçaya bölünür, model 4 parça ile eğitilir ve 1 parça ile test edilir. Bu işlem, her hiper parametre kombinasyonu için tekrarlanır ve R-kare (R-squared) skoru kullanılarak performans ölçülür. Tüm kombinasyonlar denendikten sonra, en iyi ortalama R-kare skorunu veren hiperparametreler seçilir. Bu seçim, modelin karmaşıklığını ve doğruluğunu dengelemek için önemlidir. En iyi hiper parametreler belirlendikten sonra, gizli katman boyutları, öğrenme oranı ve iterasyon sayısı ekrana yazdırılır.

Genel olarak, bu kod ÇKA Regressor modelinin ayarlarını otomatik olarak yapar. Böylece model, verideki desenleri mümkün olduğunca doğru öğrenebilir. Bu optimizasyon süreci, yapay sinir ağları için çok önemlidir, çünkü doğru hiper parametreleri seçmek hem eğitim süresini hem de modelin doğruluğunu büyük ölçüde etkileyebilir.

4.4.3. Değerlendirme metrikleri

Tahminler yapıldıktan sonra, bir sonraki adım bu tahmin edilen değerlerin gerçek hedef değerlerle karşılaştırılmasıdır. Modelin ne kadar doğru performans gösterdiğini belirlemek için çeşitli değerlendirme matrisleri hesaplanır. Bu metrikler, modelin tahminleri ile gerçek sonuçlar arasındaki farkı nicelleştirir. Özel olarak, kod dört yaygın metrik hesaplar: R-kare (R^2), Ortalama Mutlak Hata, Ortalama Kare Hata ve Karekök Ortalama Kare Hata.

```
r2 = round(r2_score(y_test, y_pred), 3)
mae = round(mean_absolute_error(y_test, y_pred), 3)
mse = round(mean_squared_error(y_test, y_pred), 3)
rmse = round(np.sqrt(mse), 2)

n = len(y_test) # Number of observations
p = X_test.shape[1] # Number of predictors
adj_r2 = adjusted_r2(r2, n, p)
```

Şekil 4.17. Değerlendirme parametreleri

R-kare (R^2) ve düzeltilmiş R-kare (adj_R^2)

Şekil 3.17’de birinci satırdaki formül, R-kare değerini (R^2) hesaplar. R-kare, tahmin edilen değerlerin gerçek hedef değerlerle ne kadar iyi eşleştiğini gösteren bir istatistiksel ölçüdür. 0 ile 1 arasında değişir. 1’e ne kadar yakınsa, model verideki değişkenliği o kadar iyi açıklar. Sonuç, üç ondalık basamağa yuvarlanarak gösterilir.

R^2 ve MSE arasındaki ilişki regresyon analizinden türetilmiştir:

$$R^2 = 1 - \frac{MSE}{Var(Y)}$$

Burada:

- R^2 , modelin veriyi ne kadar iyi açıkladığını gösterir.
- MSE, Ortalama Kare Hatasıdır.
- $Var(Y)$, gerçek hedef değerlerin varyansıdır (Standart sapmanın karesi).

Bu formüle göre, MSE değeri hedef değişkenin varyansına kıyasla çok küçükse, R^2 değeri 1'e yaklaşır. Bu da modelin başarılı olduğunu gösterir. [88]

Düzeltilmiş R-kare (Adjusted R-squared), modele eklenen değişken sayısını dikkate alan R-karenin düzeltilmiş bir versiyonudur. Yeni bir değişken modeli rastlantısal olarak beklenenden daha fazla iyileştirirse, düzeltilmiş R-kare artar. Ancak, yeni değişken beklenenden daha az etkili olursa, bu değer azalır. Genellikle düzeltilmiş R-kare negatife düşmez ve her zaman R-kare değerinden daha düşük olur. [88]

Ortalama mutlak hata

Şekil 3.17'de ikinci satırdaki formül, Ortalama Mutlak Hata'yı hesaplar, bu hata tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasıdır. Modelin tahminlerinin gerçek değerlere ne kadar uyduğunu ortalama olarak gösterir. Daha düşük MAE, modelin daha doğru olduğunu gösterir.

Eğer MAE, gerçek değerlerin ortalamasına göre küçük bir yüzdeye sahipse, model doğru kabul edilir. MAPE (Ortalama Mutlak Yüzde Hata) şu formülle hesaplanır:

$$MAPE = \frac{MAE}{Mean Value} \times 100\%$$

Burada:

- $MAPE < 10\% \rightarrow$ Mükemmel Model

- MAPE 10% - 20% → Kabul Edilebilir Model
- MAPE > 20% → Zayıf Model

Ortalama kare hata

Şekil 3.17’de görülen kodda üçüncü satırdaki formül, Ortalama Kare Hata’yı hesaplar, bu hata tahmin edilen ve gerçek değerler arasındaki kare farkların ortalamasını ölçer. Hataları karelemek daha büyük sapmalara daha fazla ağırlık verir, bu nedenle model büyük hatalara karşı daha fazla hassasiyet gösterir. Daha küçük bir MSE değeri, daha iyi model performansını gösterir.

Ayrıca, MSE, gerçek eksenel dayanım değerlerinin varyansı ile karşılaştırılır. Eğer MSE, varyanstan çok küçükse, model verideki değişkenliği iyi yakalamış demektir ve iyi performans gösterir.

$$Benchmark\ Ratio = \frac{MSE}{\sigma^2}$$

Burada σ^2 , gerçek eksenel dayanım değerlerinin varyansıdır. Eğer bu oran 1’den çok küçükse, model başarılıdır.

Karekök ortalama kare hata

Şekil 3.17’de dördüncü satırdaki formül, Karekök Ortalama Kare Hata’yı hesaplar, bu hata MSE’nin kareköküdür. RMSE, MSE’nin daha anlaşılır bir versiyonudur çünkü hedef değerlerle aynı ölçektir. Hataların tipik büyüklüğünü açıkça gösterir, daha küçük bir RMSE daha iyi performansı verir.

4.4.4. Gerçek ve tahmini değerler çizimi

```
# Plot actual vs predicted values
plt.figure(figsize=(10, 6))
plt.scatter(y_test, y_pred)

# Plot the 1:1 line (perfect prediction line)
plt.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], lw=2, label='Perfect Prediction', color='black', alpha=0.8)

# Plot the +10% and -10% error lines
plt.plot([y_test.min(), y_test.max()], [y_test.min() * 1.1, y_test.max() * 1.1], '--', lw=2, label='+10% Error', color='orange', alpha=0.8)
plt.plot([y_test.min(), y_test.max()], [y_test.min() * 0.9, y_test.max() * 0.9], '--', lw=2, label='-10% Error', color='blue', alpha=0.8)

# Plot the +20% and -20% error lines
plt.plot([y_test.min(), y_test.max()], [y_test.min() * 1.2, y_test.max() * 1.2], '--', lw=2, label='+20% Error', color='purple', alpha=0.8)
plt.plot([y_test.min(), y_test.max()], [y_test.min() * 0.8, y_test.max() * 0.8], '--', lw=2, label='-20% Error', color='green', alpha=0.8)

# Labels and title
plt.xlabel('Actual')
plt.ylabel('Predicted')
plt.title('Actual vs Predicted')
plt.legend()
plt.show()
```

Şekil 4.18. Gerçek ve tahmini değerler grafik kodu

Şekil 3.18'de verilen kod, bir makine öğrenimi modelinden elde edilen tahmin değerleri ('y_pred') ile gerçek hedef değerlerin ('y_test') görsel olarak karşılaştırılmasını sağlayan bir saçılma grafiği oluşturmak için kullanılmıştır. Bu grafiğin amacı, modelin tahminlerinin gerçek verilere ne kadar yakın olduğunu değerlendirmek ve modelin doğruluğunu grafiksel bir anlayışla sunmaktır. Grafiğin x eksenini gerçek değerleri, y eksenini ise tahmin edilen değerleri temsil etmektedir. Saçılma grafiğinin deseni, modelin performansı hakkında bir fikir sunar.

Şekil 3.18'de yer alan kodun ilk iki satırı, bir saçılma grafiği oluşturmaktadır. Bu grafikteki her bir nokta, x ekseninde gerçek değeri, y ekseninde ise modelin bu değere karşılık olarak yaptığı tahmini göstermektedir. Eğer model tamamen doğru sonuçlar üretebilseydi, tüm noktalar, tahminlerin gerçek değerlerle birebir örtüştüğü 45 derecelik düz bir çizgi üzerinde yer alırdı. Bu ideal senaryo, grafiğe eklenen ve “mükemmel tahmin” çizgisi olarak adlandırılan 1:1 çizgisiyle temsil edilmektedir. Kodda rengi siyah olarak belirtilen bu çizgi (çizgiye ait renk bilgisi, ilgili kod satırlarının sonunda yer almaktadır), model tahminlerinin gerçek değerlerden ne ölçüde saptığını görsel olarak değerlendirmek amacıyla bir referans noktası olarak kullanılır.

Mükemmel tahmin çizgisine ek olarak, kod birkaç hata marjı çizgisi de çizer. Bu çizgiler, tahmin edilen değerlerin gerçek değerlerden belirli yüzdelerde sapmasını gösterir. Örneğin, +10% ve -10% hata çizgileri, tahmin edilen değerlerin gerçek değerlerden %10 daha yüksek veya daha düşük olabileceği sınırları gösterir ve sırasıyla turuncu ve mavi kesik çizgilerle

temsil edilir. Benzer şekilde, +20% ve -20% hata çizgileri, mor ve yeşil renkte gösterilerek %20 hata marjını ifade eder. Bu çizgiler, modelin performansını değerlendirmek için bir referans sağlar, çünkü bu hata sınırları içinde kaç noktanın kaldığı kolayca tespit edilebilir. Noktaların 1:1 çizgisine ve %10 veya %20 marjlarına ne kadar yakın olduğu, modelin tahminlerinin doğruluğunu gösterir.


Mükemmel tahmin çizgisinin yanı sıra birden fazla hata bandının çizilmesi, modelin doğruluğuna dair daha net bir tablo sunar. Bu grafik, modelin aşırı tahmin yapma veya eksik tahmin yapma eğiliminde olup olmadığını ve tahminlerin gerçek değerlerden ne kadar uzak olduğunu anlamayı kolaylaştırır. Ayrıca, x ve y eksenlerine "Gerçek" ve "Tahmin" etiketleri eklenmiş, çizgilerin anlamını açıklayan bir gösterge (legend) sağlanmış ve `plt.show()` komutuyla grafik görüntülenmiştir. Genel olarak, bu grafik modelin tahmin performansının kapsamlı bir görsel özetini sunar ve modelin iyileştirilmesi gereken alanları hızlı bir şekilde belirlemeye yardımcı olur.

5. ARAŞTIRMA BULGULARI

Bu araştırmada, FRP sargılı betonun aksenal dayanımını tahmin etmek için Doğrusal Regresyon (DR), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA) olmak üzere üç makine öğrenimi modeli kullanılmıştır. Toplam 331 veriden oluşan bir veri seti kullanılmış olup, bu verilerin %85'i modelin eğitimi, %15'i ise modelin test edilmesi için kullanılmıştır. Her bir modelin performansı, R^2 skoru, Ortalama Mutlak Hata, Ortalama Kare Hata ve Kök Ortalama Kare Hata kullanılarak değerlendirilmiştir.

5.1. Eğitim Kayıp Eğrisi

Eğitim kayıp eğrisi, modelin öğrenme ilerleyişi ve çoklu epoch (öğrenme yinelemesi) boyunca eğitim verilerine ne kadar etkili bir şekilde uyum sağladığı hakkında önemli bilgiler vermektedir.



Şekil 5.1. Eğitim kaybi eğrisi

Şekil 4-1’de görüldüğü gibi, eğitimin başında modelin kaybı yaklaşık 3500 civarındadır. Bunun sebebi, modelin başlangıçta ağırlıklarını rastgele belirlemesidir. İlk aşamada modelin tahminleri çok hatalıdır, bu yüzden kayıp oldukça yüksektir. Ancak eğitim ilerledikçe model tahminlerini iyileştirmiş ve kayıp değeri keskin bir şekilde düşmüştür. Bu hızlı düşüş, modelin verideki önemli yapıları öğrenmeye başladığını ve hatalarını azaltmak adına doğru yönde ilerlediğini gösterir. Öğrenme sürecinin iyileştirilmesi yaklaşık ilk 50 epoch boyunca devam eder. Bu da, modelin öğrenme sürecinin etkili bir şekilde ilerlediğini ve tahminlerinin giderek gerçek değerlere yaklaştığını gösterir.


İlk hızlı düşüş evresinin ardından, kayıp fonksiyonu azalmaya devam etse de bu azalma giderek daha düşük bir hızda gerçekleşmektedir. 100. epoch civarında, kayıp değeri yaklaşık 30–40 aralığına gerileyerek sabitlenme eğilimi gösterir. Bu noktadan itibaren kayıp eğrisi yatay bir görünüme kavuşur ve modelin öğrenme sürecindeki büyük ilerlemeler yerini küçük iyileştirmelere bırakır. Bu durum, modelin eğitim verisindeki temel örüntüleri büyük ölçüde öğrendiğini ve artık yalnızca parametre düzeyinde ince ayarlamalar yaptığını göstermektedir. Bu aşamada devam eden eğitim, doğruluk üzerinde anlamlı bir katkı sağlamaz; model, yapısal öğrenmeyi tamamlamış olup sadece marjinal kazanımlar elde etmektedir.

100. epoch’tan sonra, eğitim kaybının neredeyse sabitlenmesi ve belirgin bir azalma göstermemesi, modelin artık yeni bilgileri öğrenmekten ziyade mevcut performans seviyesini sürdürdüğüne göstermektedir. Bu noktadan itibaren eğitim sürecinin uzatılması, modelin genel doğruluğunu artırmak yerine aşırı öğrenmeye (overfitting) yol açabilir. Bu durumda model, eğitim verisine fazla uyum sağladığı için yeni ve görülmemiş veriler üzerinde sağlıklı tahminlerde bulunmakta zorlanabilir. Ancak bu durum, modelin doğruluk ve kararlılık açısından dengeli bir duruma ulaştığını gösterdiğinden, eğitim sürecinin doğal ve beklenen bir evresi olarak değerlendirilebilir.

5.2. Doğrusal Regresyon

Doğrusal Regresyon modeli, veriye ilişkin orta düzeyde bir uyum göstermiştir; modelin R^2 skoru 0,781, düzeltilmiş R^2 skoru ise 0,722 olarak hesaplanmıştır. Bu değerler, modelin eksenel dayanım değişkenindeki varyansın yaklaşık %72’sini açıklayabildiğini ortaya koymaktadır. Ancak doğrusal yapısı nedeniyle modelin karmaşık ilişkileri yeterince temsil

edemediği anlaşılmaktadır. Hata metrikleri incelendiğinde, MAE 13,682, MSE 285,485 ve RMSE 16,9 olarak elde edilmiştir. Bu sonuçlar, modelin tahminlerinde belirli bir sapma bulunduğunu ve özellikle büyük hataların etkisini yeterince azaltamadığını göstermektedir. MSE değerinin görece yüksek oluşu, doğrusal modellerin yüksek varyanslı durumlarda yetersiz kalabileceğine işaret etmektedir.



Şekil 5.2. Gerçek ve tahmin edilen değerler grafiği (doğrusal regresyon)

Gerçek ve tahmin edilen değerler arasındaki ilişkiye ait grafikler Şekil 4-2’de sunulmuştur. Ayrıca, her bir veri noktasının gerçek değerlere kıyasla ne düzeyde yüzde hata içerdiği de grafiksel olarak ifade edilmiştir. Doğrusal Regresyon modeli, bağımsız değişkenler ile bağımlı değişken arasında doğrusal bir ilişki olduğunu varsayan, hesaplama açısından hızlı ve yorumlanması görece kolay bir yöntemdir. Ancak, veriler arasında doğrusal olmayan ilişkilerin söz konusu olduğu durumlarda bu modelin yetersiz kaldığı bilinmektedir.


FRP sargılı betonun eksenel basınç dayanımının tahmin edilmesi gibi çok değişkenli ve karmaşık problemlerde, Doğrusal Regresyon modeli sınırlı bir başarı sergilemektedir. Bunun temel nedeni, modelin her bir bağımsız değişkenin hedef değişken üzerindeki etkisini birbirinden bağımsız ve doğrusal olarak varsaymasıdır. Oysa bu çalışmada olduğu gibi, bazı değişkenlerin (örneğin FRP türü ile katman sayısı) birlikte etkide bulunduğu durumlarda, model bu etkileşimleri dikkate alamamaktadır.

Bu durum, modelin düşük R^2 değeri ile birlikte yüksek hata metrikleri (MAE, MSE, RMSE) üretmesiyle açık biçimde gözlemlenmiştir. Dolayısıyla, Doğrusal Regresyon modelinin bu tür çok boyutlu yapay öğrenme problemlerinde sınırlı bir öngörü gücüne sahip olduğu sonucuna varılabilir.

5.3. Rastgele Orman

Rastgele Orman modeli, Doğrusal Regresyon modeline kıyasla oldukça üstün performans göstermiştir. Elde edilen R^2 skoru 0,985, düzeltilmiş R^2 skoru ise 0,981 olarak belirlenmiştir. Bu yüksek korelasyon katsayıları, modelin giriş değişkenleri ile FRP sargılı betonun eksenel dayanımı arasındaki ilişkiyi güçlü ve tutarlı bir şekilde kurabildiğini göstermektedir.

Modelin MAE değeri 3,028 olarak hesaplanmıştır; bu değer, Doğrusal Regresyon modeline kıyasla oldukça düşüktür ve tahminlerin gerçeğe daha yakın olduğunu göstermektedir. Ayrıca, MSE 19,541 ve RMSE 4,42 olarak bulunmuştur. Bu hata metrikleri, Rastgele Orman modelinin yalnızca genel doğruluk açısından değil, aynı zamanda büyük sapmaları minimize etme açısından da daha başarılı sonuçlar ürettiğini göstermektedir. Dolayısıyla, söz konusu modelin bu çalışmadaki karmaşık veri yapısına uygun ve etkili bir tahmin aracı olduğu söylenebilir.



Şekil 5.3. Gerçek ve tahmin edilen değerler grafiği (rastgele orman)

Şekil 4-3'te de görülebileceği üzere, veri noktalarının büyük bir kısmının doğrusal eğriye yakın bir şekilde konumlanması, Rastgele Orman modelinin tahmin hatasının Doğrusal Regresyon modelinden daha düşük olduğunu gösterir. Doğrusal Regresyon modeli yalnızca doğrusal ilişkileri dikkate alabildiğinden, doğrusal olmayan ve karmaşık veri yapılarında yetersiz kalmaktadır. Buna karşın, Rastgele Orman modeli, doğrusal olmayan ilişkileri de kapsayabildiği için bu tür verilerle daha etkili bir şekilde çalışmaktadır.


Modelin temel yapısı, çok sayıda karar ağacının bir araya getirilmesiyle oluştuğundan, bireysel ağaçların ezberleme eğilimleri azaltılmakta ve modelin genelleme kapasitesi artmaktadır. Ayrıca, Rastgele Orman modeli, tahmin sürecinde hangi değişkenlerin daha belirleyici olduğunu analiz edebilme yeteneğine sahiptir. Bu sayede, veri setindeki önemli değişkenlere ağırlık verirken, daha az etkili olanları geri planda bırakabilmektedir.

Bu özellikleriyle birlikte değerlendirildiğinde, Rastgele Orman modeli, bu çalışmadaki gibi çok değişkenli ve karmaşık veri yapılarına sahip problemler için daha uygun ve güvenilir bir yöntem olarak öne çıkmaktadır.

5.4. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcı modeli, Doğrusal Regresyon modeline kıyasla daha yüksek bir performans göstermiş ve Rastgele Orman modeli ile karşılaştırılabilir sonuçlar elde edilmiştir. Modelin R^2 skoru 0,991, düzeltilmiş R^2 skoru ise 0,989 olarak hesaplanmıştır. Bu yüksek değerler, YSA modelinin bağımlı değişkendeki varyansın %98'inden fazlasını açıklayabildiğini ve bu doğrultuda oldukça başarılı bir tahmin kapasitesine sahip olduğunu göstermektedir.

Elde edilen bu yüksek doğruluk oranı, ÇKA modelinin veri kümesinde bulunan karmaşık ve doğrusal olmayan ilişkileri öğrenme ve işleyebilme açısından en uygun bir yöntem olduğunu ortaya koymaktadır. MAE değeri 2,511 olarak hesaplanmış olup, bu değer üç model arasında en düşük hata oranıdır. Ayrıca, MSE 11,683 ve RMSE 3,42 olarak bulunmuştur. Bu hata metrikleri, YSA modelinin genel tahmin hatasının düşük seviyede olduğunu ve modelin yüksek doğrulukla birlikte istikrarlı bir performans sergilediğini göstermektedir.



Şekil 5.4. Gerçek ve tahmin edilen değerler grafiği

Şekil 4-4'te de görüldüğü üzere, hata yüzdesi Rastgele Orman modelden daha düşük olan YSA modeli, tüm modeller arasında en yüksek doğruluğa sahip yöntem olarak öne çıkmıştır. Bu model, yalnızca en yüksek R^2 skorunu elde etmekle kalmamış, aynı zamanda hata metrikleri açısından da en düşük değerleri sunarak üstün bir performans göstermiştir. Genel anlamda hem Yapay Sinir Ağı hem de Rastgele Orman modelleri yüksek doğruluk oranları ile dikkat çekmektedir; ancak YSA modelinin başarısı, yapısal özellikleri itibarıyla daha belirgin hale gelmektedir.

YSA modelinin bu üstün performansında, insan beynine benzer şekilde organize olmuş, birbirine bağlı düğümlerden oluşan çok katmanlı mimarisi belirleyici rol oynamaktadır. Bu katmanlar, veri içerisindeki karmaşık desenleri öğrenmektedir. Öğrenme süreci, ağırlıkların güncellenmesi ve geri yayılım (backpropagation) mekanizması aracılığıyla gerçekleşmektedir.


Modelin doğrusal olmayan değişken ilişkilerini etkin bir şekilde öğrenebilmesi, önemli bir avantaj sağlamaktadır. Bu durum, özellikle değişkenler arasında yüksek derecede etkileşimin bulunduğu veri yapılarında öne çıkmaktadır. Doğrusal Regresyon modeli bu tür etkileşimleri yalnızca sınırlı düzeyde temsil edebilmektedir. Buna karşın, YSA modeli bu ilişkileri daha ayrıntılı ve esnek biçimde değerlendirebilmektedir. Ayrıca, YSA modeli

eğitim sürecinde ağırlıklarını sürekli olarak optimize etmektedir. Her yinelemede, tahmin edilen değerlerle gerçek değerler arasındaki farkı azaltmaya yönelik bir öğrenme süreci izlemektedir. Bu durum, modelin genel doğruluğunu artırmaktadır.

Elde edilen sonuçlar, hem kullanılan makine öğrenimi modellerinin yapısal farklılıklarından hem de FRP sargılı betonun eksenel yük altındaki davranışını yansıtan verilerin karmaşıklığından kaynaklanmaktadır. FRP sargılı betonun eksenel dayanımını tahmin etmek, birden fazla değişkenin sonuçlar üzerinde etkili olabilmesi nedeniyle oldukça karmaşık bir problemidir. Bu çalışma kapsamında elde edilen bulgular, veri yapısının karmaşıklığına uygun modellerin seçilmesinin ne denli önemli olduğunu ortaya koymakta; ayrıca yapısal mühendislik uygulamalarında gelişmiş makine öğrenimi yöntemlerinin, örneğin Yapay Sinir Ağları (YSA), kullanımının sağladığı avantajları göstermektedir. Elde edilen sonuçlar, doğrusal yaklaşımların bu tür karmaşık sistemlerde yetersiz kaldığını ve doğrusal olmayan desenleri yakalama kapasitesine sahip modellerin, özellikle Rastgele Orman ve YSA, tercih edilmesi gerektiğini göstermektedir. Bulguların özetine Tablo 4.1’de yer verilmiştir.

Çizelge 5.1. Sonuçların özeti

Model	R ² skoru	Adj R ² skoru	MAE	RMSE
Doğrusal regresyon	0,781	0,723	13,682	16,9
Rastgele orman	0,985	0,981	3,028	4,42
Çok katman algılayıcı	0,991	0,988	2,511	3,42



Şekil 5.5. Yapay zeka modellerinin performans metrikleri

6. SONUÇ

Bu çalışmada, FRP sargılı beton elemanların eksenel dayanımını tahmin etmek için mevcut literatürden toplanan 331 veriden oluşan bir veri seti kullanılmış, bu verilerin %85'i modelin eğitimi, %15'i ise modelin test edilmesi için kullanılarak tahmin modelleri oluşturulmuştur. Üç makine öğrenmesi modeli uygulanmıştır: Doğrusal Regresyon (DR), Rastgele Orman (RO) ve Yapay Sinir Ağları (YSA). DR modeli, basit olması nedeniyle karşılaştırma için temel model olarak kullanılmıştır. RO ve YSA ise daha karmaşık ve doğrusal olmayan ilişkileri yakalayabildiği için tercih edilen gelişmiş modellerdir.

Veri kalitesini artırmak ve model performansını iyileştirmek amacıyla beş kat çapraz doğrulama, eksik değerleri silme ve aykırı değerlerin etkisini azaltma gibi veri temizleme ve ön işleme teknikleri dikkatli şekilde uygulanmıştır. Python kütüphaneleri hem modellerin kurulmasında hem de veri eğilimlerinin görselleştirilmesi ve önemli bulguların elde edilmesinde kullanılmıştır. Modelin doğruluğunu ve genellenebilirliğini artırmak için 5 katlı çapraz doğrulama, veri normalizasyonu, standart ölçekleme ve etiket kodlama gibi ek yöntemler kullanılmıştır. Bu adımlar, aşırı öğrenme (overfitting) ve yetersiz öğrenme (underfitting) sorunlarını azaltarak genel tahmin gücünü artırmıştır.

Ayrıca, giriş değişkenlerinin hedef sonuç (sargılanmış betonun basınç dayanımı) üzerindeki etkisini incelemek için değişken önem analizleri ve korelasyon matrisleri kullanılmıştır. Modellerin başarısını değerlendirmek için R^2 , MAE, MSE ve RMSE gibi çeşitli performans ölçütleri kullanılmıştır. Bu ölçütler sayesinde her bir modelin tahmin doğruluğu ve hata payları belirlenmiştir. Tüm modellerin eğitilip test edilmesinden sonra bu araştırmadan aşağıdaki sonuçlar alınmıştır:

- Tahmin modellerinin yapısal karmaşıklığı arttıkça, FRP sargılı beton elemanların eksenel dayanımını tahmin etme doğruluğu da anlamlı şekilde artmaktadır. Yapay Sinir Ağları (YSA) ve Rastgele Ormanlar gibi gelişmiş makine öğrenmesi algoritmaları, veri setlerinde yer alan karmaşık örüntüleri tanıma kapasiteleri sayesinde, Doğrusal Regresyon gibi daha basit modellere kıyasla daha başarılı sonuçlar üretmektedir. Bu gelişmiş algoritmalar, özellikle yapısal mühendislik veri kümelerinde sıkça karşılaşılan doğrusal olmayan ilişkileri modelleyebilmekte ve daha yüksek güvenilirlik düzeyinde tahminler sunabilmektedir.

- Doğrusal Regresyon modeli, sade yapısı ve yorumlanabilirliği nedeniyle belirli analizlerde avantaj sağlasa da, doğrusal olmayan veri yapıları karşısında yetersiz kalmaktadır. FRP sargılı beton elemanların dayanımı gibi, değişkenler arasındaki etkileşimlerin karmaşık ve doğrusal olmayan karakterde olduğu durumlarda, bu modelin yetersizlikleri belirginleşmekte ve daha sofistike yaklaşımların gerekliliği ortaya çıkmaktadır.
- Bu çalışma kapsamında gerçekleştirilen analizler sonucunda, Yapay Sinir Ağları ve Rastgele Orman modelleri en başarılı tahmin algoritmaları olarak dikkat çekmiştir. Söz konusu modeller, en yüksek determinasyon katsayısı (R^2) değerlerine ulaşmış ve en düşük hata metrikleri ile en iyi tahmin performansını göstermiştir.
- Doğrusal olmayan makine öğrenmesi modelleri, FRP sargılı beton elemanların eksenel dayanımını tahmin etme gibi mühendislik uygulamalarında doğruluk düzeyini artırma potansiyeline sahiptir. Bu durum, veri odaklı yöntemlerin geleneksel mühendislik yaklaşımlarını tamamlayıcı bir unsur olarak kullanımına yönelik artan eğilimi desteklemektedir.
- Bu çalışmada elde edilen bulgular, uygun tahmin modellerinin seçimi açısından önemli bir referans olmaktadır. Doğrusal olmayan makine öğrenmesi tekniklerinin avantajlarını göz önünde bulundurarak, özellikle değişkenler arası etkileşimin yoğun olduğu sistemlerde, model seçiminde optimizasyon yapılması gerektiği önerilmektedir.

Gelecek çalışmalar

Bu tezde, Rastgele Orman gibi bagging ensemble modelleri kullanılmıştır. Bu modeller, eğitim verisinin farklı bölümleriyle bağımsız olarak eğitilen birden fazla modelden oluşur. Genellikle rastgele örnekleme yöntemiyle veriler tekrar seçilerek kullanılır. Ancak, boosting ensemble modellerinin de denenmesi mümkündür. Ancak, bu çalışmanın sonuçlarını önemli ölçüde geliştirebilecek bazı başka konular da araştırılabilir.

- Boosting topluluk modelleri, zayıf öğrencilerin sıralı olarak eğitildiği ve her modelin önceki hataları düzeltmeye çalıştığı bir yöntemdir. XGBoost ve LightGBM gibi algoritmalar, özellikle değişkenler arası ilişkilerin karmaşık olduğu durumlarda yüksek doğruluk sağlar.

- Makine öğreniminde veri miktarı, modelin genelleme yeteneđi ve dođruluđu için önemlidir. Daha fazla veri, aşırı öğrenme riskini azaltır, modelin gerçek desenleri öğrenmesini kolaylaştırır ve rastgele hataları ezberleme olasılıđını düşürür.
- Bu çalışmada yalnızca dairesel kesitli beton eleman örnekleri kullanılmış olup, bu durum modelin genelleştirilebilirliğini sınırlamaktadır. Gelecek çalışmalarda dikdörtgen ve kare kesitli örneklerin de veri setine dahil edilmesi, modelin farklı kesit geometrilerini öğrenerek sargılı beton dayanımı için daha kapsamlı bağıntılar oluşturulması sağlanabilir.





KAYNAKLAR

1. Tehrani, P., Eini, A. (2022). Seismic performance assessment of steel moment frames with non-parallel system irregularity. *Journal of Rehabilitation in Civil Engineering*, 10(4), 109-128.
2. Hoseynzadeh, H., Mortezaei, A. (2021). Seismic vulnerability and rehabilitation of one of the world's oldest masonry minaret under the different earthquake frequency contents. *Journal of Rehabilitation in Civil Engineering*, 9(4), 12-36.
3. Jalali, S. A., Banazadeh, M., Tafakori, E., Abolmaali, A. (2011). Seismic performance assessment of steel moment frames with generic Locally Reinforced connections. *Journal of Constructional Steel Research*, 67(8), 1261-1271.
4. Jamali, F., Mousavi, S. R., Peyma, A. B., & Moodi, Y. (2022). Prediction of compressive strength of fiber-reinforced polymers-confined cylindrical concrete using artificial intelligence methods. *Journal of Reinforced Plastics and Composites*, 41(17-18), 679-704.
5. Lejano, B. A. (2017). Evaluation of different fiber reinforced mortar as retrofitting materials for RC columns. *GEOMATE Journal*, 13(35), 40-47.
6. Kalogeropoulos, G., & Tsonos, A. D. (2021). Seismic performance enhancement of RC columns using thin high-strength RC jackets and CFRP jackets. *Fibers*, 9(5), 2-9.
7. Hoseynzadeh, H., & Mortezaei, A. (2021). Seismic vulnerability and rehabilitation of one of the world's oldest masonry minaret under the different earthquake frequency contents. *Journal of Rehabilitation in Civil Engineering*, 9(4), 12-36.
8. Kirthiga, R., & Elavenil, S. (2022). A review on using inorganic binders in fiber reinforced polymer at different conditions to strengthen reinforced concrete beams. *Construction and Building Materials*, 3(2), 129-135.
9. Bhuvaneshwari, P., Mohan, K. S. R., & Kirthiga, R. (2014). Stress strain behaviour of concrete element retrofitted using organic and inorganic binders. *Asian Journal of Applied Sciences*, 7(4), 215-223.
10. Awani, O., El-Maaddawy, T., & Ismail, N. (2017). Fabric-reinforced cementitious matrix: A promising strengthening technique for concrete structures. *Construction and Building Materials*, 1(132), 94-111.
11. Kirthiga, R., & Elavenil, S. (2023). Potential utilization of sugarcane bagasse ash in cementitious composites for developing inorganic binder. *Ain Shams Engineering Journal*, 14(11), 131-135.
12. Rizkalla, S., Hassan, T., & Hassan, N. (2003). Design recommendations for the use of FRP for reinforcement and strengthening of concrete structures. *Progress in Structural Engineering and Materials*, 5(1), 16-28.

13. Qureshi, J. (2022). A review of fibre reinforced polymer structures. *Fibers*, 10(3), 22-27.
14. Pampanin, S., Bolognini, D., & Pavese, A. (2007). Performance-based seismic retrofit strategy for existing reinforced concrete frame systems using fiber-reinforced polymer composites. *Journal of Composites for Construction*, 11(2), 211-226.
15. Del Vecchio, C., Di Ludovico, M., & Prota, A. (2021). Cost and effectiveness of fiber-reinforced polymer solutions for the large-scale mitigation of seismic risk in reinforced concrete buildings. *Polymers*, 13(17), 92-96.
16. Ling, J. H., Lim, Y. T., & Jusli, E. (2023). Methods to determine ductility of structural members: a review. In *Journal of the Civil Engineering Forum*, 3(5), 181-194.
17. Khodadadi, N., Roghani, H., Harati, E., Mirdarsoltany, M., De Caso, F., & Nanni, A. (2024). Fiber-reinforced polymer (FRP) in concrete: A comprehensive survey. *Construction and Building Materials*, 9(4), 43-52,
18. Demers, M., & Neale, K. W. (1999). Confinement of reinforced concrete columns with fibre-reinforced composite sheets-an experimental study. *Canadian Journal of Civil Engineering*, 26(2), 226-241.
19. Rochette, P., & Labossiere, P. (2000). Axial testing of rectangular column models confined with composites. *Journal of Composites for Construction*, 4(3), 129-136.
20. Benmokrane, B., El-Salakawy, E., El-Ragaby, A., & Lackey, T. (2006). Designing and testing of concrete bridge decks reinforced with glass FRP bars. *Journal of Bridge Engineering*, 11(2), 217-229.
21. Benmokrane, B., El-Salakawy, E., El-Ragaby, A., & El-Gamal, S. (2007). Performance evaluation of innovative concrete bridge deck slabs reinforced with fibre-reinforced-polymer bars. *Canadian Journal of Civil Engineering*, 34(3), 298-310.
22. Raza, A., Khan, Q. U. Z., & Ahmad, A. (2019). Numerical Investigation of Load-Carrying Capacity of GFRP-Reinforced Rectangular Concrete Members Using CDP Model in ABAQUS. *Advances in Civil Engineering*, 2019(1), 174-241.
23. Raza, A., Shah, S. A. R., Khan, A. R., Aslam, M. A., Khan, T. A., Arshad, K., & Waseem, M. (2020). Sustainable FRP-confined symmetric concrete structures: an application experimental and numerical validation process for reference data. *Applied Sciences*, 10(1), 32-33.
24. Shuhan, W., Chengzhi, Y., Xiaoxiao, L., & Siyu, W. (2024). Smart infrastructure design: Machine learning solutions for securing modern cities. *Sustainable Cities and Society*, 5(107), 10-39.
25. Firoozi A.,(2024). Intelligent Learning Algorithms for Smart Infrastructure. Revolutionizing Civil Engineering with Neuromorphic Computing. *Springer Nature Switzerland*, 5(55), 39-47.

26. Ma, G., Wang, F., Jin, R., Guo, B., Huo, H., Dai, Y., & Li, S. (2025). Dual Doping in Precious Metal Oxides: Accelerating Acidic Oxygen Evolution Reaction. *International Journal of Molecular Sciences*, 26(4), 15-82.
27. Boumarafi, A., Abouzied, A., & Masmoudi, R. (2015). Harsh environments effects on the axial behaviour of circular concrete-filled fibre reinforced-polymer (FRP) tubes. *Composites Part B: Engineering*, 8(3), 81-87.
28. Tamke, M., Nicholas, P., & Zwierzycki, M. (2018). Machine learning for architectural design: Practices and infrastructure. *International Journal of Architectural Computing*, 16(2), 123-143.
29. Dick, K., Russell, L., Souley Dosso, Y., Kwamena, F., & Green, J. R. (2019). Deep learning for critical infrastructure resilience. *Journal of Infrastructure Systems*, 25(2), 50-69.
30. Zhukova, M. A., Chinn, L. K., Cheek, C., Sukmanova, A. A., Kustova, T. A., & Grigorenko, E. L. (2025). Impact of maternal institutionalization on children's language development: A multidisciplinary study. *Journal of Experimental Child Psychology*, 2(53), 106-197.
31. Tzampoglou, P., Loukidis, D., Anastasiades, A., & Tsangaratos, P. (2025). Advanced machine learning techniques for enhanced landslide susceptibility mapping: Integrating geotechnical parameters in the case of Southwestern Cyprus. *Earth Science Informatics*, 18(2), 39-57.
32. Xu, C., Zhang, Y., Isleem, H. F., Qiu, D., Zhang, Y., Alsaadawi, M. M., & Hamed, A. Y. (2024). Numerical and machine learning models for concentrically and eccentrically loaded CFST columns confined with FRP wraps. *Structural Concrete*, 91(5), 20-25.
33. Saadatmanesh, H., Ehsani, M. R., & Jin, L. (1997). Repair of earthquake-damaged RC columns with FRP wraps. *Structural Journal*, 94(2), 206-215.
34. Sayed, Y. A., Ibrahim, A. A., Tamrazyan, A. G., & Fahmy, M. F. (2023). Machine-learning-based models versus design-oriented models for predicting the axial compressive load of FRP-confined rectangular RC columns. *Engineering Structures*, 2(8), 11-30.
35. Lejano, B. A. (2017). Evaluation of different fiber reinforced mortar as retrofitting materials for RC columns. *GEOMATE Journal*, 13(35), 40-47.
36. Kalogeropoulos, G., & Tsonos, A. D. (2021). Seismic performance enhancement of RC columns using thin high-strength RC jackets and CFRP jackets. *Fibers*, 9(5), 29.
37. Yan, L., Chouw, N., & Kasal, B. (2017). Experimental study and numerical simulation on bond between FFRP and CFRC components. *Journal of Reinforced Plastics and Composites*, 36(4), 305-320.
38. Qureshi, J. (2022). A review of fibre reinforced polymer structures. *Fibers*, 10(3), 5-7.

39. Wang, C., Song, L. H., Yuan, Z., & Fan, J. S. (2023). State-of-the-art AI-based computational analysis in civil engineering. *Journal of Industrial Information Integration*, 3(3), 100-120.
40. Adeli, H. (2001). Neural networks in civil engineering: 1989–2000. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 126-142.
41. Lim, J. C., & Ozbakkaloglu, T. (2015). Influence of concrete age on stress–strain behavior of FRP-confined normal-and high-strength concrete. *Construction and Building Materials*, 8(2), 61-70.
42. Keshtegar, B., Gholampour, A., Thai, D. K., Taylan, O., & Trung, N. T. (2021). Hybrid regression and machine learning model for predicting ultimate condition of FRP-confined concrete. *Composite Structures*, 7(62), 113-144.
43. Gholizadeh, S., & Mohammadi, M. (2017). Reliability-based seismic optimization of steel frames by metaheuristics and neural networks. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems*, 16(3), 123-151.
44. Keshtegar, B., Gholampour, A., Ozbakkaloglu, T., Zhu, S. P., & Trung, N. T. (2020). Reliability analysis of FRP-confined concrete at ultimate using conjugate search direction method. *Polymers*, 12(3), 7-17.
45. Ali, L., Isleem, H. F., Bahrami, A., Jha, I., Zou, G., Kumar, R., & Jahami, A. (2024). Integrated behavioural analysis of FRP-confined circular columns using FEM and machine learning. *Composites*, 26(4), 15-82.
46. Wei, Y., Zhang, Y., Chai, J., Wu, G., & Dong, Z. (2020). Experimental investigation of rectangular concrete-filled fiber reinforced polymer (FRP)-steel composite tube columns for various corner radii. *Composite Structures*, 6(44), 102-111.
47. Onyelowe, K. C., Jayabalan, J., Ebid, A. M., Samui, P., Singh, R. P., Soleymani, A., & Jahangir, H. (2022). Evaluation of the compressive strength of CFRP-wrapped circular concrete columns using artificial intelligence techniques. *Designs*, 6(6), 11-32.
48. Allahyarsharahi, N., Kiani, A., & Hoseini, S. O. (2025). Machine learning-based models for FRP shear contribution of wrapped reinforced concrete beams. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 8(1), 14-21.
49. Xu, C., Zhang, Y., Isleem, H. F., Qiu, D., Zhang, Y., Alsaadawi, M. M., ... & Hamed, A. Y. (2024). Numerical and machine learning models for concentrically and eccentrically loaded CFST columns confined with FRP wraps. *Structural Concrete*, 5(6), 22-35
50. Djafar-Henni, I., Berradia, M., Ghazouani, N., Raza, A., & Elhag, A. B. (2024). Predicting ultimate strength and axial strain of circular concrete columns having AFRP wraps and tube-encased confinement. *Mechanics of Advanced Materials and Structures*, 6(7), 1-16.

51. Kumar, P., Arora, H. C., Bahrami, A., Kumar, A., & Kumar, K. (2023). Development of a reliable machine learning model to predict compressive strength of FRP-confined concrete cylinders. *Buildings*, 13(4), 9-31.
52. Kumar, P., Arora, H. C., Kumar, A., & Radu, D. (2024). Prediction of axial capacity of corrosion-affected RC columns strengthened with inclusive FRP. *Scientific Reports*, 14(1), 140-211.
53. Koodiani, H. K., Erfanian, N., Majlesi, A., Hosseinzadeh, A., Jafari, E., Shahin, M., & Matamoros, A. (2023). Calibrating equations to predict the compressive strength of FRP-Confined columns using optimized neural network model, *Structures*, 5(56), 105-160.
54. Chen, P., Wang, H., Cao, S., & Lv, X. (2022). Prediction of mechanical behaviours of FRP-confined circular concrete columns using artificial neural network and support vector regression: Modelling and performance evaluation. *Materials*, 15(14), 49-71.
55. Wang, J., Xiao, H., Lu, L., Yang, J., Lu, S., & Shayanfar, J. (2024). Axial stress-strain model for concrete in partially FRP wrapped reinforced concrete columns. *Construction and Building Materials*, 4(16), 13-50.
56. Raza, A., Shah, S. A. R., ul Haq, F., Arshad, H., Raza, S. S., Farhan, M., & Waseem, M. (2020). Prediction of axial load-carrying capacity of GFRP-reinforced concrete columns through artificial neural networks. *Structures*, 3(28), 1557-1571.
57. Cascardi, A., Micelli, F., & Aiello, M. A. (2017). An Artificial Neural Networks model for the prediction of the compressive strength of FRP-confined concrete circular columns. *Engineering Structures*, 2(140), 199-208.
58. NadimiShahraki, K., & Reisi, M. (2020). Stress-strain based method for analysis and design of FRP wrapped reinforced concrete columns. *Structures*, 2(28), 1818-1830.
59. Isleem, H. F., Abid, M., Alaloul, W. S., Shah, M. K., Zeb, S., Musarat, M. A., & Alabduljabbar, H. (2021). Axial compressive strength models of eccentrically-loaded rectangular reinforced concrete columns confined with FRP. *Materials*, 14(13), 3498.
60. Onyelowe, K. C., Jayabalan, J., Ebid, A. M., Samui, P., Singh, R. P., Soleymani, A., & Jahangir, H. (2022). Evaluation of the compressive strength of CFRP-wrapped circular concrete columns using artificial intelligence techniques. *Designs*, 6(6), 11-22.
61. Liu, K. H., Xie, T. Y., Cai, Z. K., Chen, G. M., & Zhao, X. Y. (2024). Data-driven prediction and optimization of axial compressive strength for FRP-reinforced CFST columns using synthetic data augmentation. *Engineering Structures*, 3(10), 117-225.
62. Berradia, M., Alashker, Y., Raza, A., & El Ouni, M. H. (2022). Artificial neural networks approach for prediction of axial loading capacity of circular normal strength concrete columns confined by both transverse steel reinforcement and carbon fiber reinforced polymer wraps. *Advances in Structural Engineering*, 25(15), 3171-3194.

63. Jiang, K., Han, Q., Bai, Y., & Du, X. (2020). Data-driven ultimate conditions prediction and stress-strain model for FRP-confined concrete. *Composite Structures*, 2(42), 112-194.
64. Elsanadedy, H. M., Al-Salloum, Y. A., Abbas, H., & Alsayed, S. H. (2012). Prediction of strength parameters of FRP-confined concrete. *Composites Part B: Engineering*, 43(2), 228-239.
65. Jiang, K., Han, Q., Bai, Y., & Du, X. (2020). Data-driven ultimate conditions prediction and stress-strain model for FRP-confined concrete. *Composite Structures*, 2(49), 112-194.
66. Lu, M., AbouRizk, S. M., & Hermann, U. H. (2001). Sensitivity analysis of neural networks in spool fabrication productivity studies. *Journal of Computing in Civil Engineering*, 15(4), 299-308.
67. Mansouri, I., Ozbakkaloglu, T., Kisi, O., & Xie, T. (2016). Predicting behavior of FRP-confined concrete using neuro fuzzy, neural network, multivariate adaptive regression splines and M5 model tree techniques. *Materials and Structures*, 2(49), 4319-4334.
68. Naderpour, H., Kheyroddin, A., & Amiri, G. G. (2010). Prediction of FRP-confined compressive strength of concrete using artificial neural networks. *Composite Structures*, 92(12), 2817-2829.
69. Samui, P. (2008). Support vector machine applied to settlement of shallow foundations on cohesionless soils. *Computers and Geotechnics*, 35(3), 419-427.
70. Sobhani, J., Najimi, M., Pourkhorshidi, A. R., & Parhizkar, T. (2010). Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models. *Construction and Building Materials*, 24(5), 709-718.
71. Alizamir, M., Gholampour, A., Kim, S., Keshtegar, B., & Jung, W. T. (2024). Designing a reliable machine learning system for accurately estimating the ultimate condition of FRP-confined concrete. *Scientific Reports*, 14(1), 20-46.
72. Raza, A., ur Rehman, A., Masood, B., & Hussain, I. (2020, August). Finite element modelling and theoretical predictions of FRP-reinforced concrete columns confined with various FRP-tubes. *Structures*, 6(26), 626-638.
73. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 1(2), 2825-2830.
74. Kazemi, F., Shafighfard, T., & Yoo, D. Y. (2024). Data-driven modeling of mechanical properties of fiber-reinforced concrete: a critical review. *Archives of Computational Methods in Engineering*, 31(4), 2049-2078.
75. Cascardi, A., Micelli, F., & Aiello, M. A. (2017). An Artificial Neural Networks model for the prediction of the compressive strength of FRP-confined concrete circular columns. *Engineering Structures*, 6(40), 199-208.

76. Heddarn, S., Keshtegar, B., & Kisi, O. (2020). Predicting total dissolved gas concentration on a daily scale using kriging interpolation, response surface method and artificial neural network: Case study of Columbia river Basin Dams, USA. *Natural Resources Research*, 2(9), 1801-1818.
77. Bahtiyar, H., Soydaner, D., & Yüksel, E. (2022). Application of multilayer perceptron with data augmentation in nuclear physics. *Applied Soft Computing*, 12(8), 109-470.
78. Li, J., Li, C., & Zhang, S. (2022). Application of Six Metaheuristic Optimization Algorithms and Random Forest in the uniaxial compressive strength of rock prediction. *Applied Soft Computing*, 1(31), 10-72.
79. Nikoopayan Tak, M. S., Feng, Y., & Mahgoub, M. (2025). Advanced Machine Learning Techniques for Predicting Concrete Compressive Strength. *Infrastructures*, 10(2), 26.
80. Vadyala, S. R., Betgeri, S. N., Matthews, J. C., & Matthews, E. (2022). A review of physics-based machine learning in civil engineering. *Results in Engineering*, 13(12), 100-316.
81. Hastie, T., Tibshirani, R., & Wainwright, M. (2015). Statistical learning with sparsity. *Monographs on Statistics and Applied Probability*, 143(143), 8-10.
82. Hasselmann, K. (1979). Linear statistical models. *Dynamics of Atmospheres and Oceans*, 2(3), 501-521.
83. Draper, N. R., & Smith, H. (1998). Applied regression analysis. *Artificial Intelligence Techniques*, 7(4), 50-61.
84. Salimi, A., Rostami, J., Moormann, C., & Delisio, A. (2016). Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs. *Tunnelling and Underground Space Technology*, 5(8), 236-246.
85. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
86. Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
87. Nelson, R. R. (1959). The simple economics of basic scientific research. *Journal of Political Economy*, 67(3), 297-306.
88. Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2005). Applied linear statistical models. *Computers and Geotechnics*, 35(3), 419-427.
89. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning. *Springer*, 2(112), 12-21.
90. Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning. *Springer*, 2(4), 73-78

91. Breiman, L. (2001). Random forests. *Machine Learning*, 5(45), 5-32.
92. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 9(12), 2825-2830.
93. Liaw, A., & Wiener, M. (2002). Classification and regression by random Forest. *R News*, 2(3), 18-22.
94. Haykin, S. (1994). Neural networks: a comprehensive foundation. *Composite Structures*, 9(12), 21-27.
95. LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (2002). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
96. Jiang, X., Pang, Y., Li, X., Pan, J., & Xie, Y. (2018). Deep neural networks with elastic rectified linear units for object recognition. *Neurocomputing*, 2(75), 1132-1139.
97. Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(60), 533-536.
98. Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *Structures*, 9(27), 56-91.
99. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.
100. Chen, W., Xu, J., Dong, M., Yu, Y., Elchalakani, M., & Zhang, F. (2021). Data-driven analysis on ultimate axial strain of FRP-confined concrete cylinders based on explicit and implicit algorithms. *Composite Structures*, 2(68), 113-190.
101. Alhusban, M., Alhusban, M., & Alkhawaldeh, A. A. (2024). The efficiency of using machine learning techniques in fiber-reinforced-polymer applications in structural engineering. *Sustainability*, 16(1), 15-31.
102. Benzaid, R., Mesbah, H., & Chikh, N. E. (2010). FRP-confined concrete cylinders: axial compression experiments and strength model. *Journal of Reinforced Plastics and Composites*, 29(16), 2469-2488.
103. Ozbakkaloglu, T., & Akin, E. (2012). Behavior of FRP-confined normal-and high-strength concrete under cyclic axial compression. *Journal of Composites for Construction*, 16(4), 451-463.
104. Vincent, T., & Ozbakkaloglu, T. (2013). Influence of concrete strength and confinement method on axial compressive behavior of FRP confined high-and ultra-high-strength concrete. *Composites Part B: Engineering*, 5(10), 413-428.

105. Akogbe, R. K., Liang, M., & Wu, Z. M. (2011). Size effect of axial compressive strength of CFRP confined concrete cylinders. *International Journal of Concrete Structures and Materials*, 5(1), 49-55.
106. Karabinis, A. I., & Rousakis, T. C. (2002). Concrete confined by FRP material: A plasticity approach. *Engineering Structures*, 24(7), 923-932.
107. Cui, C., & Sheikh, S. A. (2010). Experimental study of normal-and high-strength concrete confined with fiber-reinforced polymers. *Journal of Composites for Construction*, 14(5), 553-561.
108. Lam, L., & Teng, J. G. (2004). Ultimate condition of fiber reinforced polymer-confined concrete. *Journal of Composites for Construction*, 8(6), 539-548.
109. Touhari, M., & Mitiche-Kettab, R. (2016). Behaviour of FRP confined concrete cylinders: Experimental investigation and strength model. *Periodica Polytechnica Civil Engineering*, 60(4), 647-660.
110. Karabinis, A. I., & Rousakis, T. C. (2002). Concrete confined by FRP material: A plasticity approach. *Engineering Structures*, 24(7), 923-932.
111. Rodsin, K., Hussain, Q., Suparp, S., & Nawaz, A. (2020). Compressive behavior of extremely low strength concrete confined with low-cost glass FRP composites. *Case Studies in Construction Materials*, 9(13), 4-52.
112. Cakiroglu, C. (2023). Explainable data-driven ensemble learning models for the mechanical properties prediction of concrete confined by aramid fiber-reinforced polymer wraps using generative adversarial networks. *Applied Sciences*, 13(21), 119-131.
113. Mohammadi, A. H., Barros, J. A., & Sena-Cruz, J. (2025). An interpretable machine learning-based model for shear resistance prediction of CFRP-strengthened RC beams using experimental and synthetic dataset. *Elsevier*, 5(25), 23-29
114. Onyelowe, K. C., Jayabalan, J., Ebid, A. M., Samui, P., Singh, R. P., Soleymani, A., & Jahangir, H. (2022). Evaluation of the compressive strength of CFRP-wrapped circular concrete columns using artificial intelligence techniques. *Designs*, 6(6), 11-42.





EK-1. Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. Yaygın liflerin özellikleri

Type	Naming Scheme	Diameter	Height	Fiber tensile strength	Fiber sheet thickness	Unconfined Concrete Strength	No. of FRP Layers	FRP circumferential failure strain	Confined Concrete Strength	Strengthening ratio	Axial strain of the unconfined concrete at peak stress	Ultimate strain of FRP-confined concrete	Ratio
Carbon	I.RCC.1.1L	160	320	4300	1	29,51	1	13,15	50,59	1,71	3,77	15,93	4,23
Carbon	I.RCC.2.1L	160	320	4300	1	29,51	1	13,16	49,17	1,67	3,77	14,75	3,91
Carbon	I.RCC.1.3L	160	320	4300	3	29,51	3	14,06	70,83	2,40	3,77	22,22	5,89
Carbon	I.RCC.2.3L	160	320	4300	3	29,51	3	12,42	71,88	2,44	3,77	23,74	6,30
Carbon	I.PCC.1.1L	160	320	4300	1	25,93	1	13,12	39,63	1,53	2,73	12,78	4,68
Carbon	I.PCC.1.3L	160	320	4300	3	25,93	3	13,18	66,14	2,55	2,73	15,16	5,55
Carbon	II.RCC.1.1L	160	320	4300	1	58,24	1	13,17	75,84	1,30	3,02	7,37	2,44
Carbon	II.RCC.2.1L	160	320	4300	1	58,24	1	13,16	79,18	1,36	3,02	9,35	3,10
Carbon	II.RCC.1.3L	160	320	4300	3	58,24	3	13,2	101,48	1,74	3,02	13,72	4,54
Carbon	II.RCC.2.3L	160	320	4300	3	58,24	3	13,17	99,35	1,71	3,02	13,44	4,45
Carbon	II.PCC.1.1L	160	320	4300	1	49,46	1	2,9	52,75	1,07	1,69	2,52	1,49
Carbon	II.PCC.1.3L	160	320	4300	3	49,46	3	13,15	82,91	1,68	1,69	7,27	4,30
Carbon	III.RCC.1.1L	160	320	4300	1	63,01	1	7,79	77,99	1,24	2,69	4,59	1,71
Carbon	III.RCC.2.1L	160	320	4300	1	63,01	1	2,61	74,43	1,18	2,69	2,91	1,08
Carbon	III.RCC.1.3L	160	320	4300	3	63,01	3	4,1	94,92	1,51	2,69	3,87	1,44
Carbon	III.RCC.2.3L	160	320	4300	3	63,01	3	7,15	94,71	1,50	2,69	8,49	3,16
Carbon	III.PCC.1.1L	160	320	4300	1	61,81	1	2,46	62,68	1,01	2,84	3,27	1,15
Carbon	III.PCC.1.3L	160	320	4300	3	61,81	3	12,89	93,19	1,51	2,84	10,54	3,71
Carbon	N1C1A	152	305	849	0,17	48,1	1	15,1	80,9	1,68	0,22	30,09	6,68
Carbon	N1C1B	152	305	849	0,17	48,1		15,3	86,6	1,80	0,22	28,47	6,32
Carbon	N1C2A	152	305	849	0,17	48,1	2	20,1	109,4	2,27	0,22	29,50	6,55
Carbon	N1C2B	152	305	849	0,17	48,1		26,6	126,7	2,63	0,22	35,14	7,80
Carbon	N1C3A	152	305	849	0,17	48,1	3	30,9	162,7	3,38	0,22	32,03	7,11
Carbon	N1C3B	152	305	849	0,17	48,1		28,9	153,6	3,19	0,22	31,35	6,96
Carbon	N1dC1A	152	305	849	0,17	48,1	1	15,5	84,2	1,75	0,22	24,77	5,50
Carbon	N1dC1B	152	305	849	0,17	48,1		16,9	87,9	1,83	0,22	27,75	6,16
Carbon	N1dC2A	152	305	849	0,17	48,1	2	23,7	123,3	2,56	0,22	29,37	6,52
Carbon	N1dC2B	152	305	849	0,17	48,1		19,3	108,2	2,25	0,22	28,42	6,31
Carbon	N1dC3A	152	305	849	0,17	48,1	3	31,3	156,5	3,25	0,22	31,17	6,92
Carbon	N1dC3B	152	305	849	0,17	48,1		28,4	157	3,26	0,22	28,24	6,27
Carbon	M1C1A	152	305	849	0,17	79,9	1	5,25	90,9	1,14	0,24	10,46	2,52
Carbon	M1C1B	152	305	849	0,17	79,9		7,39	105,3	1,32	0,24	14,19	3,42
Carbon	M1C2A	152	305	849	0,17	79,9	2	11,25	142,1	1,78	0,24	13,03	3,14

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon	M1C2B	152	305	849	0,17	79,9		9,74	140,8	1,76	0,24	13,44	3,24
Carbon	M1C3A	152	305	849	0,17	79,9	3	14,79	172,9	2,16	0,24	16,27	3,92
Carbon	M1C3B	152	305	849	0,17	79,9		14,74	181,8	2,28	0,24	15,98	3,85
Carbon	H1C1A	152	305	849	0,17	110,6	1	5,18	107,3	0,97	0,26	6,37	1,67
Carbon	H1C1B	152	305	849	0,17	110,6		5,51	116,6	1,05	0,26	6,68	1,75
Carbon	H1C3A	152	305	849	0,17	110,6	3	8,43	198,4	1,79	0,26	8,47	2,22
Carbon	H1C3B	152	305	849	0,17	110,6		7,3	182,3	1,65	0,26	7,86	2,06
Glass	N2G1A	152	305	620	0,17	47,76	1	13,5	59,1	1,24	0,22	35,63	7,91
Glass	N2G1B	152	305	620	0,17	47,76		11,5	59,8	1,25	0,22	34,77	7,72
Glass	N2G2A	152	305	620	0,17	47,76	2	22,1	88,9	1,86	0,22	42,66	9,47
Glass	N2G2B	152	305	620	0,17	47,76		22,1	88	1,84	0,22	43,69	9,70
Glass	N2G3A	152	305	620	0,17	47,76	3	28,5	113,2	2,37	0,22	44,91	9,97
Glass	N2G3B	152	305	620	0,17	47,76		28	112,5	2,36	0,22	42,70	9,48
Glass	N2dG1A	152	305	620	0,17	47,76	1	15,1	63,4	1,33	0,22	42,70	9,48
Glass	N2dG1B	152	305	620	0,17	47,76		13,5	62,4	1,31	0,22	34,05	7,56
Glass	N2dG2A	152	305	620	0,17	47,76	2	21,4	89,7	1,88	0,22	32,57	7,23
Glass	N2dG2B	152	305	620	0,17	47,76		20,5	88,3	1,85	0,22	35,95	7,98
Glass	N2dG3A	152	305	620	0,17	47,76	3	26,2	108	2,26	0,22	34,41	7,64
Glass	N2dG3B	152	305	620	0,17	47,76					0,22	35,45	7,87
Glass	M1G1A	152	305	620	0,17	79,9	1	7,58	66,7	0,83	0,24	16,22	3,91
Glass	M1G1B	152	305	620	0,17	79,9		8,78	74,7	0,93	0,24	19,05	4,59
Glass	M1G2A	152	305	620	0,17	79,9	2	8,63	92,5	1,16	0,24	17,88	4,31
Glass	M1G2B	152	305	620	0,17	79,9		7,75	94,1	1,18	0,24	17,14	4,13
Glass	M1G3A	152	305	620	0,17	79,9	3	12,55	120,8	1,51	0,24	20,46	4,93
Glass	M1G3B	152	305	620	0,17	79,9		11,82	126,1	1,58	0,24	18,13	4,37
Glass	H1G2A	152	305	620	0,17	110,6	2	6,65	106,3	0,96	0,26	9,05	2,37
Glass	H1G2B	152	305	620	0,17	110,6		4,59	100,3	0,91	0,26	9,85	2,58
Glass	H1G4A	152	305	620	0,17	110,6	4	9,49	174,6	1,58	0,26	13,70	3,59
Glass	H1G4B	152	305	620	0,17	110,6		12,82	172,9	1,56	0,26	14,89	3,90
Carbon	N3ST1A	152	305	405	0,17	45,6	1	12,1	57,7	1,27	0,25	26,44	6,53
Carbon	N3ST1B	152	305	405	0,17	45,6		13,1	55,4	1,21	0,25	28,58	7,06
Carbon	N3ST2A	152	305	405	0,17	45,6	2	19,7	78	1,71	0,25	32,96	8,14
Carbon	N3ST2B	152	305	405	0,17	45,6		21,4	86,8	1,90	0,25	28,91	7,14
Carbon	N3ST3A	152	305	405	0,17	45,6	3	29	106,5	2,34	0,25	33,52	8,28
Carbon	N3ST3B	152	305	405	0,17	45,6		28,3	106	2,32	0,25	31,94	7,89
Carbon	N3dST1A	152	305	405	0,17	45,6	1	12,3	56,3	1,23	0,25	25,71	6,35
Carbon	N3dST1B	152	305	405	0,17	45,6		11,9	58,8	1,29	0,25	25,75	6,36
Carbon	N3dST2A	152	305	405	0,17	45,6	2	18,7	81,9	1,80	0,25	30,45	7,52
Carbon	N3dST2B	152	305	405	0,17	45,6		21,7	82,8	1,82	0,25	32,15	7,94

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon	N3dST3A	152	305	405	0,17	45,6	3	28,6	107,3	2,35	0,25	34,82	8,60
Carbon	N3dST3B	152	305	405	0,17	45,6		27,8	108,6	2,38	0,25	33,81	8,35
Carbon	M2ST1A	152	305	405	0,17	85,6	1	4,43	64,4	0,75	0,26	7,05	1,82
Carbon	M2ST1B	152	305	405	0,17	85,6		4,36	66,6	0,78	0,26	6,98	1,80
Carbon	M2ST2A	152	305	405	0,17	85,6	2	5,6	78,9	0,92	0,26	8,14	2,10
Carbon	M2ST2B	152	305	405	0,17	85,6		5,82	86,1	1,01	0,26	9,57	2,47
Carbon	M2ST4A	152	305	405	0,17	85,6	4	9,95	125,4	1,46	0,26	12,44	3,21
Carbon	M2ST4B	152	305	405	0,17	85,6		9,91	126,5	1,48	0,26	11,90	3,07
Carbon	H2ST2A	152	305	405	0,17	111,8	2	3,24	101,1	0,90	0,26	3,83	1,00
Carbon	H2ST2B	152	305	405	0,17	111,8		4,81	94,3	0,84	0,26	5,98	1,56
Carbon	H2ST5A	152	305	405	0,17	111,8	5	4,96	152,1	1,36	0,26	5,48	1,43
Carbon	H2ST5B	152	305	405	0,17	111,8		5,8	145,3	1,30	0,26	6,78	1,77
Carbon	N4HM1A	152	305	542	0,17	45,7	1	11,1	67,5	1,48	0,24	20,54	4,99
Carbon	N4HM1B	152	305	542	0,17	45,7		10,3	64,1	1,40	0,24	19,05	4,63
Carbon	N4HM2A	152	305	542	0,17	45,7	2	13,3	84,2	1,84	0,24	20,21	4,91
Carbon	N4HM2B	152	305	542	0,17	45,7		12,3	83,1	1,82	0,24	19,59	4,76
Carbon	N4HM3A	152	305	542	0,17	45,7	3	15,6	99,7	2,18	0,24	18,19	4,42
Carbon	N4HM3B	152	305	542	0,17	45,7		14,3	94,9	2,08	0,24	19,30	4,69
Carbon	N4dHM1A	152	305	542	0,17	45,7	1	9,7	65,8	1,44	0,24	18,07	4,39
Carbon	N4dHM1B	152	305	542	0,17	45,7		10,3	65,9	1,44	0,24	19,26	4,68
Carbon	N4dHM2A	152	305	542	0,17	45,7	2	14,2	88,1	1,93	0,24	20,95	5,09
Carbon	N4dHM2B	152	305	542	0,17	45,7		12,3	82	1,79	0,24	19,42	4,72
Carbon	N4dHM3A	152	305	542	0,17	45,7	4	15,3	103,2	2,26	0,24	20,21	4,91
Carbon	N4dHM3B	152	305	542	0,17	45,7		18,6	105,6	2,31	0,24	23,13	5,62
Carbon	M2HM1A	152	305	542	0,17	85,6	1	4,21	91,5	1,07	0,26	6,40	1,65
Carbon	M2HM1B	152	305	542	0,17	85,6		5,43	94,5	1,10	0,26	8,41	2,17
Carbon	M2HM2A	152	305	542	0,17	85,6	2	7,06	117,7	1,38	0,26	8,88	2,29
Carbon	M2HM2B	152	305	542	0,17	85,6		5,53	117,5	1,37	0,26	6,78	1,75
Carbon	M2HM4A	152	305	542	0,17	85,6	4	10,17	161,6	1,89	0,26	9,26	2,39
Carbon	M2HM4B	152	305	542	0,17	85,6		9,53	162,6	1,90	0,26	8,88	2,29
Carbon	H2HM2A	152	305	542	0,17	111,8	2	3,23	139,1	1,24	0,26	4,14	1,08
Carbon	H2HM2B	152	305	542	0,17	111,8		3,14	123,3	1,10	0,26	3,79	0,99
Carbon	H2HM5A	152	305	542	0,17	111,8	5	4,88	176,4	1,58	0,26	4,56	1,19
Carbon	H2HM5B	152	305	542	0,17	111,8		4,99	172,5	1,54	0,26	4,79	1,25
Aramid	N-A-2L-M1	152,5	305	2900	0,2	39	2	1,71	69,2	1,77	0,21	2,32	11,05
Aramid	N-A-2L-M2	152,5	305	2900	0,2	39	2	1,56	67,1	1,72	0,21	2,30	10,95
Aramid	N-A-3L-M1	152,5	305	2900	0,2	39	3	1,66	85	2,18	0,21	2,86	13,62
Aramid	N-A-3L-M2	152,5	305	2900	0,2	39	3	1,84	87,6	2,25	0,21	3,11	14,81
Aramid	H-A-4L-M1	152,5	305	2900	0,2	100	4	1,18	122,3	1,22	0,34	1,45	4,26

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Aramid	H-A-4L-M2	152,5	305	2900	0,2	102	4	1,29	118,7	1,16	0,34	1,29	3,79
Aramid	H-A-6L-M1	152,5	305	2900	0,2	106	6	1,1	154,7	1,46	0,35	1,70	4,86
Aramid	H-A-6L-M2	152,5	305	2900	0,2	106	6	1,07	153,2	1,45	0,35	1,70	4,86
Carbon	H-C-4L-M2	152,5	305	3800	0,12	108	4	0,81	103,3	0,96	0,35	0,96	2,74
Carbon	H-C-6L-M1	152,5	305	3800	0,12	110	6	0,94	122,3	1,11	0,35	1,13	3,23
Aramid	N-A-2L-C1	152,5	305	2900	0,2	38	2	1,5	64,3	1,69	0,21	2,25	10,71
Aramid	N-A-2L-C2	152,5	305	2900	0,2	39	2	1,56	64,3	1,65	0,21	2,25	10,71
Aramid	N-A-3L-C1	152,5	305	2900	0,2	39	3	1,76	97,4	2,50	0,21	4,04	19,24
Aramid	N-A-3L-C2	152,5	305	2900	0,2	39	3	2,02	104,5	2,68	0,21	4,43	21,10
Aramid	H-A-4L-C1	152,5	305	2900	0,2	100	4	1,24	136,4	1,36	0,34	1,82	5,35
Aramid	H-A-4L-C2	152,5	305	2900	0,2	102	4	1,1	125,4	1,23	0,34	1,63	4,79
Aramid	H-A-6L-C1	152,5	305	2900	0,2	104	6	1,16	157,2	1,51	0,34	1,87	5,50
Aramid	H-A-6L-C2	152,5	305	2900	0,2	106	6	1,45	170,9	1,61	0,35	2,13	6,09
Carbon	H-C-4L-C1	152,5	305	3800	0,12	100	4	0,69	102,3	1,02	0,34	1,07	3,15
Carbon	H-C-4L-C2	152,5	305	3800	0,12	100	4	0,81	96	0,96	0,34	1,06	3,12
Carbon	H-C-6L-C1	152,5	305	3800	0,12	109	6	0,64	123,7	1,13	0,35	1,14	3,26
Carbon	H-C-6L-C2	152,5	305	3800	0,12	105	6	0,81	129,9	1,24	0,35	0,81	2,31
Carbon	N-W1-1	152	305	3800	0,12	35,5	1	1,2	44	1,24	0,20	0,77	3,85
Carbon	N-W1-2	152	305	3800	0,12	35,5	1	1,1	43,9	1,24	0,20	0,82	4,10
Carbon	N-W1-3	152	305	3800	0,12	35,5	1	1,1	43,1	1,21	0,20	0,82	4,10
Carbon	N-W2-1	152	305	3800	0,12	38	2	1,17	63,5	1,67	0,21	1,51	7,19
Carbon	N-W2-2	152	305	3800	0,12	38	2	1,17	66,1	1,74	0,21	1,65	7,86
Carbon	N-W2-3	152	305	3800	0,12	36,1	2	1,11	58,6	1,62	0,20	1,27	6,35
Carbon	H-W1-1	152	305	3800	0,12	64,5	1	0,93	65,6	1,02	0,27	0,59	2,19
Carbon	H-W1-2	152	305	3800	0,12	64,5	1	0,81	68,7	1,07	0,27	0,57	2,11
Carbon	H-W1-3	152	305	3800	0,12	62,9	1	0,98	66,3	1,05	0,27	0,65	2,41
Carbon	H-W2-1	152	305	3800	0,12	64,5	2	1,25	72,3	1,12	0,27	0,93	3,44
Carbon	H-W2-2	152	305	3800	0,12	62,4	2	0,94	68,4	1,10	0,27	0,71	2,63
Carbon	H-W2-3	152	305	3800	0,12	64,2	2	1,08	68,2	1,06	0,27	0,82	3,04
Carbon	H-W3-1	152	305	3800	0,12	64,5	3	1,07	85,9	1,33	0,27	1,19	4,41
Carbon	H-W3-2	152	305	3800	0,12	64,5	3	1,01	80,3	1,24	0,27	1,00	3,70
Carbon	H-W4-1	152	305	3800	0,12	64,5	4	1,11	99,4	1,54	0,27	1,38	5,11
Carbon	H-W4-2	152	305	3800	0,12	62,4	4	0,98	101,3	1,62	0,27	1,41	5,22
Carbon	H-W4-3	152	305	3800	0,12	65,8	4	1,03	104,3	1,59	0,27	1,36	5,04
Carbon	UH-W4-1a	152	305	3800	0,12	108	4	0,81	117,4	1,09	0,35	0,96	2,74
Carbon	UH-W5-1	152	305	3800	0,12	112	5	0,8	121,2	1,08	0,36	1,09	3,03
Carbon	UH-W6-1a	152	305	3800	0,12	110	6	0,94	122,3	1,11	0,35	1,13	3,23
Carbon	N-T1-1	152	305	3800	0,12	37,3	1	1,2	42	1,13	0,21	0,79	3,76
Carbon	N-T1-2	152	305	3800	0,12	34,6	2	0,77	41,6	1,20	0,20	0,66	3,30

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon	N-T2-1	152	305	3800	0,12	35,5	1	1,32	59,1	1,66	0,20	1,43	7,15
Carbon	N-T2-2	152	305	3800	0,12	36,3	2	1,36	60,9	1,68	0,21	1,53	7,29
Carbon	N-T2-3	152	305	3800	0,12	37,3	3	1,23	61,7	1,65	0,21	1,45	6,90
Carbon	H-T1-1	152	305	3800	0,12	59	1	0,9	58,8	1,00	0,26	0,72	2,77
Carbon	H-T1-2	152	305	3800	0,12	59	2	1,08	60,1	1,02	0,26	0,56	2,15
Carbon	H-T1-3	152	305	3800	0,12	59	3	1,03	57,3	0,97	0,26	0,50	1,92
Carbon	H-T2-1	152	305	3800	0,12	62	1	1,03	66,8	1,08	0,26	0,84	3,23
Carbon	H-T2-2	152	305	3800	0,12	59	2	1,19	65,4	1,11	0,26	1,05	4,04
Carbon	H-T2-3	152	305	3800	0,12	59	3	1,14	68,4	1,16	0,26	0,95	3,65
Carbon	H-T3-1	152	305	3800	0,12	59	1	1,07	79,2	1,34	0,26	1,24	4,77
Carbon	H-T3-2	152	305	3800	0,12	65	2	0,77	77,8	1,20	0,27	1,20	4,44
Carbon	H-T3-3	152	305	3800	0,12	59	3	0,92	81,6	1,38	0,26	1,54	5,92
Carbon	H-T4-1	152	305	3800	0,12	59	1	0,92	73,3	1,24	0,26	0,99	3,81
Carbon	H-T4-2	152	305	3800	0,12	59	2	0,98	88	1,49	0,26	1,36	5,23
Carbon	H-T4-3b	152	305	3800	0,12	59	3	0,62	81,3	1,38	0,26	1,23	4,73
Carbon	UH-T1-1	152	305	3800	0,12	92	1	0,78	96,7	1,05	0,32	0,55	1,72
Carbon	UH-T1-2	152	305	3800	0,12	85,6	2	0,68	91	1,06	0,31	0,45	1,45
Carbon	UH-T1-3b	152	305	3800	0,12	92	3	0,78	97,6	1,06	0,32	0,55	1,72
Carbon	UH-T2-1	152	305	3800	0,12	93,1	1	0,92	97,9	1,05	0,33	0,50	1,52
Carbon	UH-T2-2	152	305	3800	0,12	83,1	2	0,92	95,6	1,15	0,31	0,50	1,61
Carbon	UH-T2-3	152	305	3800	0,12	80,4	3	0,5	89,7	1,12	0,30	0,46	1,53
Carbon	UH-T3-1	152	305	3800	0,12	92,7	1	0,75	101,3	1,09	0,32	0,81	2,53
Carbon	UH-T3-2	152	305	3800	0,12	94,7	2	0,86	103,4	1,09	0,33	0,89	2,70
Carbon	UH-T3-3	152	305	3800	0,12	90,1	3	0,84	96	1,07	0,32	0,82	2,56
Carbon	UH-T4-1	152	305	3800	0,12	97,5	1	0,97	107,2	1,10	0,33	1,01	3,06
Carbon	UH-T4-2	152	305	3800	0,12	93	2	0,71	97,9	1,05	0,33	0,92	2,79
Carbon	UH-T4-3a	152	305	3800	0,12	100	3	0,89	107,9	1,08	0,34	0,93	2,74
Carbon	UH-T5-1b	152	305	3800	0,12	87	1	0,69	110,8	1,27	0,31	0,83	2,68
Carbon	UH-T5-2	152	305	3800	0,12	102,5	2	0,87	119,2	1,16	0,34	1,06	3,12
Carbon	UH-T5-3	152	305	3800	0,12	102,5	3	0,74	112,8	1,10	0,34	1,01	2,97
Carbon	UH-T6-1	152	305	3800	0,12	102,5	1	0,89	121,4	1,18	0,34	1,10	3,24
Carbon	UH-T6-2a	152	305	3800	0,12	94	2	0,78	124,4	1,32	0,33	1,16	3,52
Carbon	UH-T6-3	152	305	3800	0,12	93	3	0,66	112,1	1,21	0,33	0,60	1,82
Carbon		100	200	3248	0,17	25,2	1			0,00	0,31	2,55	8,23
Carbon		100	200	3248	0,17	25,9	1		63	2,43	0,21	2,18	10,38
Carbon		100	200	3248	0,17	28,1	1		66,4	2,36	0,33	2,29	6,94
Carbon		100	200	3248	0,17	26,8	1		64,8	2,42	0,38	2,48	6,53
Carbon		200	400	3248	0,17	21,8	2		64,3	2,95	0,26	2,79	10,73
Carbon		200	400	3248	0,17	20,6	2		69,1	3,35	0,17	2,69	15,82

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon		200	400	3248	0,17	23,6	2		60,1	2,55	0,21	2,10	10,00
Carbon		200	400	3248	0,17	20,6	2		66,3	3,22	0,24	2,54	10,58
Carbon		300	600	3248	0,17	25,3	3		58,8	2,32	0,21	1,80	8,57
Carbon		300	600	3248	0,17	24	3		59,4	2,48	0,21	2,00	9,52
Carbon		300	600	3248	0,17	23,7	3		63	2,66	0,20	1,90	9,50
Carbon		300	600	3248	0,17	25	3		60,6	2,42	0,26	2,00	7,69
Carbon	A1	200	320	4400	0,12	20	0		40,9	2,05		2,72	
Carbon	A2	200	320	4400	0,12	20	0		38,5	1,93	2,80	2,80	1,00
Carbon	C1	200	320	4400	0,12	20	1		43	2,15	2,80	7,96	2,84
Carbon	C2	200	320	4400	0,12	20	1		41,6	2,08	2,80	7,14	2,55
Carbon	C3	200	320	4400	0,12	20	1		46	2,30	2,79	3,49	1,25
Carbon	C7	200	320	4400	0,12	20	2		51,5	2,58	2,80	8,77	3,13
Carbon	C8	200	320	4400	0,12	20	2		50	2,50	2,80	5,77	2,06
Carbon	C9	200	320	4400	0,12	20	2		55	2,75	2,80	8,60	3,07
Carbon	C13	200	320	4400	0,12	20	3		67	3,35	2,80	17,60	6,29
Carbon	C14	200	320	4400	0,12	20	3		51,5	2,58	2,80	10,90	3,89
Carbon	C15	200	320	4400	0,12	20	3		45	2,25	2,80	6,72	2,40
Carbon	B1	200	320	4400	0,12	16	0		33,9	2,12		2,02	
Carbon	B2	200	320	4400	0,12	16	0		35,7	2,23	1,80	1,80	1,00
Carbon	C4	200	320	4400	0,12	16	1		42,5	2,66	1,80	8,59	4,77
Carbon	C5	200	320	4400	0,12	16	1		42	2,63	1,80	12,38	6,88
Carbon	C6	200	320	4400	0,12	16	1		41	2,56	1,80	2,96	1,64
Carbon	C10	200	320	4400	0,12	16	2		50	3,13	1,80	6,04	3,36
Carbon	C11	200	320	4400	0,12	16	2		48,5	3,03	1,80	10,40	5,78
Carbon	C12	200	320	4400	0,12	16	2		50	3,13	1,80	10,72	5,96
Carbon	C16	200	320	4400	0,12	16	3		63	3,94	1,80	17,18	9,54
Carbon	C17	200	320	4400	0,12	16	3		67,5	4,22	1,80	17,05	9,47
Carbon	C18	200	320	4400	0,12	16	3		65,5	4,09	1,80	16,86	9,37
Carbon	C1-1	152	305	3420	0,17	35,9	1		50,4	1,40	1,28	1,27	0,99
Carbon	C1-2	152	305	3420	0,17	35,9	1		47,2	1,31	1,28	1,11	0,86
Carbon	C1-3	152	305	3420	0,17	35,9	1		53,2	1,48	1,28	1,29	1,01
Carbon	C2-1	152	305	3420	0,33	35,9	2		68,7	1,91	1,28	1,68	1,31
Carbon	C2-2	152	305	3420	0,33	35,9	2		69,9	1,95	1,28	1,96	1,53
Carbon	C2-3	152	305	3420	0,33	35,9	2		71,6	1,99	1,28	1,85	1,44
Carbon	C3-1	152	305	3420	0,50	34,3	3		82,6	2,41	1,15	2,05	1,78
Carbon	C3-2	152	305	3420	0,50	34,3	3		90,4	2,64	1,15	2,41	2,10
Carbon	C3-3	152	305	3420	0,50	34,3	3		97,3	2,84	1,15	2,52	2,19
Carbon	C1-100	152	305	3420	0,17	34,3	1		50,3	1,47	1,15	1,02	0,89

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon	C1-250	152	305	3420	0,17	34,3	1		50	1,46	1,15	1,08	0,94
Carbon	C1-400	152	305	3420	0,17	34,3	1		56,7	1,65	1,15	1,17	1,02
Glass	G1-1	152	305	450	1,27	38,5	1		56,2	1,46	1,19		
Glass	G1-2	152	305	450	1,27	38,5	1		51,9	1,35	1,19	1,32	1,10
Glass	G1-3	152	305	450	1,27	38,5	1		58,3	1,51	1,19	1,46	1,22
Glass	G2-1	152	305	450	2,54	38,5	2		75,7	1,97	1,19	2,46	2,06
Glass	G2-2	152	305	450	2,54	38,5	2		77,3	2,01	1,19	2,19	1,83
Glass	G2-3	152	305	450	2,54	38,5	2		75,2	1,95	1,19		
Carbon	CL1-	160	320	403	1	24	1	47	1,96	2,71	16,90	6,24	
Carbon	CL1-	160	320	403	1	24	1	45,3	1,89	2,71	15,60	5,76	
Carbon	CL1-	160	320	403	1	24	1	29,5	1,23	2,71	9,31	3,44	
Carbon	CL2-	160	320	403	1	24	2	55,8	2,33	2,71	24,10	8,89	
Carbon	CL2-	160	320	403	1	24	2	55,5	2,31	2,71	21,80	8,04	
Carbon	CL2-	160	320	403	1	24	2	58	2,42	2,71	25,20	9,30	
Carbon	CL3-	160	320	403	1	24	3	77,3	3,22	2,71	32,00	11,81	
Carbon	CL3-	160	320	403	1	24	3	79	3,29	2,71	33,40	12,32	
Carbon	CL3-	160	320	403	1	24	3	72,9	3,04	2,71	29,10	10,74	
Carbon	CN1-	160	320	403	1	41,6	1	49,8	1,2	3,11	9,92	3,19	
Carbon	CN1-	160	320	403	1	41,6	1	61,3	1,47	3,11	12,50	4,02	
Carbon	CN1-	160	320	403	1	41,6	1	62,9	1,51	3,11	12,90	4,15	
Carbon	CN2-	160	320	403	1	41,6	2	73,2	1,76	3,11	15,70	5,05	
Carbon	CN2-	160	320	403	1	41,6	2	76,6	1,84	3,11	18,40	5,92	
Carbon	CN2-	160	320	403	1	41,6	2	77	1,85	3,11	19,90	6,40	
Carbon	CN3-	160	320	403	1	41,6	3	96,9	2,33	3,11	25,20	8,10	
Carbon	CN3-	160	320	403	1	41,6	3	95,9	2,31	3,11	23,00	7,40	
Carbon	CN3-	160	320	403	1	41,6	3	92,7	2,23	3,11	22,40	7,20	
Carbon	CH1-	160	320	403	1	61,5	1	80	1,3	3,02	10,90	3,61	
Carbon	CH1-	160	320	403	1	61,5	1	78,9	1,28	3,02	9,78	3,24	
Carbon	CH1-	160	320	403	1	61,5	1	81,1	1,32	3,02	9,72	3,22	
Carbon	CH2-	160	320	403	1	61,5	2	96	1,56	3,02	11,60	3,84	
Carbon	CH2-	160	320	403	1	61,5	2	99,4	1,62	3,02	13,70	4,54	
Carbon	CH2-	160	320	403	1	61,5	2	98,2	1,6	3,02	14,90	4,93	
Carbon	CH3-	160	320	403	1	61,5	3	104,99	1,71	3,02	15,60	5,17	
Carbon	CH3-	160	320	403	1	61,5	3	117,14	1,9	3,02	17,80	5,89	
Carbon	CH3-	160	320	403	1	61,5	3	105,44	1,71	3,02	15,90	5,26	
Glass	GL1-	160	320	325	1	26,2	1	38,3	1,46	2,67	15,00	5,62	
Glass	GL1-	160	320	325	1	26,2	1	34,6	1,32	2,67	12,60	4,72	
Glass	GL1-	160	320	325	1	26,2	1	38	1,45	2,67	13,90	5,21	

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Glass	GL2-	160	320	325	1	26,2	2	30,2	1,15	2,67	6,81	2,55	
Glass	GL2-	160	320	325	1	26,2	2	49,4	1,89	2,67	24,10	9,03	
Glass	GL2-	160	320	325	1	26,2	2	52,5	2	2,67	25,50	9,55	
Glass	GL3-	160	320	325	1	26,2	3	62,8	2,4	2,67	33,90	12,70	
Glass	GL3-B	160	320	325	1	26,2	3	56,4	2,15	2,67	29,80	11,16	
Glass	GL3-	160	320	325	1	26,2	3	54,7	2,09	2,67	28,90	10,82	
Glass	GN1-	160	320	325	1	42,6	1	56,5	1,33	2,89	11,00	3,81	
Glass	GN1-	160	320	325	1	42,6	1	55,5	1,3	2,89	10,40	3,60	
Glass	GN1-	160	320	325	1	42,6	1	59,8	1,4	2,89	12,30	4,26	
Glass	GN2-	160	320	325	1	42,6	2	68,5	1,61	2,89	16,50	5,71	
Glass	GN2-	160	320	325	1	42,6	2	70	1,64	2,89	17,20	5,95	
Glass	GN2-	160	320	325	1	42,6	2	71,7	1,68	2,89	18,10	6,26	
Glass	GN3-	160	320	325	1	42,6	3	75,5	1,77	2,89	21,00	7,27	
Glass	GN3-	160	320	325	1	42,6	3	78,8	1,85	2,89	24,90	8,62	
Glass	GN3-	160	320	325	1	42,6	3	77,5	1,82	2,89	22,40	7,75	
Glass	GH1-	160	320	325	1	61,7	1	69,4	1,12	3,11	8,85	2,85	
Glass	GH1-	160	320	325	1	61,7	1	73,1	1,18	3,11	9,37	3,01	
Glass	GH1-	160	320	325	1	61,7	1	77,5	1,26	3,11	11,10	3,57	
Glass	GH2-	160	320	325	1	61,7	2	80,8	1,31	3,11	14,90	4,79	
Glass	GH2-	160	320	325	1	61,7	2	76,7	1,24	3,11	13,50	4,34	
Glass	GH2-	160	320	325	1	61,7	2	78	1,26	3,11	14,40	4,63	
Glass	GH3-	160	320	325	1	61,7	3	90,1	1,46	3,11	17,10	5,50	
Glass	GH3-	160	320	325	1	61,7	3	92,1	1,49	3,11	18,80	6,05	
Glass	GH3-	160	320	325	1	61,7	3	94,4	1,53	3,11	19,50	6,27	
Carbon	80 - 1	150	300	4410	0,17	70,6	0		72,4	1,03		0,36	
Carbon	80 - 2t	150	300	4410	0,17	70,6	0		70,1	0,99		0,36	
Carbon	80 - 3t	150	300	4410	0,17	70,6	0		69,2	0,98		0,34	
Carbon	80L1 - 1t	150	300	4410	0,17	70,6	1		87,3	1,24	2,85	0,71	2,01
Carbon	80L1 - 2t	150	300	4410	0,17	70,6	1		84	1,19	2,86	0,65	1,86
Carbon	80L1C - 3t	150	300	4410	0,17	70,6	2		83,2	1,18	2,86	0,76	2,17
Carbon	80L2 - 1t	150	300	4410	0,17	70,6	2		94,1	1,33	2,86	0,80	2,30
Carbon	80L2 - 2t	150	300	4410	0,17	70,6	2		98,1	1,39	2,86	0,92	2,62
Carbon	80L2C - 3t	150	300	4410	0,17	70,6	3		107,2	1,52	2,86	0,98	2,81
Carbon	80L3 - 1t	150	300	4410	0,17	70,6	3		114,2	1,62	2,86	1,29	3,67
Carbon	80L3 - 3t	150	300	4410	0,17	70,6	3		110,4	1,56	2,86	1,22	3,48
Carbon	80L3C - 2t	150	300	4410	0,17	70,6	3		108,2	1,53	2,85	1,10	3,13
Carbon	100 - 1	150	300	4410	0,17	82,1	0		87,6	1,07		0,32	
Carbon	100 - 2t	150	300	4410	0,17	82,1	0		76,6	0,93		0,29	

EK-1. (devam) Önceki literatürden elde edilen tam veri seti

Çizelge 1.1. (devam) Yaygın liflerin özellikleri

Carbon	100 - 3t	150	300	4410	0,17	82,1	0		82,2	1,00		0,34	
Carbon	100L1 - 1t	150	300	4410	0,17	82,1	1		94,1	1,15	3,16	0,46	1,46
Carbon	100L1 - 3t	150	300	4410	0,17	82,1	1		96	1,17	3,17	0,56	1,77
Carbon	100L1C - 2t	150	300	4410	0,17	82,1	1		97,6	1,19	3,17	0,56	1,76
Carbon	100L2 - 1t	150	300	4410	0,17	82,1	2		97,4	1,19	3,17	0,52	1,64
Carbon	100L2 - 2t	150	300	4410	0,17	82,1	2		98,9	1,20	3,17	0,44	1,40
Carbon	100L2C - 3t	150	300	4410	0,17	82,1	2		98,2	1,20	3,18	0,53	1,68
Carbon	100L3 - 1t	150	300	4410	0,17	82,1	3		124,2	1,51	3,17	1,04	3,30
Carbon	100L3 - 3t	150	300	4410	0,17	82,1	3		120,4	1,47	3,17	0,87	2,77
Carbon	100L3C - 2t	150	300	4410	0,17	82,1	3		129,6	1,58	3,17	0,98	3,11
Glass	L-C-1L	150	300	377,64	0,16	5	1		12,28	1,95	0,35	10,85	3,75
Glass	L-C-1L	150	300	377,64	0,16	5	1		14,96	2,38	0,35	21,70	7,50
Glass	L-C-1L	150	300	377,64	0,16	5	1		13,03	2,07	0,35	20,76	7,18
Glass	L-C-2L	150	300	377,64	0,16	5	2		21,43	3,41	0,35	25,50	8,81
Glass	L-C-2L	150	300	377,64	0,16	5	2		22,28	3,54	0,35	27,35	9,45
Glass	L-C-2L	150	300	377,64	0,16	5	2		21,64	3,44	0,35	25,70	8,88
Glass	L-C-3L	150	300	377,64	0,16	5	3		25,08	3,99	0,35	24,68	8,53
Glass	L-C-3L	150	300	377,64	0,16	5	3		25,89	4,12	0,35	24,00	8,29
Glass	L-C-3L	150	300	377,64	0,16	5	3		25,38	4,04	0,35	24,45	8,45
Glass	N-C-1L	150	300	377,64	0,16	15	1		20,7	1,32	0,65	14,50	9,48
Glass	N-C-1L	150	300	377,64	0,16	15	1		19,57	1,25	0,65	10,63	6,95
Glass	N-C-1L	150	300	377,64	0,16	15	1		19,65	1,26	0,65	10,80	7,06
Glass	N-C-2L	150	300	377,64	0,16	15	2		26,84	1,72	0,65	19,50	12,75
Glass	N-C-2L	150	300	377,64	0,16	15	2		27,96	1,79	0,65	10,00	6,54
Glass	N-C-2L	150	300	377,64	0,16	15	2		28,43	1,82	0,65	23,62	15,44
Glass	N-C-3L	150	300	377,64	0,16	15	3		35,57	2,27	0,65	23,20	15,16
Glass	N-C-3L	150	300	377,64	0,16	15	3		36,68	2,34	0,65	18,50	12,09
Glass	N-C-3L	150	300	377,64	0,16	15	3		32,97	2,11	0,65	24,85	16,24



Gazili olmak ayrıcalıktır