



# MAKİNE ÖĞRENMESİ İLE MÜHENDİSLİK ÖZELLİKLERİNİN MODELLENMESİ

Lifli Çimento Kompozitleri

Necim KAYA

**yaz**  
yayınları

# MAKİNE ÖĞRENMESİ İLE MÜHENDİSLİK ÖZELLİKLERİNİN MODELLENMESİ

Lifli Çimento Kompozitleri

Necim KAYA

**yaz**  
yayınları  
2025

**Makine Öğrenmesi ile Mühendislik  
Özelliklerinin Modellenmesi:  
Lifli Çimento Kompozitleri**

Yazar: Necim KAYA

ORCID NO: 0000-0003-1478-761X

---

**© YAZ Yayınları**

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

---

E\_ISBN 978-625-5838-46-9

Temmuz 2025 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3  
İscehisar / AFYONKARAHİSAR

[www.yazyayinlari.com](http://www.yazyayinlari.com)

[yazyayinlari@gmail.com](mailto:yazyayinlari@gmail.com)

[info@yazyayinlari.com](mailto:info@yazyayinlari.com)

Bu kitap, Necim KAYA tarafından hazırlanan ve “Yüksek Sıcaklık ve Sülfat Hücumuna Maruz Kalmış Çimento Esaslı Lifli Kompozitlerin Mühendislik Özelliklerinin Makine Öğrenmesi Yöntemleriyle İncelenmesi” başlığını taşıyan doktora tezinden üretilmiştir. Söz konusu tez Doç. Dr. Serhat DEMİRHAN danışmanlığında tamamlanmış olup, danışman hocamız, tezden üretilecek yayınlardaki tüm akademik haklarından kendi isteğiyle feragat ettiğini beyan etmiş ve bu nedenle adı yazarlar arasında yer almamıştır.

## ÖNSÖZ

Bu çalışmada, çimento esaslı lifli kompozitlerin performansını etkileyen yüksek sıcaklık ve sülfat etkisi gibi çift yönlü dayanıklılık sorunları makine öğrenmesi yöntemiyle detaylı bir şekilde incelenmiştir. Ayrıca lif türü, çimentonun uçucu kül ile ikame edilmesi, farklı sıcaklıklarda yüksek sıcaklık etkisi ve sülfat etkisi gibi faktörlerin bu kompozitlerin özellikleri üzerindeki etkilerini farklı makine öğrenmesi yöntemleri ile analiz ederek yöntemlerin kıyaslaması yapılmıştır. Ayrıca, makine öğrenmesi tabanlı tahmin modelleri ile desteklenen multidisipliner yaklaşımlar sayesinde, bu alandaki deneysel çalışmaların daha verimli hale getirilmesi, iş gücü ve zaman maliyetlerinin azaltılması mümkün olacaktır. Böylelikle, mühendislik uygulamalarında karar alma süreçleri daha hızlı ve isabetli bir şekilde yürütülebilecek, malzeme tasarımı ve performans değerlendirme süreçleri dijitalleşmenin sunduğu avantajlarla daha etkin yönetilebilecektir.

Bu çalışma esnasında sabırları ve destekleri için eşime, çocuklarıma, anneme, kardeşlerime, akademik çalışmalarımda her zaman yanımda olan, hem hocalık hem ağabeylik eden, öğretim üyesi Yılmaz KAYA'ya ve hiçbir zaman desteklerini esirgemeyen, emektar akademisyen babam Ekrem KAYA'ya, sonsuz teşekkürlerimi sunarım.

Saygılarımla...

Necim KAYA

**Canım Aileme...**

# İÇİNDEKİLER

|                                                                               |    |
|-------------------------------------------------------------------------------|----|
| 1. GİRİŞ.....                                                                 | 1  |
| 1.1. Amaç ve Kapsam .....                                                     | 6  |
| 2. MAKİNE ÖĞRENMESİ .....                                                     | 9  |
| 2.1. Veri işleme grup yöntemi (Group method of data<br>handling (GMDH)) ..... | 9  |
| 2.2. Aşırı öğrenme makinesi (Extreme learning machine<br>(ELM)).....          | 16 |
| 3. VERİ SETİNİN OLUŞTURLUMASI.....                                            | 21 |
| 3.1. Ham verilerin işlenmesi ve makine öğrenmesi<br>yöntemleri.....           | 21 |
| 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....                                       | 32 |
| 4.1. Makine Öğrenmesi Yöntemleri .....                                        | 32 |
| 4.1.1. GMDH için eğitim veri seti.....                                        | 35 |
| 4.1.2. GMDH için test veri seti .....                                         | 36 |
| 4.1.3. GMDH için tüm veri seti .....                                          | 37 |
| 4.1.4. ELM için eğitim veri seti .....                                        | 45 |
| 4.1.5. ELM için test veri seti .....                                          | 47 |
| 4.1.6. ELM için tüm veri seti.....                                            | 47 |

|                                          |    |
|------------------------------------------|----|
| 4.2. Eğitim Seti Karşılaştırması.....    | 56 |
| 4.2.1. Senaryo 1: .....                  | 56 |
| 4.2.2. Senaryo 2: .....                  | 57 |
| 4.2.3. Senaryo 3: .....                  | 57 |
| 4.3. Test Seti Karşılaştırması .....     | 58 |
| 4.4. Tüm Veri Seti Karşılaştırması ..... | 59 |
| 5. SONUÇLAR VE ÖNERİLER .....            | 63 |
| 5.1. Sonuçlar.....                       | 63 |
| 5.2. Öneriler .....                      | 64 |
| KAYNAKLAR.....                           | 66 |



# SİMGELER VE KISALTMALAR

## Kısaltmalar

|                         |                                                                                                  |
|-------------------------|--------------------------------------------------------------------------------------------------|
| ASTM                    | : American Society for Testing and Materials (Amerikan Test ve Malzeme Topluluğu)                |
| BS                      | : Çelik lif                                                                                      |
| CEM I 52,5 N            | : Genel amaçlı, 52.5 MPa basınca dayanabilen ve normal dayanım sınıfına sahip Portland çimentosu |
| ÇELK                    | : Çimento Esaslı Lifli Kompozit                                                                  |
| MSE                     | : Mean square error (Ortalama kare hatası)                                                       |
| NC                      | : Nano Kalsit                                                                                    |
| PP                      | : Polipropilen                                                                                   |
| R                       | : Korelasyon katsayısı                                                                           |
| SEM                     | : Scanning Elektron Microscope (Taramalı Elektron Mikroskobu)                                    |
| TS                      | : Türk Standartları                                                                              |
| UK                      | : Uçucu Kül                                                                                      |
| UPV                     | : Ultrases Dalgası Geçiş Hızı                                                                    |
| CH, Ca(OH) <sub>2</sub> | : Kalsiyum hidroksit                                                                             |
| C-S-H                   | : Kalsiyum Silikat Hidrat                                                                        |
| C <sub>3</sub> A        | : Trikalsiyum Alüminat                                                                           |
| C <sub>4</sub> AF       | : Tetra Kalsiyum Alümino Ferrit                                                                  |
| BS_FA0_0                | : Çelik lifli, uçucu kül kullanılmayan, oda sıcaklığındaki numune                                |
| BS_FA0_200              | : Çelik lifli, uçucu kül kullanılmayan, 200°C sıcaklıkta bekletilen numune                       |
| BS_FA0_500              | : Çelik lifli, uçucu kül kullanılmayan, 500°C sıcaklıkta bekletilen numune                       |
| BS_FA30_0               | : Çelik lifli, %30 uçucu kül kullanılan, oda sıcaklığındaki numune                               |
| BS_FA30_200             | : Çelik lifli, %30 uçucu kül kullanılan, 200°C sıcaklıkta bekletilen numune                      |
| BS_FA30_500             | : Çelik lifli, %30 uçucu kül kullanılan, 500°C sıcaklıkta bekletilen numune                      |

|                       |                                                                                                  |
|-----------------------|--------------------------------------------------------------------------------------------------|
| <b>H_FA0_0</b>        | : Hibrit lifli, uçucu kül kullanılmayan, oda sıcaklığındaki numune                               |
| <b>H_FA0_200</b>      | : Hibrit lifli, uçucu kül kullanılmayan, 200°C sıcaklıkta bekletilen numune                      |
| <b>H_FA0_500</b>      | : Hibrit lifli, uçucu kül kullanılmayan, 500°C sıcaklıkta bekletilen numune                      |
| <b>H_FA30_0</b>       | : Hibrit lifli, %30 uçucu kül kullanılan, oda sıcaklığındaki numune                              |
| <b>H_FA30_200</b>     | : Hibrit lifli, %30 uçucu kül kullanılan, 200°C sıcaklıkta bekletilen numune                     |
| <b>H_FA30_500</b>     | : Hibrit lifli, %30 uçucu kül kullanılan, 500°C sıcaklıkta bekletilen numune                     |
| <b>BS_FA0_NC_0</b>    | : Çelik lifli, uçucu kül kullanılmayan, nano kalsit ilaveli oda sıcaklığındaki numune            |
| <b>BS_FA0_NC_200</b>  | : Çelik lifli, uçucu kül kullanılmayan, nano kalsit ilaveli 200°C sıcaklıkta bekletilen numune   |
| <b>BS_FA0_NC_500</b>  | : Çelik lifli, uçucu kül kullanılmayan, nano kalsit ilaveli 500°C sıcaklıkta bekletilen numune   |
| <b>BS_FA30_NC_0</b>   | : Çelik lifli, %30 uçucu kül kullanılan, nano kalsit ilaveli, oda sıcaklığındaki numune          |
| <b>BS_FA30_NC_200</b> | : Çelik lifli, %30 uçucu kül kullanılan, nano kalsit ilaveli, 200°C sıcaklıkta bekletilen numune |
| <b>BS_FA30_NC_500</b> | : Çelik lifli, %30 uçucu kül kullanılan, nano kalsit ilaveli, 500°C sıcaklıkta bekletilen numune |
| <b>H_FA0_NC_0</b>     | : Hibrit lifli, uçucu kül kullanılmayan, nano kalsit ilaveli oda sıcaklığındaki numune           |
| <b>H_FA0_NC_200</b>   | : Hibrit lifli, uçucu kül kullanılmayan, nano kalsit ilaveli 200°C sıcaklıkta bekletilen numune  |
| <b>H_FA0_NC_500</b>   | : Hibrit lifli, uçucu kül kullanılmayan, nano kalsit ilaveli 500°C sıcaklıkta bekletilen numune  |
| <b>H_FA30_NC_0</b>    | : Hibrit lifli, %30 uçucu kül kullanılan, nano kalsit ilaveli, oda sıcaklığındaki numune         |

- H\_FA30\_NC\_200** : Hibrit lifli, %30 uçucu kül kullanılan, nano kalsit ilaveli, 200°C sıcaklıkta bekletilen numune
- H\_FA30\_NC\_500** : Hibrit lifli, % 30 uçucu kül kullanılan, nano kalsit ilaveli, 500°C sıcaklıkta bekletilen numune

*"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."*

## 1. GİRİŞ

Makine öğrenmesi yöntemlerinin kullanılması, karmaşık ilişkileri daha derinlemesine anlamak ve malzeme özelliklerinin tahmin edilmesi için güçlü bir araçtır. Makine öğrenmesi algoritmaları, büyük miktarda veriyi işleyerek malzeme geliştirme sürecindeki karar alma sürecini hem destekleyip hem de optimize edebilir.

Makine öğrenmesi (Machine Learning (ML)), klasik anlamda “insan müdahalesi olmadan veriden öğrenebilen sistemler” olarak tanımlanır (Samuel, 1959; Bishop, 2025). Bu alan, istatistik, optimizasyon ve bilgisayarla görme gibi disiplinlerin kesişim noktasında konumlanmakta olup, özellikle büyük veri çağında hem teorik hem de uygulamalı yönüyle öne çıkmaktadır (Cabrera Martin et al., 2025; Chen et al., 2024).

Makine öğrenmesinin akademik kökleri, 1940'lara kadar uzanır; McCulloch ve Pitts'in matematiksel sinir modelleri ile Hebb'in öğrenme ilkeleri bu temeli oluşturur. Samuel'in dama oynayan bilgisayar programı ML'yi pratiğe taşımış, Rosenblatt'ın 1957 perceptron çalışması önemli bir adım olmuş ancak Minsky&Papert'ın 1969 eleştirisiyle bir duraksama yaşanmıştır. Ardından

1980’lerde çok katmanlı sinir ağlarının yeniden canlanması ve 2010’ların derin öğrenme atılımıyla ML yeni bir ivme kazanmıştır (Gholami& Al Abdwani, 2025; Wikipedia, 2025).

Bu gelişmeler, ML uygulamalarını çeşitlendirmiştir. Gözetimli, gözetimsiz, yarı-gözetimli ve pekiştirmeli öğrenme gibi farklı öğrenme paradigma ve metotları; finans, sağlık, tarım, endüstri ve eğitim gibi alanlarda kullanılmıştır. Örneğin, derin öğrenme tabanlı modeller; hastalık teşhisi, dolandırıcılık tespiti, arıza tahmini gibi uygulamalarda önemli başarılar elde etmiştir (Peter, 2025; Zhang et al., 2025).

Son yıllarda literatürde dikkat çeken yeni alt alanlar ortaya çıkmıştır:

**Extreme Learning Machine (ELM):** ELM, **tek katmanlı ileri beslemeli ağ (SLFN)** için geliştirilen, son derece hızlı bir öğrenme algoritmasıdır. 2004 yılında Guang-Bin Huang ve arkadaşları tarafından tanıtılmıştır (Huang et al., 2006). ELM’de gizli katman ağırlıkları ve biaslar rastgele atanır ve sadece çıkış katmanındaki ağırlıklar analitik çözümle belirlenir. Bu da geleneksel yapay sinir ağlarına kıyasla çok hızlı eğitim süresi sağlar. Bu yöntemin; Çok hızlı eğitim: Gerçek zamanlı uygulamalar için uygun olması, Yüksek genelleme kabiliyeti: Aşırı

öğrenmeye karşı dayanıklı olması ve Basit yapı: Sadece bir gizli katman içerip, yapı sabitliği bulunması gibi farklı avantajları bulunmaktadır. ELM yöntemi; Lifli beton dayanımı tahmini (Shahmansouri et al., 2020), Yapı mühendisliği, enerji tüketimi, zaman serisi öngörüsü, Görüntü işleme gibi kullanım alanlarında mühendislik hesaplama ve uygulamalarına katkı sağlamaktadır.

**Evolving Machine Learning (EML):** Veri ve kavram değişikliklerine (data/concept drift) gerçek zamanlı uyum sağlayan sistemler tasarlanmakta, dinamik çevrelerde öğrenme yeteneği güçlendirilmektedir. Bu paradigma, özellikle online ve akış verisi uygulamalarında kullanılmaya başlanmıştır (Cabrera Martin et al., 2025).

**Group Method of Data Handling (GMDH):** GMDH, 1968'de Alexey Ivakhnenko tarafından geliştirilen, veri odaklı bir modelleme yöntemidir. Bu yöntem, sistemin giriş-çıkış ilişkisini tanımlayan çok terimli regresyon modellerini üretmek üzere yapılandırılmıştır (Ivakhnenko, 1968). GMDH algoritması, kendini organize eden bir yapıya sahiptir. Bu yöntemde farklı model yapıları test edilir, performansı yüksek olanlar sonraki katmana aktarılır. Model, çapraz doğrulama gibi performans ölçütlerine göre otomatik olarak durdurulur. Bu yöntemin Otomatik modelseçimi (Giriş değişkenlerinden anlamlı

olanlar seçilir), Polinom temelli öğrenme (İkili kombinasyonlarla oluşturulan polinomlar üzerinden tahmin yapılır.), Aşırı öğrenme kontrolü (Aşırı uyum riski, doğrulama verileriyle minimize edilir.) gibi uygulamada kolaylık sağlayan özellikleri bulunmaktadır. Ayrıca bu yöntem, hava kalitesi, enerji sistemleri, biyomedikal veri analizi gibi alanların yanı sıra beton basınç dayanımı tahmini (Kalayci&Dogan, 2021), malzeme özellik modellemesi (Tiryaki et al., 2020) gibi farklı inşaat mühendisliği çalışmalarında kullanılmaktadır.

**Imbalanced Learning:** Dengesiz veri setlerinde performansı artırmaya yönelik yöntemler önem kazanmıştır. Sınıf dağılımı dengesiz veri setlerinde bu tür yöntemler model doğruluğunu artırır. Örneğin ensemble yöntemleri, çok-sınıflı ve uzun kuyruklu (long-tail) problemler için stratejiler geliştirilmiştir (Chen et al., 2024).

**Güvenli ve gizlilik korumalı ML:** SecureML, federated learning ve güvenli çok-terafli hesaplama (MPC) sayesinde hassas verilerle çalışırken işbirliğini koruyacaktır (Liao et al., 2025).

**Generatif yapay zekâ:** GAN, VAE ve diffusion modelleri; eğitim, yaratıcı içerik üretimi ve klinik uygulamalar gibi alanlarda önemli bir ivme kazanmıştır (Anandhi, 2025).



Derin öğrenme süreçleri için performans iyileştirme yöntemleri, algoritma optimizasyonu, model sıkıştırma, veri ön işleme ile donanım hızlandırma araştırmaları sürmektedir (Jevinger et al., 2024). Bu çalışmalar, ML sistemlerinin ölçeklenebilirliğini, verimliliğini ve sürdürülebilirliğini artırmayı hedeflemektedir.

Bilimsel araştırmada ML'nin rolü de büyüme-dir. Örneğin, Microsoft'un Christopher Bishop'a göre derin öğrenme ve büyük dil modelleri (özellikle GPT-4 gibi) bilimsel keşifleri hızlandırarak ilaç, enerji ve iklim konularında dönüştürücü sonuçlar üretmektedir (Bishop, 2025). Coğrafi verilerle çalışan fizik tabanlı tahmin modellerine entegre edilen yapay zeka, hava ve iklim bilimlerinde de belirgin ilerlemelere öncülük etmektedir (Financial Times, 2024).

Teknik olarak, ML modelleri; örneğin VisionTransformers (ViT), Infini-attention gibi uzun bağlamlı LLM mekanizmaları ve sıfır-örnek sınıflandırma zero-shot learning (ZSL), yeni mimari ve algoritmik gelişmelerle donatılmaktadır (Stojnic et al., 2024; Munkhdalai et al., 2024). Bu gelişmeler, özellikle yüksek bağlamlı metin, görüntü-işleme ve sıfır-etiketli (zero-shot) görevlerde performansı önemli ölçüde artırmıştır.

Uygulamaya dönük bakıldığında, makine öğrenmesi birçok farklı alanda kullanılmaktadır. Örnek alanlar aşağıda sıralanmıştır.

- Ulaşım sistemlerinde (hava, kara, deniz), enerji yönetimi ve bakım planlamasında aktif olarak kullanılmakta; bu alanda risk tahmini, optimizasyon ve önleyici bakım uygulamaları yapılmaktadır (Zhang et al., 2025).
- Malzeme bilimi alanında, yeni materyallerin keşfi, özellik tahmini ve süreç optimizasyonu ML ile hızlandırılmıştır (Gholami& Al Abdwani, 2025).
- Kablosuz iletişim sistemlerinde (5G/6G), federatedlearning, multi-ajent pekiştirmeli öğrenme gibi yöntemlerle ağ optimizasyonu ve güvenlik sağlanmaktadır (Tran et al., 2025).

### **1.1. Amaç ve Kapsam**

Bu çalışma, çimento esaslı lifli kompozitlerin performansını iyileştirmeye yönelik olarak, farklı üretim parametrelerinin mekanik ve fiziksel özellikler üzerindeki etkilerinin analiz edilmesi ve bu ilişkilerin makine öğrenmesiyle modellenmesi amaçlanmaktadır. Araştırma kapsamında; lif türü, uçucu kül (UK) oranı, nano boyutlu mineral katkıları, yüksek sıcaklık etkisi ve sülfat

maruziyeti gibi çok sayıda değişken, deneysel yöntemlerle test edilerek veri seti oluşturulmuştur. Elde edilen bu çok değişkenli veri seti, Grup Metoduna Dayalı Veri İşleme (GMDH) ve Aşırı Öğrenme Makineleri (ELM) gibi denetimli makine öğrenmesi algoritmalarıyla analiz edilmiştir. Bu yöntemler sayesinde, geleneksel istatistiksel analizlerin ötesine geçilerek, karmaşık ve doğrusal olmayan ilişkilerin modellenmesi ve yüksek doğrulukla tahmin edilmesi hedeflenmiştir. Böylece hem mühendislik karar süreçlerinde daha hızlı ve güvenilir sonuçlara ulaşmak, hem de deneysel çalışmalarda zaman ve kaynak tasarrufu sağlamak mümkün olmuştur. Bu yönüyle çalışma, inşaat mühendisliği ve malzeme bilimi alanlarında makine öğrenmesi uygulamalarının potansiyelini ortaya koymakta ve multidisipliner yaklaşımlar için örnek teşkil etmektedir.

**Makine Öğrenmesi ile Analiz:** Mevcut çalışmada Kaya'nın (2024) doktora tezinden elde edilen deneysel sonuçlar, makine öğrenmesi yöntemleri kullanılarak işlenmiştir. Bu çalışmada kullanılan yöntemler, karmaşık veri setlerinden anlamlı bilgiler çıkarmış ve malzeme özelliklerini tahmin etmiştir.

Makine öğrenmesi yöntemlerinde eğitim seti ve test seti için veriler toplamda 24 farklı karışım test

sonuçlarından elde edilmiştir. Elde edilen karışımlar, çimento esaslı lifli kompozitlerin geniş bir yelpazesini temsil etmektedir ve farklı uygulamalara uygun potansiyel özelliklere sahiptir. Çalışmanın değerlendirme aşamasında, 7, 28 ve 90 günlük kür yaşı süreleri belirlenmiştir. Bu kür yaşları, çimento esaslı malzemelerin olgunlaşma sürecinde kritik aşamaları temsil etmektedir. Bu sürelerde, malzemenin mekanik ve fiziksel özellikleri önemli ölçüde değişebilir, bu da yapı malzemelerinin uzun vadeli dayanıklılığını etkileyebilir. Bu nedenle, belirlenen kür yaşı sürelerinde numunelerin performansının değerlendirilmesi kritik öneme sahiptir. Numunelerin değerlendirme sürecinde, öncelikle belirli bir sıcaklıkta (500 derece) tabii tutulmuş, ardından belirlenen kür yaşı sürelerinde sülfatlı suda bekletilmiştir. Bu işlemler, çimento esaslı lifli kompozitlerin gerçek dünya koşullarında maruz kalabileceği çevresel etkilere benzer koşullarda test edilmesini sağlamıştır.

## 2. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, verilerden öğrenme yeteneğine sahip algoritmaların geliştirilmesi ve uygulanmasını kapsayan bir yapay zekâ dalıdır. Bu yöntem, sistemlerin verileri kullanarak belirli görevlerde performanslarını zamanla arttırmalarını sağlar. Bu bağlamda, Veri İşleme Grup Yöntemi (GMDH) ve Aşırı Öğrenme Makineleri (ELM) gibi yöntemler makine öğrenmesinin önemli yöntemlerindendir. Yapılan çalışmada ilgili iki yöntem kullanılmıştır.

### 2.1. Veri işleme grup yöntemi (Groupmethod of datahandling (GMDH))

GMDH modelinin amacı gizli katmandaki nöronlar arasındaki fonksiyonel yapıyı tanımlamaktır. GMDH algoritması, kademeli olarak karmaşık modellerin, bir dizi çoklu-giriş-tek-çıkış veri çiftleri üzerindeki performanslarının değerlendirilmesine dayanarak oluşturulduğu, kendi kendini organize eden bir yaklaşımdır. GMDH polinomiyal sinir ağları olarak da bilinen bir ağ modelidir. GMDH algoritması, değişkenler arasında bilinmeyen ilişkilere sahip kara kutu

modellerinin tahmin edilmesine yönelik bir indüktif kendini organize etme yaklaşımına dayanmaktadır (MathewNkurlu ve Ark., 2020; Panahi ve Ark., 2022).

GMDH ağı, 1960'larda Ivakhnenko tarafından önerilen, sezgisel kendi kendini organize etme ilkesine dayanan bir yapay sinir ağı modelidir. GMDH, polinomiyal sinir ağı modelleri sınıfına ait bir mimaridir (Farlow, 1981). GMDH kendi kendini organize eden bir yapıdadır. GMDH ağı esnek bir yapıya sahiptir. Bu yüzden genetik, evrimsel, parçacık sürü optimizasyon gibi sezgisel yöntemler ile melez yöntemler geliştirilmiştir. Yapılan çalışmalarda hibrit modellerin mühendislik problemlerin çözümünde başarılı oldukları görülmüştür. GMDH modelin temel mantığı karesel nöronlar kullanılan ileri beslemeli sinir ağlarında ağırlıkları regresyon tabanlı elde edilmesini sağlayan analitik bir fonksiyon tanımlamaktır. GMDH ağında bir katmandaki nöronlar kuadratik ve trikuadratik polinom yoluyla bir sonraki katmana bağlanarak sonraki katmanda yeni nöronlar oluşturulmaktadır. GMDH ağın topolojisi her katmandaki en iyi nodların hangileri olduğu önceden belirlenmiş bir kritere göre katman katman budama işlemi gerçekleştirilerek belirlenir. Bu modelde giriş değişkenleri çıkış değişkene haritalanır. Bu haritalamada amaç, verilen

$X = (x_1, x_2, x_3, \dots, x_n)$  girdi vektörünü kullanarak  $\hat{y}$  çıktı değerini tahmin edecek  $f$  fonksiyonunu oluşturmaktadır. Bu fonksiyon ile gerçek  $y$  çıktı değerlerine mümkün olduğunda yakın değerler tahmin edilmektedir. Çoklu giriş tekli çıkış veriler göz önüne alındığında (Mulashani ve Ark., 2022);

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, 3, \dots, M) \quad (2.1)$$

Şimdi verilen  $X = (x_1, x_2, x_3, \dots, x_n)$  girdi vektörünü kullanarak  $\hat{y}$  çıktı değerini tahmin etmek mümkün olacaktır. Tahmin denklemi aşağıdaki gibi yazılabilir.

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, 3, \dots, M) \quad (2.2)$$

Bu problemi çözmek için, GMDH çıktı ve girdi değişkenleri arasındaki genel ilişkiyi, bir referans olarak da adlandırılan matematiksel bir tanım biçiminde oluşturur. Amaç gerçek çıktı değerleri ile tahmin edilen değerler arasındaki farkın minimum olmasıdır (Amiri ve Soleimani, 2021).

$$\sum_{i=1}^M [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow Minimum \quad (2.3)$$

Giriş ve çıkış değişkenleri arasındaki genel bağlantı, aşağıdaki gibi bir seri olan Volterra fonksiyonunun karmaşık bir ayırık biçimi ile ifade edilebilir:

$$y = w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n w_{ijk} x_i x_j x_k + \dots, \quad (2.4)$$

Denklem 2.4, Kolmogorov-Gabor polinomu olarak bilinir. Bu çalışmada, şu şekilde yazılan GMDH ağının ikinci dereceden polinomu kullanılmıştır. Bu fonksiyon aşağıdaki gibi yazılmaktadır. GMDH, herhangi bir modeli sentezlemek için yinelemeli bir polinom regresyon prosedürü kullanır. Polinom regresyon denklemleri, etkili prosedürleri kullanarak yüksek mertebeden bir polinom modeli üretebilmektedir.


$$\text{Quadratic: } \hat{y} = G(x_i, x_j) = w_0 + w_1 x_i + w_2 x_j + w_3 x_i x_j + w_4 x_i^2 + w_5 x_j^2 \quad (2.5)$$

Oluşturulan ağın girdi değişkenleri ile çıktı değişken arasındaki matematiksel ilişki Denklem 2.4 ile oluşturulmaktadır. Denklem 2.5'deki ağırlıkları regresyon yöntemleri ile hesaplanmaktadır. Böylece  $x_i$  ve  $x_j$  giriş çiftleri için gerçek  $y$  ve tahmin edilen  $\hat{y}$  arasındaki fark



minimize edilmiş olur. Ağırlıklar en küçük kareler yöntemi ile elde edilir. Bu şekilde, kuadratik fonksiyonun ( $G_i$ : Giriş fonksiyonu) ağırlık katsayıları, çıktıyı tüm giriş-çıkış veri çiftleri kümesine optimal olarak uyacak şekilde elde edilir. GMDH modelinde eğitim süreci tüm girdi değişkenlerini (bir kerede iki değişken) alarak ikinci dereceden polinom denklemini (Denklem 2.5) oluşturup çıkış değişkenini en iyi şekilde tahmin edilmeye çalışılmaktadır. Her giriş vektörü çifti (öznitelikler) bir ikinci kuadratik regresyon polinom denklemi oluşturacaktır. İlk katman için  $L$  ( $L = m(m-1) / 2$ ) kadar regresyon polinom denklemi elde edilir. Örneğin giriş değişken sayısı  $m=4$  ise 1.katmanda  $L=6$  adet regresyon polinom denklemi elde edilecektir. Bu denklemler kullanılarak 1.katmandan sonraki katman için yeni değişkenler elde edilmektedir. Bu şekilde her katmandaki diğer katmanlar için yeni değişkenler elde edilmektedir. Dolayısıyla giriş değişkenlerinden çıkış değişkenini en iyi şekilde açıklayan yeni değişkenler üretilmektedir. Geçerli katmandaki minimum hata değeri bir önceki katmandaki hata değerinden büyük ise modeli karmaşık hale getirmektedir. Diğer bir deyişle bir katmandaki hata değeri bir önceki katmandaki hata değerinden küçük

olması beklenir. GMDH modelinin mimari yapısı görsel olarak Şekil 2.1’de verilmiştir.



Şekil 2.1. GMDH ağı mimari yapısı.

Her giriş veri çifti bir regresyon denklemi oluşturur. Regresyon denklemlerinin çıktıları, bir sonraki katmana yeni girdiler oluşturur. Son çıktı, tüm katmanlardan seçilen regresyon denklemlerinden oluşur.

$$E = \frac{\sum_{i=1}^M (y_i - G_i(x_i, x_j))^2}{M} \rightarrow \text{minimum} \quad (2.6)$$

Bağımsız y değişkenini en küçük kareler yöntemi ile en iyi tahmin edecek Eşitlik 4'teki polinomiyal regresyon denklemini oluşturmak için n adet girdi değişkenlerin olası tüm ikili kombinasyonları kullanılarak GMDH ağı oluşturulur. Gözlenen  $\{(y_i, x_{ip}, x_{iq}), (i = 1, 2, 3, \dots, M)\}$  örneklerden GMDH ağın ilk katmanını  $n(n-1)/2$

1)/2 adet kuadratik polinom nöronları kullanılarak oluşturulur.

$$\begin{bmatrix} x_{1p} & x_{1q} & y_1 \\ x_{2p} & x_{2q} & y_2 \\ x_{mp} & x_{mq} & y_m \end{bmatrix} \quad (2.7)$$

Yukarıdaki belirtilen giriş-çıkış değişkenlerini kullanarak Denklem2.5'deki matris formu aşağıdaki gibi yazılabilir.

$$AW = Y \quad (2.8)$$

Burada  $W$ , tahmin edilecek ağırlık vektörüdür. Kuadratikpolinomun bilinmeyen ağırlık katsayılarının vektörüdür (Zhang ve Zhang, 2023).

$$W = \{w_0, w_1, w_2, w_3, w_4, w_5\}^T \quad (2.9)$$

$Y$  ise çıkış değerlerin vektörünü belirtir.

$$Y = \{y_1, y_2, y_3, y_4, y_5, \dots y_M\}^T \quad (2.10)$$

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ 1 & x_{mp} & x_{mq} & x_{mp}x_{mq} & x_{mp}^2 & x_{mq}^2 \end{bmatrix} \quad (2.11)$$


Ağırlıklar çoklu regresyon denklemi kullanılarak matris formunda aşağıdaki gibi çözülür.

$$W = (A^T A)^{-1} A^T Y \quad (2.12)$$

Burada A giriş matrisi ve Y ise çıkış vektörünü belirtir.

## 2.2. Aşırı öğrenme makinesi (Extreme learningmachine (ELM))

ELM, giriş ağırlıkları rastgele çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir yapay sinir ağı (YSA) modelidir. ELM'de gizli katmanda sigmoidal, sinüs, Gaussian ve hard-limitin gibi aktivasyon fonksiyonları yanında YSA'dan farklı olarak türevlenemeyen veya kesikli aktivasyon fonksiyonları da kullanılabilir (Ding ve Ark., 2014; Tang ve Ark., 2015).



Şekil 2.2. İleri beslemeli yapay sinir ağı.

Geleneksel ileri beslemeli yapay sinir ağların performansı momentum, öğrenme oranı vb. bazı parametrelere bağlıdır. Bu tür ağlarda ağırlıklar ve eşik değerler gibi parametrelerin gradyen temelli öğrenme algoritmaları ile güncellenmesi gerekir. Ancak iyi performansın sağlanması için öğrenme süreci hem zaman almakta hem de hata yerel bir noktaya takılabilmektedir. Momentum değerinin değiştirilmesi belki hatanın yerel bir noktaya takılmasını engelleyebilir ancak öğrenme sürecinin uzun sürmesini etkilemeyecektir. ELM de giriş ağırlıkları ve eşik değerleri rastgele üretilmekte ancak çıkış ağırlıkları analitik olarak elde edilmektedir (Wang ve Ark., 2022). ELM ağı tek gizli katmanlı ileri beslemeli bir

YSA modelinin özelleştirilmiş versiyonudur. Şekil 2.2'de tek gizli katmanlı ileri beslemeli bir YSA'na ait şekil gösterilmiştir.

Burada  $W_i = (W_{i1}, W_{i2} \dots W_{in})$  giriş katmandaki  $\beta_i = (\beta_{i1}, \beta_{i2} \dots \beta_{im})$  çıkış katmandaki ağırlıkları,  $b_i$  gizli katman nöronların eşik değerlerini ve  $O_k$  çıkış değerlerini belirtir.  $g(\cdot)$  aktivasyon fonksiyonudur (Liu ve Wang, 2010).  $N$  giriş özellikli bir ağda amaç hatanın  $\sum_{k=1}^N (o_k - Y_k) = 0$  olması veya  $\min \|\sum_{k=1}^N (o_k - Y_k)^2\|$  hatanın elde edilmesidir. Dolayısıyla Deklem 2.13 aşağıdaki gibi yazılabilir (Zong ve Ark., 2013).

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = Y_k, \quad k = 1, 2 \dots \dots N \quad (2.13)$$

Yukarıdaki eşitlikte,

$$H\beta = Y \quad (2.14)$$

yazılabilir (Zong ve Ark., 2013). Burada

$$H(W_1, \dots W_M; b_1, \dots b_M; X_1, \dots X_N) = \begin{bmatrix} g(W_1 X_1 + b_1) & \dots & g(W_M X_1 + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \dots & g(W_M X_N + b_M) \end{bmatrix} \quad (2.15)$$

ve

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m} \text{ ve } Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times m} \quad (2.16)$$

şeklinde ifade edilebilir. Burada  $H$  gizli katman çıkış matrisidir. Geleneksel ileri beslemeli bir YSA da ağırlık eğitilmesi, ELM 'de  $H\beta = Y$  doğrusal denklemde en küçük kareler çözümünün aranmasıdır. ELM algoritması üç adımda aşağıdaki gibi özetlenebilir (Zong ve Ark., 2013).

1. **Aşama:**  $W_i = (W_{i1}, W_{i2} \dots W_{in})$  giriş ağırlıkları ve gizli katman  $b_i$  eşik değerleri rastgele üretilir.
2. **Aşama:**  $H$  gizli katman çıkışı hesaplanır.
3. **Aşama:**  $\hat{\beta}$  çıkış ağırlıkları  $\hat{\beta} = H^+Y$  göre hesaplanır.  $Y$  karar özelliğidir.

**Performans Ölçütleri:** Bu çalışmada GMDH ve ELM modellerinin performanslarını test etmek için ortalama kare hatası (MSE), hataların ortalama kare kökü ve korelasyon katsayısı (R) gibi istatistiksel ölçütler kullanılmıştır. Bu ölçütler aşağıdaki eşitlikler ile tanımlanırlar (Chicco ve Ark., 2021).

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2 \quad (2.17)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2} \quad (2.18)$$

$$R = \sqrt{\frac{\sum_{i=1}^N (Y_i - \bar{Y})^2 - \sum_{i=1}^N ((\hat{Y}_i - Y_i)^2)}{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (2.19)$$

Burada  $Y_i$  basınç dayanımı, eğilme dayanımı ve UPV parametrelerin gerçek değerleridir.  $\bar{Y}$  ise bu parametrelerin ortalama değerlerini,  $\hat{Y}_i$  tahmin edilen basınç dayanımı, eğilme dayanımı ve UPV parametre değerlerini, N toplam gözlem sayısı belirtir. RMSE, MSE pozitif değerler olup bu istatistiki ölçütlerin küçük olması tercih edilir. Sıfıra yakın değerler modellerin optimum basınç dayanımı, eğilme dayanımı ve UPV parametrelerinin gerçeğe yakın tahmin edildiğini belirtir. R ölçütü ise basınç dayanımı, eğilme dayanımı ve UPV parametre değerleri ile modellerin bu parametreler için tahmin ettiği değerler arasındaki ilişkiyi belirtir. Modellerin başarısı için R'nin 1 yakın olması beklenir.



### 3. VERİ SETİNİN OLUŞTURLUMASI

Makine öğrenmesi yöntemlerinde senaryolar için veri girişinde kullanılan çimento, uçucu kül, agrega, su, çelik lif, polipropilen, nano kalsit, uçucu kül bağlayıcı oranı, sıcaklık derecesi, sülfat etkisi miktarları, karışım bileşenleri Tablo 3.1’de verilmiştir.

|    |                | PC  | UK  | Agrega (A) | Su  | Lif |     | NC | UK/B | Su/B | A/B  |
|----|----------------|-----|-----|------------|-----|-----|-----|----|------|------|------|
|    |                |     |     |            |     | BS  | PP  |    |      |      |      |
| 1  | BS_FA0_0       | 915 |     | 1051       | 290 | 117 |     |    | 0    | 0.32 | 1.15 |
| 2  | BS_FA0_200     | 915 |     | 1051       | 290 | 117 |     |    | 0    | 0.32 | 1.15 |
| 3  | BS_FA0_500     | 915 |     | 1051       | 290 | 117 |     |    | 0    | 0.32 | 1.15 |
| 4  | BS_FA30_0      | 630 | 273 | 1035       | 293 | 117 |     |    | 0.3  | 0.32 | 1.15 |
| 5  | BS_FA30_200    | 630 | 273 | 1035       | 293 | 117 |     |    | 0.3  | 0.32 | 1.15 |
| 6  | BS_FA30_500    | 630 | 273 | 1035       | 293 | 117 |     |    | 0.3  | 0.32 | 1.15 |
| 7  | H_FA0_0        | 915 |     | 1051       | 290 | 94  | 2.7 |    | 0    | 0.32 | 1.15 |
| 8  | H_FA0_200      | 915 |     | 1051       | 290 | 94  | 2.7 |    | 0    | 0.32 | 1.15 |
| 9  | H_FA0_500      | 915 |     | 1051       | 290 | 94  | 2.7 |    | 0    | 0.32 | 1.15 |
| 10 | H_FA30_0       | 633 | 271 | 1041       | 290 | 94  | 2.7 |    | 0.3  | 0.32 | 1.15 |
| 11 | H_FA30_200     | 633 | 271 | 1041       | 290 | 94  | 2.7 |    | 0.3  | 0.32 | 1.15 |
| 12 | H_FA30_500     | 633 | 271 | 1041       | 290 | 94  | 2.7 |    | 0.3  | 0.32 | 1.15 |
| 13 | BS_FA0_NC_0    | 880 |     | 1013       | 299 | 117 |     | 44 | 0    | 0.32 | 1.15 |
| 14 | BS_FA0_NC_200  | 880 |     | 1013       | 299 | 117 |     | 44 | 0    | 0.32 | 1.15 |
| 15 | BS_FA0_NC_500  | 880 |     | 1013       | 299 | 117 |     | 44 | 0    | 0.32 | 1.15 |
| 16 | BS_FA30_NC_0   | 665 | 216 | 1015       | 292 | 117 |     | 44 | 0.3  | 0.32 | 1.15 |
| 17 | BS_FA30_NC_200 | 665 | 216 | 1015       | 292 | 117 |     | 44 | 0.3  | 0.32 | 1.15 |
| 18 | BS_FA30_NC_500 | 665 | 216 | 1015       | 292 | 117 |     | 44 | 0.3  | 0.32 | 1.15 |
| 19 | H_FA0_NC_0     | 880 |     | 1013       | 299 | 94  | 2.7 | 44 | 0    | 0.32 | 1.15 |
| 20 | H_FA0_NC_200   | 880 |     | 1013       | 299 | 94  | 2.7 | 44 | 0    | 0.32 | 1.15 |
| 21 | H_FA0_NC_500   | 880 |     | 1013       | 299 | 94  | 2.7 | 44 | 0    | 0.32 | 1.15 |
| 22 | H_FA30_NC_0    | 665 | 216 | 1016       | 292 | 94  | 2.7 | 44 | 0.3  | 0.32 | 1.15 |
| 23 | H_FA30_NC_200  | 665 | 216 | 1016       | 292 | 94  | 2.7 | 44 | 0.3  | 0.32 | 1.15 |
| 24 | H_FA30_NC_500  | 665 | 216 | 1016       | 292 | 94  | 2.7 | 44 | 0.3  | 0.32 | 1.15 |


Tablo 3.1. Karışım Bileşenleri kg/m<sup>3</sup>

#### 3.1. Ham verilerin işlenmesi ve makine öğrenmesi yöntemleri


Bu çalışmada Kaya’nın (2024) “Yüksek Sıcaklık ve Sülfat Hücumuna Maruz Kalmış Çimento Esaslı Lifli

Kompozitlerin Mühendislik Özelliklerinin Makine Öğrenmesi Yöntemleriyle İncelenmesi” adlı doktora tezinden elde edilen veriler kullanılmıştır. Bu bağlamda elde edilen basınç dayanımı, eğilme dayanımı ve ultrasesdalgası hızı veri sonuçlarının değerlendirilmesi için Grup Yöntemi Veri İşleme (Group Method of Data Handling (GMDH)) modeli ve Aşırı Öğrenme Makinesi (Extreme Learning Machine (ELM)) modeli kullanılmış ve her iki model ile elde edilen sonuçlar birbiriyle kıyaslanmıştır.


Tablo 3.1’deki karışım parametreleri baz alınarak tasarlanmış çimento esaslı lifli kompozitler 7, 28 ve 90 günlük kür yaşları geldiğinde 3 saat boyunca 200<sup>0</sup>C ve 500<sup>0</sup>C yüksek sıcaklığa maruz bırakılmış ve soğutma işlemi sonrasında her bir numunenin basınç dayanımı testi yapılmış ve değerlerin ortalaması alınmıştır. 7, 28 ve 90 günlük kür yaşları için elde edilen deneysel sonuçların grafikleri için sırasıyla Şekil 3.1, Şekil 3.2 ve Şekil 3.3’de verilmiştir.



Şekil 3.1. 7 günlük kür yaşı basınç dayanımı değerleri.




Şekil 3.2. 28 günlük kür yaşı basınç dayanımı değerleri.




Şekil 3.3. 90 günlük kür yaşı basınç dayanımı değerleri.


7, 28 ve 90 günlük kür yaşları için yüksek sıcaklık sonrası numunelerde ölçülen UPV değerleri sırasıyla Şekil 3.4, Şekil 3.5 ve Şekil 3.6’da verilmiştir.



Şekil 3.4. 7 günlük kür yaşı UPV değerleri.




Şekil 3.5. 28 günlük kür yaşı UPV değerleri




Şekil 3.6. 90 günlük kür yaşı UPV değerleri.

Çimento esaslı lifli kompozitlerin yüksek sıcaklıklara maruz kaldıklarında eğilme dayanımlarındaki değişiklikler incelenip, elde edilen verilen 7, 28 ve 90


günlük kür yaşları için sırasıyla Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da verilmiştir.



Şekil 3.7. 7 günlük kür yaşı eğilme dayanımı değerleri.




Şekil 3.8. 28 günlük kür yaşı eğilme dayanımı değerleri.




Şekil 3.9. 90 günlük kür yaşı eğilme dayanımı değerleri.


Tasarlanmış çimento esaslı lifli kompozitlerin 7, 28 ve 90 günlük kür yaşları sonrası yüksek sıcaklık uygulamasından sonra üç günlük sülfat hücumu sonrası test edilen munelerin basınç dayanımları ortalaması Şekil 3.10, Şekil 3.11 ve Şekil 3.12’de verilmiştir.



Şekil 3.10. 7 günlük kür yaşı basınç dayanımı değerleri.




Şekil 3.11. 28 günlük kür yaşı basınç dayanımı değerleri.




Şekil 3.12. 90 günlük kür yaşı basınç dayanımı değerleri.

7, 28 ve 90 günlük kür yaşları için üç günlük sülfat etkisi sonrası numunelerde ölçülen UPV değerleri sırasıyla Şekil 3.13, Şekil 3.14 ve Şekil 3.15’de verilmiştir.






Şekil 3.13. 7 günlük kür yaşı UPV değerleri.




Şekil 3.14. 28 Günlük Kür Yaşı UPV Değerleri




Şekil 3.15. 90 günlük kür yaşı UPV değerleri.


Sülfat etkisi sonrası 40x40x160 mm boyutlarında üretilen kiriş numuneleri üç noktalı eğilme dayanımı testine tabii tutulmuştur. Test sonrası elde edilen veriler 7, 28 ve 90 günlük kür yaşları için değerlendirilmiş olup, deney sonuçları Şekil 3.16, Şekil 3.17 ve Şekil 3.18’de verilmiştir.



Şekil 3.16. 7 günlük kür yaşı eğilme dayanımı değerleri.



**Şekil 3.17.** 28 günlük kür yaşı eğilme dayanımı değerleri.



**Şekil 3.18.** 90 günlük kür yaşı eğilme dayanımı değerleri.

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışma kapsamında elde edilen verilen değerlendirilmesi ve işlenmesi adına Araştırma Sonuçları ve Tartışma bölümünde farklı kür yaşları ve karışım parametrelerine bağlı olarak elde edilen tüm deneysel veriler makine öğrenmesi yöntemleriyle işlenmiştir.

### 4.1. Makine Öğrenmesi Yöntemleri

Bu çalışmada, beton performansını etkileyen çeşitli bileşenler ve koşullar kullanılarak makine öğrenmesi yöntemleriyle basınç dayanımı, eğilme dayanımı ve ultrasonik ses hızını (UPV) tahmin etmeye çalışılmıştır. Kullanılan bileşenler ve koşullar şunlardır: çimento, UK, agrega, su, çelik lif, polipropilen, NC, uçucu kül bağlayıcı oranı, sıcaklık derecesi, sülfat etkisi, kür yaşı(gün) ve UPV şahit değişkenleri. Bu çalışma, çeşitli senaryolar altında bu bileşenlerin ve koşulların etkilerini inceleyerek tahmin modelleri geliştirmeyi amaçlamaktadır. Çalışmadaki senaryolar Tablo 4.1'de sunulmuştur.

1. ve 2. senaryolarda, aynı değişkenler kullanılarak sırasıyla basınç dayanımı ve eğilme dayanımı tahmin edilmiştir. Üçüncü senaryoda ise diğer giriş

değişkenlerine ek olarak UPV şahit değişkeni de kullanılarak UPV değeri tahmin edilmiştir. Makine öğrenmesi yöntemleri olarak GMDH ve ELM modelleri tercih edilmiştir. GMDH, 1968 yılında Alexey Ivakhnenko tarafından geliştirilmiş bir veri madenciliği ve modelleme tekniğidir. Bu yöntem, karmaşık sistemleri modellemek için kullanılır ve çok katmanlı algoritmalarıyla bilinmeyen ilişki ve desenleri keşfetmeyi amaçlar. GMDH, veri setinden en uygun modeli otomatik olarak seçmek için iteratif bir süreç kullanır. Bu süreçte, farklı model yapılarını deneyerek en iyi performansı gösteren modeli seçer. GMDH'nin temel avantajı, kullanıcı müdahalesine gerek kalmadan en uygun modeli belirleyebilmesidir. ELM, hızlı ve verimli bir öğrenme algoritması olup, tek gizli katmanlı ileri beslemeli sinir ağları (SLFNs) için kullanılır. Guang-Bin Huang tarafından 2004 yılında önerilen ELM, geleneksel sinir ağlarından farklı olarak, ağırlıkları rastgele atanmış ve yalnızca çıkış ağırlıklarını eğiten bir yapıya sahiptir. Bu yöntem, eğitim süresini büyük ölçüde azaltır ve yüksek genelleme performansı sunar. ELM, doğrusal olmayan aktivasyon fonksiyonları ve büyük veri setleri ile çalışabilir, bu da onu geniş bir uygulama yelpazesinde etkili kılar. Hem GMDH hem de ELM, modelleme ve veri analizi süreçlerinde önemli roller

oynar ve çeşitli alanlarda başarıyla uygulanmaktadır. Modellerin performansını değerlendirmek için MSE, RMSE ve R<sup>2</sup>metrikleri kullanılmıştır.

**Tablo 4.1.** Senaryolar.

| Senaryolar       | Giriş Değişkenler                                                                                                                                    | Çıkış Değişkeni |
|------------------|------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------|
| <b>Senaryo 1</b> | Çimento, Uçucu Kül, Agreg, Su, Çelik Lif, Polipropilen, Nano Kalsit, Uçucu Kül Bağlayıcı Oranı, Sıcaklık Derecesi, Sülfat Etkisi, Kür Yaşı           | Basınç Dayanımı |
| <b>Senaryo 2</b> | Çimento, Uçucu Kül, Agreg, Su, Çelik Lif, Polipropilen, Nano Kalsit, Uçucu Kül Bağlayıcı Oranı, Sıcaklık Derecesi, Sülfat Etkisi, Kür Yaşı           | Eğilme Dayanımı |
| <b>Senaryo 3</b> | Çimento, Uçucu Kül, Agreg, Su, Çelik Lif, Polipropilen, NanoKalsit, Uçucu Kül Bağlayıcı Oranı, Sıcaklık Derecesi, Sülfat Etkisi, Kür Yaşı, UPV Şahit | UPV             |

Çalışmada kullanılan veri seti toplamda 144 örnekten oluşmaktadır. Bu örneklerin %70'i (101 örnek) modelleri eğitmek için, %30'u (43 örnek) ise modelleri test etmek için kullanılmıştır. Tüm senaryolarda eğitim ve test örnekleri aynı şekilde kullanılmıştır. Bu düzenleme,

modellerin performansını karşılaştırmalı olarak değerlendirebilmek adına önemlidir.

Bu çalışma, beton performansının tahmin edilmesi sürecinde makine öğrenmesi yöntemlerinin etkinliğini ve uygulanabilirliğini göstermeyi amaçlamaktadır. Özellikle GMDH ve ELM modellerinin beton dayanımı ve UPV parametreleri üzerindeki performansları detaylı bir şekilde analiz edilmiştir.

#### 4.1.1. GMDH için eğitim veri seti

**GMDH modeli için sonuçlar:** Bu çalışma kapsamında, GMDH modeli kullanılarak, 101 örnek üzerinde model eğitimi gerçekleştirilmiş ve modelin performansı 43 test örneği üzerinde değerlendirilmiştir. Modelin başarımını değerlendirmek amacıyla MSE (MeanSquared), RMSE (RootMeanSquaredError) ve  $R^2$  (R-squared) metrikleri eğitim, test ve tüm veri setleri için ayrı ayrı hesaplanmıştır. Performans değerlendirme sonuçları Tablo 4.2'de sunulmuştur ve aşağıda detaylı olarak yorumlanmıştır.

- **Senaryo 1:** Eğitime ilişkin MSE değeri 9.9861, RMSE değeri 3.1601 ve  $R^2$  değeri 0.8392 olarak hesaplanmıştır. Bu sonuçlar, modelin eğitim sırasında nispeten düşük hata oranlarına sahip

olduğunu ve veri noktalarının %83.92'sinin model tarafından açıklanabildiğini göstermektedir.

- **Senaryo 2:** MSE 0.62607, RMSE 0.79125 ve  $R^2$  0.87157 değerlerine ulaşılmıştır. Burada, modelin daha yüksek bir doğruluk ve düşük hata ile çalıştığı görülmektedir.  $R^2$  değeri, modelin veri noktalarının %87.16'sını açıklayabildiğini göstermektedir.
- **Senaryo 3:** MSE 0.0059216, RMSE 0.076952 ve  $R^2$  0.92433 olarak belirlenmiştir. Bu değerler, modelin oldukça iyi performans gösterdiğini ve veri noktalarının %92.43'ünü açıklayabildiğini ortaya koymaktadır. Bu senaryoda en düşük hata oranlarına ulaşılmıştır.

#### 4.1.2. GMDH için test veri seti

- **Senaryo 1:** Test sonuçlarına göre, MSE 12.3623, RMSE 3.516 ve  $R^2$  0.83581 olarak belirlenmiştir. Eğitim sonuçlarına kıyasla test verisinde hata oranları biraz daha yüksek olmasına rağmen, modelin genelleme kapasitesinin oldukça iyi olduğu söylenebilir.  $R^2$  değeri, modelin veri noktalarının %83.58'ini açıklayabildiğini göstermektedir.



- **Senaryo 2:** MSE 0.89843, RMSE 0.94786 ve  $R^2$  0.83714 değerleriyle test edilmiştir. Burada, eğitim setine kıyasla biraz daha yüksek hata oranları ve biraz daha düşük bir açıklama oranı (%83.71) gözlemlenmiştir.
- **Senaryo 3:** MSE 0.01584, RMSE 0.12586 ve  $R^2$  0.8726 olarak hesaplanmıştır. Eğitim setine göre hata oranları biraz daha yüksek olmasına rağmen, modelin performansı hala oldukça iyi ve veri noktalarının %87.26'sını açıklayabiliyor.

#### 4.1.3. GMDH için tüm veri seti

- **Senaryo 1:** Tüm veri seti üzerinde hesaplanan MSE 10.6957, RMSE 3.2704 ve  $R^2$  0.83223 değerleri, modelin genel olarak iyi bir performans gösterdiğini ve veri noktalarının %83.22'sini açıklayabildiğini göstermektedir.
- **Senaryo 2:** MSE 0.7074, RMSE 0.84107 ve  $R^2$  0.85876 olarak belirlenmiştir. Bu sonuçlar, modelin düşük hata oranlarıyla ve yüksek doğrulukla çalıştığını göstermektedir.  $R^2$  değeri, modelin veri noktalarının %85.88'ini açıklayabildiğini ortaya koymaktadır.

- **Senaryo 3:** MSE 0.0088832, RMSE 0.094251 ve  $R^2$  0.90489 olarak hesaplanmıştır. Bu değerler, modelin tüm veri seti üzerinde çok yüksek bir performans sergilediğini ve veri noktalarının %90.49'unu açıklayabildiğini göstermektedir.


GMDH modeli, tüm senaryolarda hem eğitim hem de test verileri üzerinde genel olarak iyi performans göstermiştir. Eğitim ve test setlerindeki MSE ve RMSE değerleri, modelin hata oranlarının düşük olduğunu ve iyi bir genelleme kapasitesine sahip olduğunu göstermektedir.  $R^2$  değerlerinin yüksek olması, modelin bağımlı değişkenin varyansının büyük bir kısmını açıklayabildiğini göstermektedir. Özellikle üçüncü senaryo, en düşük hata oranları ve en yüksek  $R^2$  değerleri ile dikkat çekmektedir. Bu, modelin UPV tahminlerinde çok yüksek doğrulukta çalıştığını ortaya koymaktadır.


Sonuç olarak, bu çalışmada GMDH modelinin kullanılan veri setleri ve senaryolar altında başarılı bir performans sergilediği ve güvenilir tahminler üretebildiği söylenebilir. Bu sonuçlar, GMDH modelinin beton dayanımı ve ilgili parametrelerin tahmin edilmesinde etkin bir araç olduğunu göstermektedir.

**Tablo 4.2.** GMDH performans deęerleri.


| Veri Seti     | Senaryo   | MSE       | RMSE     | R <sup>2</sup> |
|---------------|-----------|-----------|----------|----------------|
| <b>Eđitim</b> | Senaryo 1 | 9.9861    | 3.1601   | 0.8392         |
|               | Senaryo 2 | 0.62607   | 0.79125  | 0.87157        |
|               | Senaryo 3 | 0.0059216 | 0.076952 | 0.92433        |
| <b>Test</b>   | Senaryo 1 | 12.3623   | 3.516    | 0.83581        |
|               | Senaryo 2 | 0.89843   | 0.94786  | 0.83714        |
|               | Senaryo 3 | 0.01584   | 0.12586  | 0.8726         |
| <b>Tümü</b>   | Senaryo 1 | 10.6957   | 3.2704   | 0.83223        |
|               | Senaryo 2 | 0.7074    | 0.84107  | 0.85876        |
|               | Senaryo 3 | 0.0088832 | 0.094251 | 0.90489        |

Eđitim, test ve tüm veri setine ait hata ve performans grafikleri ařađıdaki řekillerde verilmiřtir. Senaryo 1 için;


**řekil 4.1.** Senaryo 1 için eđitim data.




Şekil 4.2. Senaryo 1 için test data.




Şekil 4.3. Senaryo 1 için tüm data

Şekil 4.4. Senaryo 1 için  $R^2$  değerleri.


Senaryo 2 için;




Şekil 4.5. Senaryo 2 için eğitim data.




Şekil 4.6. Senaryo 2 için test data.




Şekil 4.7. Senaryo 2 için tüm data.

Şekil 4.8. Senaryo 2 için  $R^2$  değerleri.


Senaryo 3 için;



Şekil 4.9. Senaryo 3 için eğitim data.




Şekil 4.10. Senaryo 3 için test data.



Şekil 4.11. Senaryo 3 için tüm data.





Şekil 4.12. Senaryo 3 için  $R^2$  değerleri.

#### 4.1.4. ELM için eğitim veri seti

**ELM modeli için sonuçlar:** Bu çalışma kapsamında, Aşırı Öğrenme Makinesi(ELM) modeli kullanılarak basınç dayanımı, eğilme dayanımı ve ultrasonik ses hızını (UPV) tahmin etmek amacıyla 101 örnek üzerinde model eğitimi gerçekleştirilmiş ve modelin performansı 43 test örneği üzerinde değerlendirilmiştir. Modelin başarımını değerlendirmek amacıyla MSE (MeanSquaredError), RMSE (RootMeanSquaredError) ve  $R^2$  (R-squared) metrikleri eğitim, test ve tüm veri setleri için ayrı ayrı

hesaplanmıştır. Performans değerlendirme sonuçları Tablo 4.3'te sunulmuştur ve aşağıda detaylı olarak yorumlanmıştır.

- **Senaryo 1:** Eğitime ilişkin MSE değeri 11.0675, RMSE değeri 3.3268 ve  $R^2$  değeri 0.80596 olarak hesaplanmıştır. Bu sonuçlar, ELM modelinin eğitim sırasında orta seviyede hata oranlarına sahip olduğunu ve veri noktalarının %80.60'ını açıklayabildiğini göstermektedir.
- **Senaryo 2:** MSE 0.66279, RMSE 0.81412 ve  $R^2$  0.8642 değerlerine ulaşılmıştır. Burada, modelin daha yüksek bir doğruluk ve nispeten düşük hata ile çalıştığı görülmektedir.  $R^2$  değeri, modelin veri noktalarının %86.42'sini açıklayabildiğini göstermektedir.
- **Senaryo 3:** MSE 0.013645, RMSE 0.11681 ve  $R^2$  0.84459 olarak belirlenmiştir. Bu değerler, modelin iyi performans gösterdiğini ve veri noktalarının %84.46'sını açıklayabildiğini ortaya koymaktadır. Ancak, bu senaryoda hata oranları diğer senaryolara göre biraz daha yüksektir.

#### 4.1.5.ELM için test veri seti

- **Senaryo 1:** Test sonuçlarına göre, MSE 9.0585, RMSE 3.0097 ve  $R^2$  0.90388 olarak belirlenmiştir. Eğitim sonuçlarına kıyasla test verisinde hata oranlarının daha düşük olması dikkat çekicidir ve modelin genelleme kapasitesinin oldukça yüksek olduğunu göstermektedir.  $R^2$  değeri, modelin veri noktalarının %90.39'unu açıklayabildiğini göstermektedir.
- **Senaryo 2:** MSE 0.67655, RMSE 0.82253 ve  $R^2$  0.87405 değerleriyle test edilmiştir. Burada, eğitim setine kıyasla benzer hata oranları ve biraz daha yüksek bir açıklama oranı (%87.41) gözlemlenmiştir.
- **Senaryo 3:** MSE 0.01477, RMSE 0.12153 ve  $R^2$  0.87009 olarak hesaplanmıştır. Eğitim setine göre hata oranları biraz daha yüksek olmasına rağmen, modelin performansı hala oldukça iyi ve veri noktalarının %87.01'ini açıklayabiliyor.

#### 4.1.6.ELM için tüm veri seti

- **Senaryo 1:** Tüm veri seti üzerinde hesaplanan MSE 10.4676, RMSE 3.2354 ve  $R^2$  0.83635 değerleri, modelin genel olarak iyi bir performans

gösterdiğini ve veri noktalarının %83.64'ünü açıklayabildiğini göstermektedir.

- **Senaryo 2:** MSE 0.6669, RMSE 0.81664 ve  $R^2$  0.86671 olarak belirlenmiştir. Bu sonuçlar, modelin düşük hata oranlarıyla ve yüksek doğrulukla çalıştığını göstermektedir.  $R^2$  değeri, modelin veri noktalarının %86.67'sini açıklayabildiğini ortaya koymaktadır.
- **Senaryo 3:** MSE 0.013981, RMSE 0.11824 ve  $R^2$  0.85366 olarak hesaplanmıştır. Bu değerler, modelin tüm veri seti üzerinde yüksek bir performans sergilediğini ve veri noktalarının %85.37'sini açıklayabildiğini göstermektedir.

ELM modeli, tüm senaryolarda hem eğitim hem de test verileri üzerinde genel olarak iyi performans göstermiştir. Eğitim ve test setlerindeki MSE ve RMSE değerleri, modelin hata oranlarının düşük olduğunu ve iyi bir genelleme kapasitesine sahip olduğunu göstermektedir.  $R^2$  değerlerinin yüksek olması, modelin bağımlı değişkenin varyansının büyük bir kısmını açıklayabildiğini göstermektedir. Özellikle ikinci senaryo hem eğitim hem de test setlerinde en düşük hata oranları ve en yüksek  $R^2$  değerleri ile dikkat çekmektedir, bu da


modelin eğilme dayanımı tahminlerinde yüksek doğrulukta çalıştığını ortaya koymaktadır.

Sonuç olarak, ELM modelinin bu çalışmada kullanılan veri setleri ve senaryolar altında başarılı bir performans sergilediği ve güvenilir tahminler üretebildiği söylenebilir. Bu sonuçlar, ELM modelinin beton dayanımı ve ilgili parametrelerin tahmin edilmesinde etkin bir araç olduğunu göstermektedir. ELM modelinin eğitim ve test performansları arasındaki tutarlılık, modelin genelleme yeteneğinin yüksek olduğunu ve gerçek dünya verileri üzerinde de etkili olabileceğini göstermektedir.


**Tablo 4.3.** ELM için performans değerleri.

| Veri Seti     | Senaryo   | MSE      | RMSE    | R <sup>2</sup> |
|---------------|-----------|----------|---------|----------------|
| <b>Eğitim</b> | Senaryo 1 | 11.0675  | 3.3268  | 0.80596        |
|               | Senaryo 2 | 0.66279  | 0.81412 | 0.8642         |
|               | Senaryo 3 | 0.013645 | 0.11681 | 0.84459        |
| <b>Test</b>   | Senaryo 1 | 9.0585   | 3.0097  | 0.90388        |
|               | Senaryo 2 | 0.67655  | 0.82253 | 0.87405        |
|               | Senaryo 3 | 0.01477  | 0.12153 | 0.87009        |
| <b>Tümü</b>   | Senaryo 1 | 10.4676  | 3.2354  | 0.83635        |
|               | Senaryo 2 | 0.6669   | 0.81664 | 0.86671        |
|               | Senaryo 3 | 0.013981 | 0.11824 | 0.85366        |


Eğitim, test ve tüm veri seti için elde edilen performans grafikleri aşağıda verilmiştir. Senaryo 1 için;




Şekil 4.13. Senaryo 1 için eğitim data.




Şekil 4.14. Senaryo 1 için test data.




Şekil 4.15. Senaryo 1 için tüm data.

Şekil 4.16. Senaryo 1 için  $R^2$  değerleri.

Senaryo 2 için;




Şekil 4.17. Senaryo 2 için eğitim data.




Şekil 4.18. Senaryo 2 için test data.







Şekil 4.19. Senaryo 2 için tüm data.

Şekil 4.20. Senaryo 2 için  $R^2$  değerleri.


Senaryo 3 için;




Şekil 4.21. Senaryo 3 için eğitim data.



Şekil 4.22. Senaryo 3 için test data.



Şekil 4.23. Senaryo 3 için tüm data.

Şekil 4.24. Senaryo 3 için  $R^2$  değerleri.

**Modellerin Karşılaştırılması:** ELM ve GMDH modelleri, beton dayanımı ve ilgili parametrelerin tahmininde kullanılan makine öğrenmesi yöntemleridir. Bu yöntemler, eğitim, test ve tüm veri setleri üzerinde performanslarını değerlendirmek için MSE (MeanSquaredError), RMSE (RootMeanSquaredError) ve  $R^2$  (R-squared) gibi metrikler kullanılarak karşılaştırılmıştır. Sonuçlar eğitim, test ve tüm data için Tablo 4.4, Tablo 4.5 ve Tablo 4.6’da verilmiştir.

#### 4.2. Eğitim Seti Karşılaştırması

Çalışmada GMDH ve ELM modellerinde oluşturulan eğitim setleri üç farklı senaryo altında analiz edilip, performansları karşılaştırılmıştır.

##### 4.2.1. Senaryo 1:

- **MSE:** GMDH (9.9861) < ELM (11.0675)
- **RMSE:** GMDH (3.1601) < ELM (3.3268)
- **$R^2$ :** GMDH (0.8392) > ELM (0.80596)

GMDH modeli, Senaryo 1’de ELM modeline göre daha düşük MSE ve RMSE değerleri ile daha iyi bir tahmin performansı göstermiştir. Ayrıca,  $R^2$  değeri açısından da GMDH, veri varyansının daha büyük bir kısmını açıklamıştır.

#### 4.2.2. Senaryo 2:

- **MSE:** GMDH (0.62607) < ELM (0.66279)
- **RMSE:** GMDH (0.79125) < ELM (0.81412)
- **R<sup>2</sup>:** GMDH (0.87157) > ELM (0.8642)

GMDH ve ELM modelleri Senaryo 2'de benzer performans sergilemiştir. MSE ve RMSE değerleri açısından GMDH biraz daha iyi performans gösterirken, R<sup>2</sup> değerleri benzerlik göstermektedir.

#### 4.2.3. Senaryo 3:

- **MSE:** GMDH (0.0059216) < ELM (0.013645)
- **RMSE:** GMDH (0.076952) < ELM (0.11681)
- **R<sup>2</sup>:** GMDH (0.92433) > ELM (0.84459)

Senaryo 3'te GMDH modeli hem MSE ve RMSE açısından hem de R<sup>2</sup> değeri açısından belirgin bir şekilde daha iyi performans göstermiştir. GMDH'nin düşük hata oranları ve yüksek R<sup>2</sup> değeri, modelin veri setindeki kompleks ilişkileri daha iyi açıkladığını göstermektedir.

### 4.3. Test Seti Karşılaştırması

Çalışmada GMDH ve ELM modellerinde oluşturulan test setleri üç farklı senaryo altında analiz edilip, performansları karşılaştırılmıştır.

#### Senaryo 1:

- **MSE:** GMDH (12.3623) > ELM (9.0585)
- **RMSE:** GMDH (3.516) > ELM (3.0097)
- **R<sup>2</sup>:** GMDH (0.83581) < ELM (0.90388)

ELM modeli, Senaryo 1'de hem MSE hem de RMSE açısından daha düşük hata oranları ve daha yüksek R<sup>2</sup> değeri ile daha iyi bir performans sergilemiştir. Bu, ELM'nin genelleme kabiliyetinin daha yüksek olduğunu göstermektedir.

#### Senaryo 2:

- **MSE:** GMDH (0.89843) > ELM (0.67655)
- **RMSE:** GMDH (0.94786) > ELM (0.82253)
- **R<sup>2</sup>:** GMDH (0.83714) < ELM (0.87405)

Senaryo 2'de de ELM modeli, GMDH'ye göre daha düşük hata oranları ve daha yüksek R<sup>2</sup> değeri ile daha iyi performans göstermiştir. Bu durum, ELM'nin veri setindeki ilişkileri daha iyi yakaladığını ve daha doğru tahminler yapabildiğini göstermektedir.

**Senaryo 3:**

- **MSE:** GMDH (0.01584) > ELM (0.01477)
- **RMSE:** GMDH (0.12586) > ELM (0.12153)
- **R<sup>2</sup>:** GMDH (0.8726) > ELM (0.87009)

Senaryo 3'te ise ELM ve GMDH modelleri benzer performans göstermiştir. MSE ve RMSE değerleri hemen hemen aynı iken, R<sup>2</sup> değerleri de benzerlik göstermektedir.

**4.4. Tüm Veri Seti Karşılaştırması**

Çalışmada GMDH ve ELM modellerinde oluşturulan tüm veri setleri üç farklı senaryo altında analiz edilip, performansları karşılaştırılmıştır.

**Senaryo 1:**

- **MSE:** GMDH (10.6957) > ELM (10.4676)
- **RMSE:** GMDH (3.2704) > ELM (3.2354)
- **R<sup>2</sup>:** GMDH (0.83223) < ELM (0.83635)

ELM modeli, tüm veri seti üzerinde MSE ve RMSE açısından hafif bir avantaja sahipken, R<sup>2</sup> değeri açısından da biraz daha yüksek performans sergilemiştir.

**Senaryo 2:**

- **MSE:** GMDH (0.7074) > ELM (0.6669)
- **RMSE:** GMDH (0.84107) > ELM (0.81664)
- **R<sup>2</sup>:** GMDH (0.85876) < ELM (0.86671)

Tüm veri seti için, ELM modeli GMDH'ye göre daha düşük hata oranları ve daha yüksek R<sup>2</sup> değeri ile daha iyi performans göstermiştir.

**Senaryo 3:**

- **MSE:** GMDH (0.0088832) < ELM (0.013981)
- **RMSE:** GMDH (0.094251) < ELM (0.11824)
- **R<sup>2</sup>:** GMDH (0.90489) > ELM (0.85366)

Senaryo 3'te ise GMDH modeli, tüm veri seti üzerinde daha düşük hata oranları ve daha yüksek R<sup>2</sup> değeri ile daha iyi bir performans göstermiştir.

ELM ve GMDH modelleri genel olarak benzer performans göstermektedir, ancak belirli senaryolarda farklı avantajlara sahiptirler. ELM modeli genellikle daha düşük hata oranları ve daha yüksek R<sup>2</sup> değerleri ile daha doğru tahminler yapabilmektedir. Özellikle genelleme yeteneği ve veri setindeki ilişkileri yakalama kabiliyeti açısından ELM, GMDH'ye göre daha etkin olabilir. Ancak, her iki modelin de belirli senaryolarda yüksek performans



sergilediği ve beton dayanımı tahmininde etkili olduğu görülmektedir. Öte yandan, mevcut çalışmada hem yüksek sıcaklık hem de sülfat etkisi gibi iki yıpratıcı etki ile sonuçlar değerlendirildiği için karışım parametrelerinin performansa olan katkıları dayanıklılık parametresine göre değişkenlik gösterdiğinden dolayı deneysel verilerin işlenmesinde elde edilen tahmin oranlarında düşüş elde edilmiştir. Hiçbir yıpratıcı etkinin olmadığı, yani numunelerin herhangi bir dayanıklılık problemine maruz bırakılmadığı koşulların incelendiği çalışmalarda tahmin oranları olabilecek en yüksek oranlarda elde edilmiştir. ELM ve GMDH modelleri için eğitim seti, test seti ve tüm data seti sonuçları sırasıyla Tablo 4.4, Tablo 4.5 ve Tablo 4.6’da verilmiştir.

**Tablo 4.4.** Eğitim seti için ELM ve GMDH sonuçlar.

| Senaryo   | Metrik         | GMDH      | ELM      |
|-----------|----------------|-----------|----------|
| Senaryo 1 | MSE            | 9.9861    | 11.0675  |
| Senaryo 1 | RMSE           | 3.1601    | 3.3268   |
| Senaryo 1 | R <sup>2</sup> | 0.8392    | 0.80596  |
| Senaryo 2 | MSE            | 0.62607   | 0.66279  |
| Senaryo 2 | RMSE           | 0.79125   | 0.81412  |
| Senaryo 2 | R <sup>2</sup> | 0.87157   | 0.8642   |
| Senaryo 3 | MSE            | 0.0059216 | 0.013645 |
| Senaryo 3 | RMSE           | 0.076952  | 0.11681  |
| Senaryo 3 | R <sup>2</sup> | 0.92433   | 0.84459  |

**Tablo 4.5.** Test seti için ELM ve GMDH sonuçlar.

| <b>Senaryo</b>   | <b>Metrik</b>  | <b>GMDH</b> | <b>ELM</b> |
|------------------|----------------|-------------|------------|
| <b>Senaryo 1</b> | MSE            | 12.3623     | 9.0585     |
| <b>Senaryo 1</b> | RMSE           | 3.516       | 3.0097     |
| <b>Senaryo 1</b> | R <sup>2</sup> | 0.83581     | 0.90388    |
| <b>Senaryo 2</b> | MSE            | 0.89843     | 0.67655    |
| <b>Senaryo 2</b> | RMSE           | 0.94786     | 0.82253    |
| <b>Senaryo 2</b> | R <sup>2</sup> | 0.83714     | 0.87405    |
| <b>Senaryo 3</b> | MSE            | 0.01584     | 0.01477    |
| <b>Senaryo 3</b> | RMSE           | 0.12586     | 0.12153    |
| <b>Senaryo 3</b> | R <sup>2</sup> | 0.8726      | 0.87009    |

**Tablo 4.6.** Tüm dataset için ELM ve GMDH sonuçlar.

| <b>Senaryo</b>   | <b>Metrik</b>  | <b>GMDH</b> | <b>ELM</b> |
|------------------|----------------|-------------|------------|
| <b>Senaryo 1</b> | MSE            | 10.6957     | 10.4676    |
| <b>Senaryo 1</b> | RMSE           | 3.2704      | 3.2354     |
| <b>Senaryo 1</b> | R <sup>2</sup> | 0.83223     | 0.83635    |
| <b>Senaryo 2</b> | MSE            | 0.7074      | 0.6669     |
| <b>Senaryo 2</b> | RMSE           | 0.84107     | 0.81664    |
| <b>Senaryo 2</b> | R <sup>2</sup> | 0.85876     | 0.86671    |
| <b>Senaryo 3</b> | MSE            | 0.0088832   | 0.013981   |
| <b>Senaryo 3</b> | RMSE           | 0.094251    | 0.11824    |
| <b>Senaryo 3</b> | R <sup>2</sup> | 0.90489     | 0.85366    |

## 5. SONUÇLAR VE ÖNERİLER

Bu başlık altında, test sonuçları Makine Öğrenmesimethodları ile yorumlanıp, akademik çalışmalar ve endüstriyel uygulamalar için öneriler sunulmuştur.

### 5.1. Sonuçlar

- ✓ Basınç dayanımı, eğilme dayanımı ve ultrases dalgası hızı analiz ve deneyleri sonucunda elde edilen verilerin makine öğrenmesi ELM ve GMDH modelleri ile işlenmiştir. Her iki model için sonuçlar birbirine yakın olarak elde edilmiştir.
- ✓ ELM ve GMDH modelleri, her biri belirli durumlarda farklı avantajlara sahip olsa da genellikle benzer bir performans sergilemesine rağmen ELM modeli sıkça daha düşük hata oranları ve yüksek  $R^2$  değerleri elde ederek tahminlerdeki hassasiyetini artırır. Genelleme yeteneği ve veri içindeki ilişkileri yakalama konusunda ELM, GMDH'ye göre daha etkili olabilir.

## 5.2. Öneriler

- ✓ Mevcut çalışmada ikili dayanıklılık problemine maruz bırakılmış karışımların numuneleri ile elde edilen sonuçlar ELM ve GMDH modelleri ile işlenmiştir. Gelecek çalışmalar için, şahit ve en az üç ve daha fazla dayanıklılık problemlerine maruz bırakılmış numuneler için benzer şekilde değerlendirmelerin yapılması ve durabilite problemi sayısının makine öğrenmesi modelleri üzerindeki etkisinin incelenmesi önerilmektedir.
- ✓ Gelecek çalışmalarda, daha geniş bir veri kümesi oluşturulması, modelin genelleme kabiliyetini artırabilir. Farklı malzeme türleri, sıcaklık ve çevresel koşullara dair daha fazla veri toplanarak, modelin performansı iyileştirilebilir.
- ✓ Makine öğrenmesi ile elde edilen sonuçlar, daha sürdürülebilir malzeme seçeneklerinin geliştirilmesine katkıda bulunabilir. Özellikle çevre dostu ve geri dönüştürülebilir kompozit malzemelerin performansının artırılması üzerine çalışmalar yapılabilir.
- ✓ Sektördeki deney maliyetlerinden, iş gücünden ve zamandan tasarruf sağlayacağından Geleneksel

---

betonda da makine öğrenmesi modelleri ile çalışmaların yapılması önerilmektedir.

## KAYNAKLAR

- Anandhi, G. (2025). A Comprehensive Survey on Generative AI Techniques and Their Tools: Recent Advances, Applications, Opportunities, and Challenges. *Research & Review: Machine Learning and Cloud Computing*, 4(1).
- Bishop, C. (2025, Nisan 3). Scientific discovery is AI's killer application. *Financial Times*.
- Cabrera Martin, I., Mukherjee, S., Baimagambetov, A., Vanschoren, J., & Polatidis, N. (2025, May 23). Evolving Machine Learning: A Survey. *arXiv*.
- Chen, W., Yang, K., Yu, Z., et al. (2024, May). A survey on imbalanced learning: latest research, applications and future directions. *Artificial Intelligence Review*, 57, 137.
- Financial Times. (2024). AI help to produce breakthrough in weather and climate forecasting.
- Gholami, A., & Al Abdwani, A. (2025). State-of-the-art review on various applications of machine learning techniques in material science and engineering. *Chemical Engineering Science*, 306, 121147.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1-3), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Ivakhnenko, A. G. (1968). The group method of data handling – A rival of the method of

- stochastic approximation. *Soviet Automatic Control*, 13(3), 43–55.
- Jevinger, J., Gala, R., Aminizadeh, M., et al. (2024). Performance enhancement of artificial intelligence: A survey. *Journal of Network and Computer Applications*, 232, 104034.
- Kalayci, C. B., & Dogan, S. (2021). Prediction of compressive strength of concrete using hybrid machine learning algorithms. *Construction and Building Materials*, 278, 122387. <https://doi.org/10.1016/j.conbuildmat.2021.122387>
- Kaya, N. (2024). Yüksek sıcaklık ve sülfat hücumuna maruz kalmış çimento esaslı lifli kompozitlerin mühendislik özelliklerinin makine öğrenmesi yöntemleriyle incelenmesi (Yayın No: 883738) [Doktora Tezi, Batman Üniversitesi]. Yök Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Liao, T., Li, T., & Nadkarni, P. (2025, May 21). A Survey On Secure Machine Learning. arXiv.
- Panahi, M., Rahmati, O., Rezaie, F., Lee, S., Mohammadi, F., & Conoscenti, C. (2022). Application of the group method of data handling (GMDH) approach for landslides susceptibility zonation using readily available spatial covariates. *Catena*, 208, 105779.
- Peter, H. (2025, April). A Survey of Applications, Challenges, and Future Directions in Machine Learning.
- Samuel, A. (1959). Some studies in machine learning using the game of checkers. *IBM Journal*.

- Shahmansouri, A. A., Yazdani, M., Ameri, F., & Jafari, A. (2020). Application of extreme learning machine and M5 model tree for prediction of mechanical properties of concrete containing waste marble powder. *Construction and Building Materials*, 252, 119115. <https://doi.org/10.1016/j.conbuildmat.2020.119115>
- Sonar, K., & Sathe, S. (2024). Exploring fiber reinforcements in concrete and its challenges: a comprehensive review. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 1-33
- Stojnic, A., et al. (2024). Label Propagation for Zero-shot Classification with Vision-Language Models (ZLaP).
- Tang, J., Deng, C., & Huang, G. B. (2015). Extreme learning machine for multilayer perceptron. *IEEE transactions on neural networks and learning systems*, 27(4), 809-821.
- Tiryaki, B., Tiryaki, H. E., & Altunisik, A. C. (2020). A novel hybrid GMDH-based approach for modeling the mechanical behavior of fiber-reinforced composites. *Engineering Structures*, 212, 110554. <https://doi.org/10.1016/j.engstruct.2020.110554>
- Tran, H. Q., Pham, V.-T., & Ngo, S. (2025, March 20). A survey on the applications of machine learning, deep learning, and reinforcement learning in wireless communications. *Communications and Telecommunication Engineering*, 3(1).
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2022). A review on extreme learning machine. *Multimedia Tools and Applications*, 81(29), 41611-41660.



- 
- Yu, Y., Zhang, C., Xie, X., Yousefi, A. M., Zhang, G., Li, J., & Samali, B. (2023). Compressive strength evaluation of cement-based materials in sulphate environment using optimized deep learning technology. *Developments in the Built Environment*, 16, 100298.
- Zhang, S., & Zhang, R. (2023). Prediction of the thermal conductivity of rocks using group method of data handling (GMDH). *Geothermics*, 115, 102823.
- Zhang, Y., Zhang, S., & Dinavahi, V. (2025, March). A survey of machine learning applications in advanced transportation systems: Trends, techniques, and future directions. *eTransportation*, 24(6323), 100417.
- Zong, W., Huang, G. B., & Chen, Y. (2013). Weighted extreme learning machine for imbalance learning. *Neurocomputing*, 101, 229-242.

# MAKİNE ÖĞRENMESİ İLE MÜHENDİSLİK ÖZELLİKLERİNİN MODELLENMESİ

Lifli Çimento Kompozitleri

**yaz**  
yayınları

YAZ Yayınları  
M.İhtisas OSB Mah. 4A Cad. No:3/3  
İscehisar / AFYONKARAHİSAR  
Tel : (0 531) 880 92 99  
yazyayinlari@gmail.com • www.yazyayinlari.com

ISBN: 978-625-5838-46-9



9 786255 838469