

ANN KULLANARAK ÇELİK FİBERLİ GEOPOLİMER BETONLARIN EĞİLME DAYANIMININ TAHMİNİ

Necip Altay EREN*

Gaziantep Üniversitesi, İslahiye MYO, İnşaat Bölümü, Gaziantep, 27800, Türkiye

Geliş Tarihi/Received Date: 24.04.2024 Kabul Tarihi/Accepted Date:28.11.2024 DOI:10.54365/adyumbd.1473171

ÖZET

Geopolimer mekanik özellikler, işlenebilirlik ve uzun süreli kullanımdan sonra dayanıklılıktaki iyi performansları nedeniyle birçok inşaat alanında incelenmiş ve uygulanmıştır. Geopolimer betonun eğilme dayanımının belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Bu çalışmanın amacı eğilme dayanımını daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesidir. Yapay zekanın geliştirilmesi, deneysel veriler aracılığıyla beton yapıların performansını verimli bir şekilde tahmin edebilen ve belirleyebilen bazı yöntemler önermektedir. Bu çalışmada, makine öğrenimi ile çelik fiber takviyeli geopolimer betonların eğilme dayanım performansının tahmini ve doğrulanması değerlendirilmiştir. Literatürdeki geopolimer betonun eğilme dayanımına ilişkin çalışmalarda deneysel veriler kullanılarak toplamda 104 deney verisi içeren bir veri seti oluşturulmuş ve modellemeye hazır hale getirilmiştir. Bu veri seti, Yapay Sinir Ağı yöntemi kullanılarak Python programlama diliyle modellenmiş ve analiz edilmiştir. Yapılan çalışma sonucunda R^2 değeri 0,994183 olarak elde edilmiştir. Bu sonuçlar, Yapay Sinir Ağı modelinin çelik fiberli geopolimer betonun eğilme dayanımını tahmin etmede oldukça başarılı olduğunu göstermektedir. Sonuç olarak, yapay zekâ teknikleri eğilme dayanım sonuçlarının daha hızlı tahmin edebilecek ve maliyetleri önemli ölçüde azaltacak imkânlar sunmaktadır. Bu çalışmanın bulguları, inşaat sektöründe gelecekteki araştırma ve uygulamalar için umut verici bir yöntem sunmaktadır.

Anahtar Kelimeler: Geopolimer, Eğilme Dayanımı, Yapay Sinir Ağı, Çelik Fiber

ESTIMATION OF FLEXURAL STRENGTH OF STEEL FIBER GEOPOLYMER CONCRETE USING ANN

ABSTRACT

Geopolymer has been studied and applied in many construction areas due to its good performances in mechanical properties, workability and durability after long-term use. Expensive laboratory tests are usually required to determine the flexural strength of geopolymer concrete. The aim of this study is to estimate the flexural strength more quickly, accurately, cheaply and effortlessly. The development of artificial intelligence suggests some methods that can efficiently predict and determine the performance of concrete structures through experimental data. In this research, the flexural strength performance prediction and verification of steel fiber reinforced geopolymer concretes were evaluated with machine learning. A data set containing a total of 104 experimental data was created using experimental data from studies on the flexural strength of geopolymer concrete in the literature and made ready for modeling. This data set was modeled and analyzed with the Python programming language using the Artificial Neural Network method. As a result of the study, the R^2 value was obtained as 0.994183. These results show that the Artificial Neural Network model is quite successful in predicting the flexural strength of steel fiber geopolymer concrete. In conclusion, artificial intelligence techniques offer the opportunity to predict flexural strength results faster and significantly reduce costs. The findings of this study provide a promising method for future research and applications in the construction industry.

Keywords: Geopolymer, Flexural Strength, ANN, Steel Fiber

**e-posta¹ : altayeren@gantep.edu.tr ORCID ID: <https://orcid.org/0000-0003-1421-4619>

1. Giriş

Geleneksel beton, dünyada sudan sonra en çok kullanılan ikinci malzemedir. Çimento, beton üretimi için önemli bir malzemedir. Ancak çimento üretimi sırasında CO₂ yayılır, bu da atmosferdeki sera gazı etkisini artırır [1]. CO₂ yayılımının %54'ü çimento üretimi sırasında ortaya çıkan kalsinasyona ve %46'sı yakıtların yakılmasından kaynaklanıyor [2]. Ayrıca inşaat sektöründe beton kullanımı giderek artmaktadır. Bunda dolayı artan CO₂ emisyonunu azaltmak için inşaat sektöründeki uygulamalarında geleneksel çimento kullanımının azaltılması giderek daha önemli hale gelmektedir. Bundan dolayı ,bu çevresel kaygıyı azaltmak için inşaat sektöründe daha çevre dostu malzemelere olan ihtiyaç giderek artmaktadır ve bu da yenilikçi alternatif malzemelere yönelik araştırmalara neden olmaktadır. Geopolimer Beton (GPB), gelecek vaat eden daha çevre dostu özelliklere sahip alternatif bir malzeme olarak ortaya çıkmaktadır. GPB metakaolin, cüruf, uçucu kül gibi bol miktarda alümina silikat malzemesi kaynağı ile kombinasyon halinde alkalın bir çözelti kullanılarak üretilmektedir. Bu yaklaşım sadece çimento üretimiyle ilişkili karbon ayak izini azaltmakla kalmıyor, aynı zamanda inşaat projeleri için de sürdürülebilir bir çözüm sunmaktadır. Bu düşüncelerden dolayı, GPB son yıllarda büyük ilgi görmektedir ve giderek geleneksel Portland çimentosuna alternatif bir malzeme olarak kabul edilmektedir [3-5]. Geopolimer farklı şekillerde üretilebilir, yüksek yakıt maliyeti ve yüksek sıcaklıkta fırın gerektirmez. Geopolimer için gerekli kaynaklar oldukça fazladır. Bu nedenle geopolimer kullanımı malzeme ve fabrika yatırımı gerektirmez. Düşük CO₂ emisyonlu geopolimer kullanımı çevre dostu olmasının yanı sıra inşaat sektörü ve beton sektörünün CO₂ emisyonlarını da %80 oranında azaltmaktadır [6]. Ayrıca, betonun eğilme dayanımını belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Eğilme dayanımını daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesi gerekmektedir. Bundan dolayı yapay zekâ teknikleri, beton gibi malzeme testlerinde harcanan zaman, emek ve maliyetten tasarruf sağlayarak sürdürülebilir inşaatla katkı sağlayabilir. Çeşitli makine öğrenme algoritmaları yardımıyla tahmin modelleri geliştirilerek betonun özellikleri belirlenebilir [7].

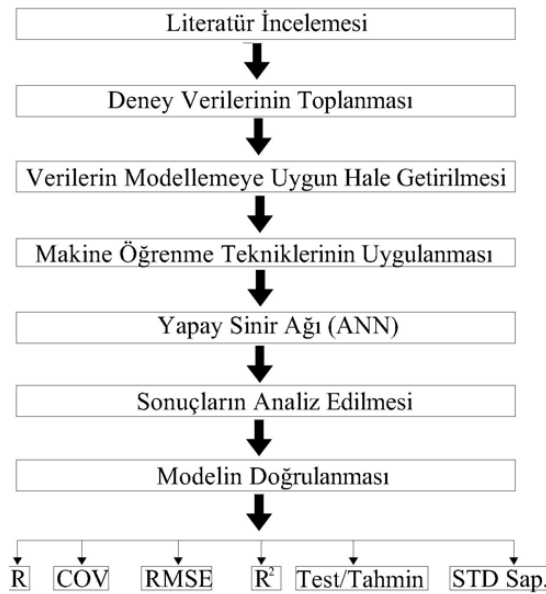
Beton alanında gerçekleştirilen bir diğer çağdaş gelişme ise fiber takviyeli betondur. Fiberin kullanılması, matrisin mekanik özelliklerini ve bütünlüğünü arttırdığı bulunmuştur. Beton içerisinde rastgele dağılan fiberler, betonda farklı aşamalarda oluşan çatlakların oluşmasını ve gelişmesini engeller, böylece içyapısında oluşan gerilimleri dağıtarak betonun enerji yutabilme kapasitesini artırır. Beton karışımında kullanılan fiberlerin etkinliği, fiberin en/boy oranına, geometrisine, çekme dayanımına, türüne ve kullanılan miktarına göre değişmektedir [8]. Beton karışımında kullanılan fiber çeşitlerinde biri Çelik fiberler (ÇF) dir. ÇF betonunun eğilme dayanıklılığını ve sünekliğini artırır. ÇF'lerin katkısı esas olarak betondaki matris çatlamasından sonra gözlemlenebilir, çünkü fiberler çatlakların ilerlemesine engel olur [9]. Bu nedenle, betonun kırılma dayanımı azalır ve enerji yutma kapasitesi artar.

Makine öğrenimi, insan etkileşimi olmadan öğrenme, akıl yürütme ve karar verme için veri kalıplarını ve yapılarını analiz eden ve yorumlayan bir hesaplamalı bilim alanı olan yapay zekânın bir parçasıdır. Bu noktada makine öğrenmesi, ÇF'li GPB'un eğilme dayanımını daha kısa sürede elde etmek için GPB'nun molaritesine, kullanılan ÇF miktarına, geometrik ve mekanik özelliklerine, ve numunenin geometrisi üzerinden GPB'un eğilme dayanımını tahmin edebilir. Bu çalışma, Yapay Sinir Ağları (ANN) modeli kullanılarak GPB'un eğilme dayanımını tahmininde uygulanabilirliğini keşfetmeyi amaçlamaktadır. ANN modeli oluşturmak için herhangi bir standart deneysel tasarım veya varsayım veya belirli bir denkleme ihtiyaç duymadan bilgileri hızla işleyen güçlü bir tahmin aracıdır [10]. ANN, düğümleri arasındaki sayısal ilişkiyi yakalar ve model içinde resmi bir formül kullanılmaz; ANN'lar, yönergeler ve veriler arasındaki ilişkilere göre eğitilir [11]. ANN, uygun uyum fonksiyonunun önceden belirlenmesine gerek kalmadan, ikinci dereceden fonksiyonlar da dahil olmak üzere hemen hemen her türlü doğrusal olmayan fonksiyonu tahmin etme evrensel yeteneğine sahiptir [12]. Bu araştırmadaki ANN modeli Python programlama dili kullanılarak oluşturulmuştur. Python, kolayca okunup uygulanabilecek şekilde tasarlanmış, açık kaynaklı, yüksek performanslı bir programlama dilidir [13].

GPB'nun eğilme dayanımının belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Bu çalışmanın amacı, ÇF takviyeli GPB 'un eğilme dayanımını makine öğrenme algoritması kullanarak daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesidir. Literatürde ÇF takviyeli GPB'un eğilme dayanım makine öğrenme teknikleri kullanarak tahmin etmek için çok az sayıda çalışma mevcuttur. Ayrıca, bu çalışma ÇF içeren GPB'nun eğilme dayanımını ANN kullanarak hızlı, doğru ve verimli bir tahmin modeli geliştirmektedir. Çalışma, GPB'nun çevre dostu yapısını ve çelik fiberlerin mekanik dayanım üzerindeki etkilerini inceleyerek, geleneksel yöntemlere kıyasla yenilikçi ve sürdürülebilir mühendislik çözümleri sunmayı hedefler. Ayrıca, daha dayanıklı ve çevresel açıdan avantajlı beton türlerinin geliştirilmesine, ve GPB kullanımının yaygınlaşmasına katkı sağlamayı amaçlar. Bu nedenle literatürde GPB'un eğilme dayanıklılığını araştıran çalışmalar kapsamlı incelenmiştir. Bu çalışmaların sonuçları, makine öğrenmesi algoritması olan ANN modeli için bağımlı ve bağımsız parametreler belirlendi. Belirlenen bu parametrelere göre incelenen çalışmalardan veriler toplanarak 104 veriden oluşan bir veri seti elde edildi. Elde edilen bu veri seti kullanılarak ANN modeli eğitildi. Bu model kullanılarak tahmin edilen sonuçlar, veri setindeki deneysel sonuçları ile karşılaştırılmıştır. Bulgular, makine öğrenimi algoritmasının, GPB'nun eğilme dayanımını doğru bir şekilde tahmin etmede önemli ölçüde umut vaat ettiğini göstermektedir.

2. Materyal ve Metod

Bu bölümde çalışmada kullanılan materyal ve yöntemler anlatılmıştır. Bu bağlamda öncelikle verilerin nasıl derlendiği ve hangi methodlar ile modellemeye hazır hale getirildiği açıklanmıştır. Daha sonra kullanılan makine öğrenmesi algoritmasından bahsedilmiştir. Son olarak modelin nasıl oluşturulduğuna ve sonuçlara yer verilmiştir. Çalışmanın stratejisini gösteren aşağıdaki grafik Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışma yönteminin akış şeması

2.1. Veri Hazırlanması

Bir makine öğrenmesi modeli elde etmek için veri setinin kalitesi oldukça önemlidir ve ayrıca Makine öğrenimi modelleri temiz ölçülmüş veriler olmalıdır. Bu nedenle veri setinin doğru bir şekilde toplanması ve makine öğrenmesi modellerine uygun hale getirilmesi oldukça önemlidir. Bu amaçla

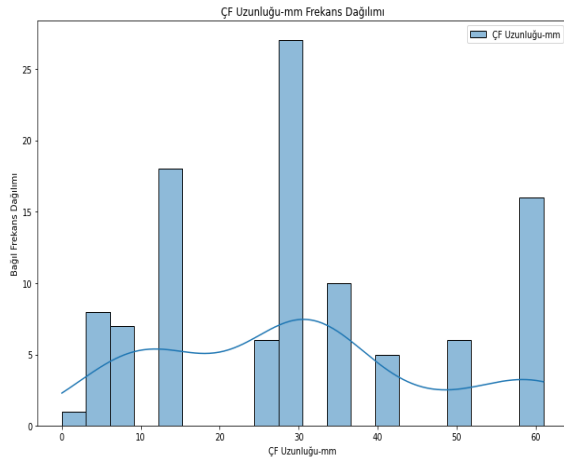
literatürde daha önce yapılan çalışmalar incelenmiş ve GPB numunelerinin eğilme dayanıklılığını inceleyen çalışmalardan toplam 104 veri içeren bir veri seti toplanmıştır ve elde edilen veri seti oluşturulurken kullanılan eğilme dayanımı değerleri Çizelge 1.'de verilmiştir. Ayrıca, GPB numunelerinin eğilme dayanımı da dahil olmak üzere tüm sayısal parametrelerin istatistiksel değerleri Çizelge 2.'de gösterilmiştir. Toplanan veri setinde eksik veriler mevcut olup, daha iyi bir sonuç elde etmek amacıyla bu veriler ortalama değerler kullanılarak belirlenmiştir. Ayrıca veri setine ait frekans dağılımı grafikleri Şekil 2.'de gösterilmiştir.

Çizelge 1. Veri seti oluşturulurken kullanılan eğilme dayanımı değerleri


Kaynaklar	Eğilme Dayanımı (MPa)	Kaynaklar	Eğilme Dayanımı (MPa)
[14]	3.1	[25]	4.43
	3.6		4.56
	4.3		3.21
[15]	1.23		4.69
	2.55		5.28
	4.23		5.52
	5.89		5.19
	6.82		6.08
[16]	8.48		6.72
	9.65		4.9
	7.02		5.6
	9.78		5.4
	10.22	4.8	
	11.2	5.3	
[17]	11.7	5.1	
	12.4	7.83	
	12.8	8.47	
	13.3	9.25	
	13.7	10.58	
[18]	5.35	12.15	
	6.4	7.41	
	7.45	11.12	
	8.5	10.25	
	9.55	9.83	
[19]	3.297	6.57	
	3.858	9.42	
	4.971	8.13	
[20]	12.1	7.91	
	16	5.2	
	18.9	8.75	
[21]	3.89	12.53	
	6.13	4.88	
	6.72	9.06	
[22]	11	10.66	
	19	3.94	
	24	4.61	
	16.6	4.1	
	25.8	6.15	
	31.9	4.9	
	17.9	5.1	
	31.4	5.5	
	33.3	5.6	
	14.2	6.5	
20.7	6.8		
[23]	30.5	7.1	
	6	7.4	
	7.8	7.2	
[24]	8.4	1.38	
	3.35	1.75	
	3.95	1.59	
	4.16	20.6	
	4.05	1.86	
[26]	[27]	4.8	1.84
		5.3	
		5.1	
7.83			
8.47			
9.25			
10.58			
12.15			
7.41			
11.12			
10.25			
9.83			
6.57			
9.42			
8.13			
7.91			
5.2			
8.75			
12.53			
4.88			
9.06			
10.66			
3.94			
4.61			
4.1			
6.15			
4.9			
5.1			
5.5			
5.6			
6.5			
6.8			
7.1			
7.4			
7.2			
1.38			
1.75			
1.59			
20.6			
1.86			
1.84			

Çizelge 2. Veri setinin istatistiksel değerleri


	Veri Sayısı	Minimum Değer	Maximum Değer	Ortalama	Standard Sapma
ÇF Uzunluğu (mm)	104	6	61	30.29	17.56
ÇF En/Boy Oranı	104	25	125	64.27	25.5
ÇF Oranı (%)	104	0.25	5	1.6	1.22
ÇF Çekme Dayanımı	104	800	3000	1611.96	682.24
Numunenin Eni (mm)	104	40	150	90.08	22.11
Numunenin Yüksekliği	104	40	125	87.1	24.28
Numunenin Uzunluğu	104	100	515	379.52	143.17
Molarite (M)	104	1.125	14	8.21	4.76




(a)



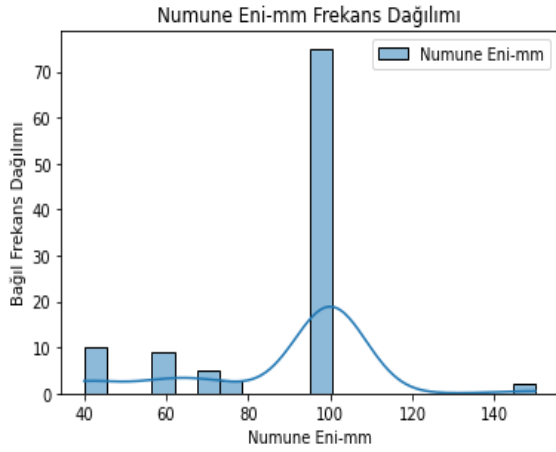
(b)



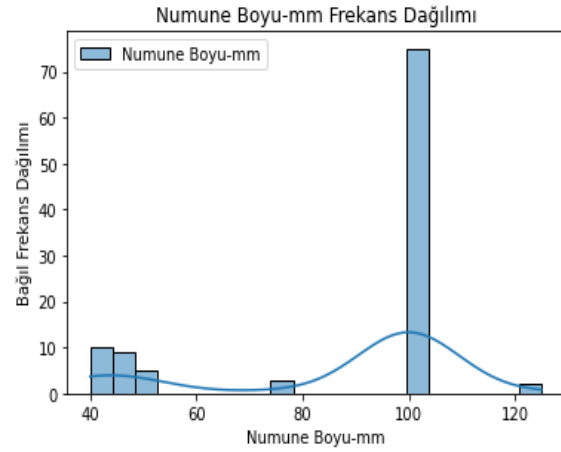
(c)




(d)




(e)



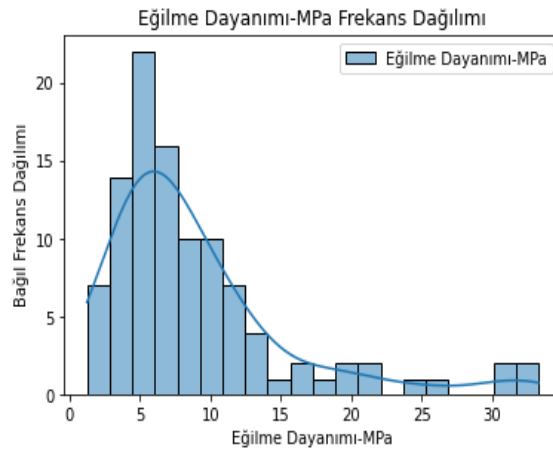
(f)



(g)




(h)



(i)

Şekil 2. Veri setine ait frekans dağılımı grafikleri:(a) SF Uzunluğu, (b) SF En/Boy Oranı (c) SF %, (d) SF Çekme Dayanımı, (e) Numunenin Eni, (f) Numunenin Boyu, (g) Numunenin Uzunluğu, (h) Molarity, (i) Eğilme Dayanımı

Veri setinin bağımsız değişkenleri arasında Şekil 3.'te gösterildiği gibi korelasyonlar mevcuttur. Korelasyon katsayılarıyla analiz yapmak veri setinin anlaşılmasını kolaylaştırır. Bir korelasyon katsayısının sıfırdan büyük olması değişkenler arasında pozitif, sıfırdan küçük olması ise değişkenler arasında negatif bir ilişkinin olduğunu işaret eder. Ayrıca korelasyon katsayısının sıfır olması bu değişkenlerin bağımsız olduğu anlamına gelir. Eğer, korelasyon katsayısı 1'e eşit ise, değişkenler arasında mükemmel bir ilişkinin olduğunu gösterir.

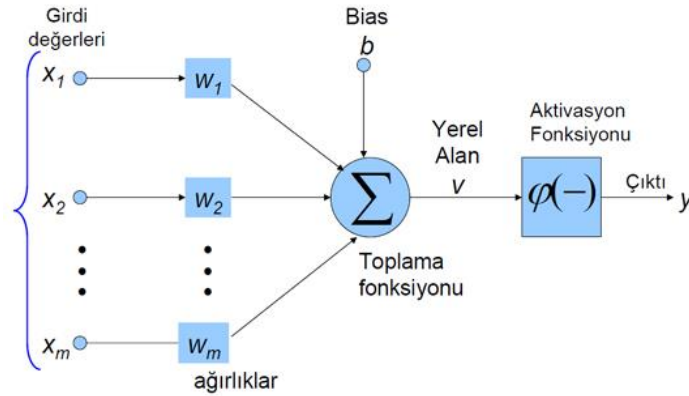


Şekil 3. Veri setinin korelasyon katsayıları Isı Haritası

2.2. Yapay Sinir Ağları (ANN):

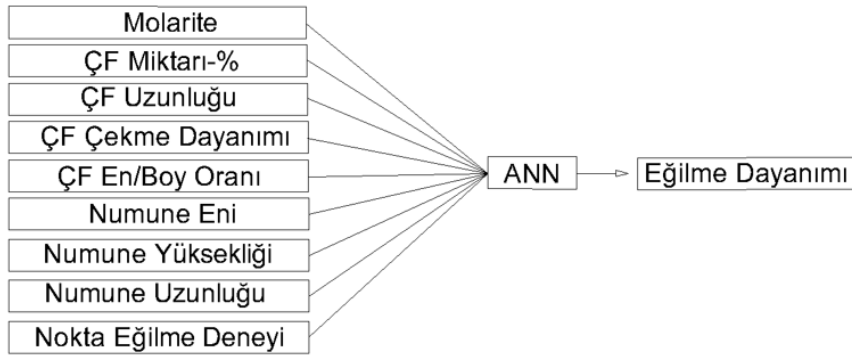
Yapay sinir ağı (ANN), insan beyninin yapısından ilham alan, birbirine bağlı unsurlardan oluşan bir hesaplama sistemidir. Özel bir öğrenme aşamasında sağlanan girdiler üzerinde eğitim alarak çıktıları tahmin etme yeteneğini kazanır [35]. Karmaşık doğrusal olmayan problemlerle başa çıkma potansiyeli yüksek olduğundan en yaygın kullanılan makine öğrenmesi modellerinden biridir [36]. ANN'nin ana görevi, tıpkı bir beyin nöronunun çalışma şekline benzer şekilde, sisteme verilen bir dizi girdiye yanıt olarak bir dizi çıktı üretmektir. Şekil 4.'te görüldüğü gibi ANN üç katmandan oluşur ve bu katmanlar bir araya gelerek sinir ağını oluşturur. ANN'ler girdi, çıktı ve gizli katmanlardan oluşur. İlk katman girdi katmanıdır ve veriler girdi katmanının aracılığıyla sisteme girer. Sonuçlarda çıktı katmanından elde edilir. Girdi ve çıktı katmanları arasında gizli katman vardır. Gizli katmanlar giriş ve çıkış katmanlarını birbirine bağlar. Birden fazla gizli katmana sahip bir sinir ağına çok katmanlı algılayıcı denir.

Bu araştırmadaki ANN modeli Python programlama dili kullanılarak oluşturulmuştur. Python, kolayca okunup uygulanabilecek şekilde tasarlanmış, açık kaynaklı, yüksek performanslı bir programlama dilidir [13]. Ayrıca çoklu işletim yazılımlarında kullanım açısından yüksek esneklik sağlar. Python, NumPy, Pandas, Keras ve TensorFlow gibi ANN modellerini oluşturmak için birleştirilmiş çok sayıda kütüphane içerir. Pandalar, NumPy'nin yüksek performanslı dizi bilişimini esnek elektronik tablo veri yönetimiyle birleştirerek Python'un veri analizi için güçlü bir araç olmasını sağlar [37]. Keras, ANN modellerini oluşturmak için kullanılan bir sinir ağı kütüphanesidir, TensorFlow ise makine öğrenimi görevlerini gerçekleştirmek için kullanılan kütüphanedir [38].



Şekil 4. Yapay sinir ağları işlem elemanı [39]

Ayrıca, ANN algoritması için giriş ve çıkış yol haritası Şekil 5.'te gösterilmiştir.



Şekil 5. ANN algoritması için giriş ve çıkış yol haritası

3. Araştırma Bulguları

Bu bölümde, performansların değerlendirilmesi amacıyla ortalama hata (test/tahmin), ortalama mutlak hata (MAE), ortalama karesel hata (MSE), kök ortalama kare hata (RMSE), korelasyon katsayısı (R) ve tanımlama katsayısı (R^2) değerleri hesaplanmıştır. Eğitilen modeli daha objektif bir şekilde değerlendirmek için ortalama hata değerinden yararlanılabilir. Ortalama hata değeri modelin yaptığı tahminlerin genel olarak gerçek değerden daha büyük mü yoksa daha küçük mü olduğunu anlamamıza yardımcı olur. Ortalama (test/tahmin) verebileceği en iyi sonuç 1'dir. Yani ortalama (test/tahmin) değeri 1'e yaklaştıkça modelin tahminleri de gerçek değerlere yaklaşmaktadır. Çizelge 3.'te eğitilen ANN modelinin ortalama (test/tahmin), MAE, MSE, RMSE, R ve R^2 değerleri gösterilmektedir. Bu değerlere göre; model oldukça etkileyici sonuçlar gösteriyor. MSE değeriniz 0,21255, yani model gerçek ve tahmin edilen değerler arasındaki ortalama karesel fark oldukça düşük. Benzer şekilde, MAE değeriniz 0,259399, yani gerçek ve tahmin edilen değerler arasındaki ortalama mutlak fark da oldukça düşük. Bu, modelin verilere oldukça yakın tahminlerde bulunduğunu gösterir. R^2 değeriniz oldukça yüksek, 0,994183. Bu, modelin bağımsız değişkenlerin açıkladığı toplam varyansın büyük bir kısmını açıkladığını gösterir. Yani, modelin verileri oldukça iyi uyduğu söylenebilir. RMSE değeriniz 4,22549. Bu, modelin hatalarının standart sapmasını gösterir. Düşük bir RMSE değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu gösterir. R değeriniz 0,889114, yani gerçek ve tahmin edilen değerler arasında güçlü bir pozitif ilişki olduğunu gösterir. Bu, modelin tahminlerinin gerçek değerlerle güçlü bir şekilde uyumlu olduğunu gösterir. Son olarak, ortalama (test/tahmin) oranı 0,99872. Bu, test değerlerinin tahmin değerlerinden yaklaşık olarak %0,128 daha küçük olduğunu gösterir. Tüm bu değerler göz önüne alındığında, oluşturduğunuz modelin oldukça güvenilir ve doğru tahminler yaptığını

söyleyebiliriz. Bu sonuçlar, modelin veri setinizdeki desenleri iyi anladığını ve doğru bir şekilde tahmin ettiğini gösterir. Ayrıca, Çizelge 4’te modelde kullanılan test değerleri, modelin tahmin ettiği değerler ve test/tahmin oranları verilmiştir.

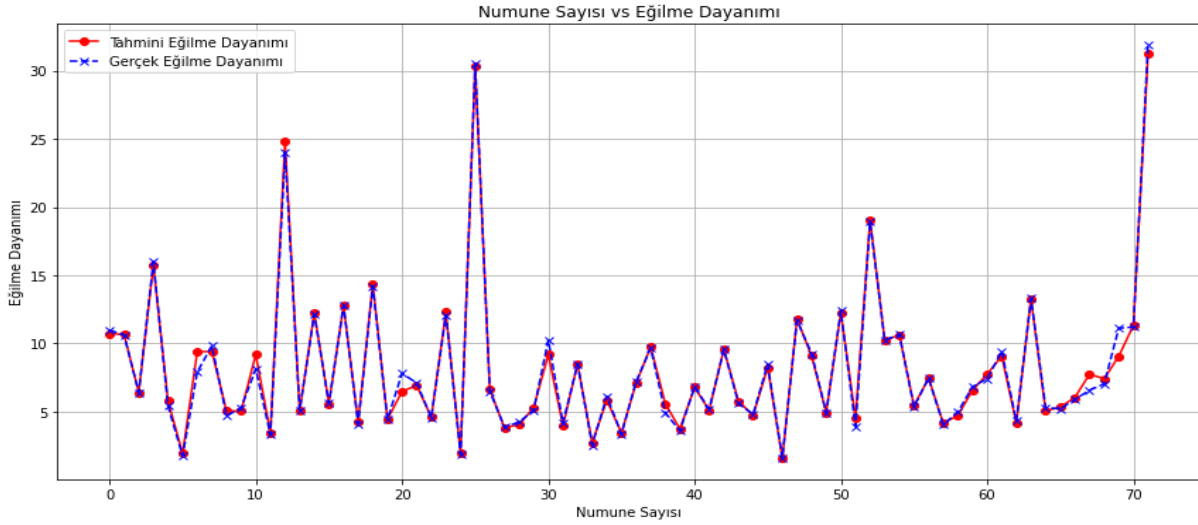
Çizelge 3. ANN Model değerlendirme metriklerine ait değerler

Model	Ortalama (Test/Tahmin)	MAE	MSE	RMSE	R	R ²
ANN	0.99872	0.2593	0.21255	4.250625	0.889114	0.994183

Çizelge 4. ANN Modeli için Test, Tahmin değerleri ve Test/Tahmin oranları

Test Değerleri	Tahmin Edilen Değerler	Test/Tahmin Oranı
93	94.16989136	0.9875768
58.41	61.7665863	0.945656924
35.92	32.76969528	1.096134697
47	42.85481644	1.0967262
42.86	34.11994934	1.256156613
42	40.61688232	1.034052778
40.95	33.75628662	1.213107368
23.81	33.70458984	0.706431976
53.45	55.64156342	0.960612835
38.1	38.97790527	0.977476848
53	56.64014435	0.935732079
150	151.5242157	0.989940778
54.32	52.16409302	1.041329329
144	148.1098022	0.972251653
89.5	92.71949768	0.965277016
74.97	68.0504303	1.101682968
38.57	36.56162643	1.054931188
61.5	58.09827423	1.058551236
70	60.0834465	1.165046349
77.8	74.36544037	1.046184889
38.46	38.31471634	1.00379185
38.46	38.101017	1.009421875
73.56	67.21195221	1.094448198
22.38	38.19934845	0.585873867
36.2	36.04360199	1.004339134
43.09	42.78999329	1.007011142
47.1	45.14181519	1.043378513
45.83	42.1729393	1.086715813
40.98	40.70159531	1.006840142
50.1	51.27976227	0.976993609
24.76	43.01924896	0.575556306
89	82.79144287	1.074990324
41.32	41.32405853	0.999901788
52.83	51.2417717	1.030994797
59.64	58.14741516	1.02566898
43.04	43.67703247	0.985414932
90.1	91.30731964	0.986777406
54.41	55.49445343	0.980458346
162	151.9851685	1.065893479
67.76	64.64296722	1.048219209
22.13	37.32938385	0.592830573
37.6	33.7326622	1.114646682
55.69	55.44241333	1.004465655
42.44	41.04401016	1.034012023

Şekil 6. ANN tarafından üretilen tahmin ayrıntılarını göstermektedir. Mavi çizgi gerçek verileri, kırmızı çizgi ise tahmin edilen verileri temsil eder. Aslında GPB'nun eğilme dayanımı gösteriyor ve iki çizgi genel olarak çok benzer, yani ANN ile yapılan tahmin modelinin çok doğru olduğu ve çok iyi çalıştığı anlamına geliyor.



Şekil 6. GPB'nun Eğilme Dayanımı tahmin grafiği

4. Sonuçlar

Bu çalışmanın konusu, çelik fiberli geopolimer betonun eğilme dayanımının ANN kullanılarak modellenmesi olmuştur. Geopolimer betonun geleneksel çimentolu betonun alternatifi olabileceği düşünüldüğünde, bu malzemenin özelliklerinin ve davranışlarının doğru bir şekilde modellenmesi oldukça önemlidir. Bu amaçla literatür kapsamlı incelenmiş ve modellemede kullanılacak olan veri seti oluşturulmuştur. ANN makine öğrenmesi algoritması kullanılarak model eğitilmiştir. Çalışma kapsamında, literatür kapsamlı bir şekilde incelenerek modelleme için uygun bir veri seti oluşturulmuştur. Ardından, ANN makine öğrenmesi algoritması kullanılarak bu veri setiyle bir model eğitilmiştir. Elde edilen model, farklı değerlendirme yöntemleri kullanılarak incelenmiş ve sonuçlar değerlendirilmiştir. Yapılan değerlendirmelerin sonucunda elde edilen bulgular ve öneriler aşağıdaki gibidir:

- Tahmin modelinin performansını değerlendirme yöntemlerinden biri modelin tanımlayıcılık katsayısıdır. R^2 değeri ANN modeli için 0,994183 olarak elde edilmiştir, yani ANN modeli %99,4183 doğrulukla tahmin yapmıştır. Buda, ANN modelinin eğilme dayanımının tahminlerinde başarılı sonuçlar verdiği görülmüş ve kullanılabilirliği test edilmiştir.
- Tahmin modellerinin performansını değerlendirmede kullanılan bir diğer yöntemde ortalama hata (ortalama (test/tahmin)) değerleridir. Ortalama hata değeri ANN modeli için 0.99872 olarak elde edilmiştir. Ortalama hata değeri 1 yaklaştıkça modelin daha doğru sonuç verdiği anlaşılır. ANN modelinin ortalama hata değeri 1 yakın olduğu için model iyi performans göstermiştir.
- ANN için RMSE değeri 4,250625'dur, bu da modelin tahminlerinin gerçek değerlere yakın olduğunu gösterirken, R değeriniz 0,889114'dir, bu da gerçek ve tahmin edilen değerler arasında güçlü bir pozitif ilişki olduğunu gösterir. Son olarak, ortalama (test/tahmin) oranı 0.99872'tür, bu da test değerlerinin tahmin değerlerinden yaklaşık %0,128 daha küçük olduğunu gösterir.
- Veri setinin korelasyon katsayıları ısı haritasına göre Numune Uzunluğu ve Numune Boyu arasında yüksek bir pozitif korelasyon görülmektedir. Ayrıca, Numune Eni ile Numune Boyu arasında yüksek bir pozitif ilişki bulunmaktadır. Buna ek olarak, Eğilme Dayanımı ile

Çekme Dayanımı arasında orta düzeyde bir pozitif ilişki bulunmaktadır. Bu iki dayanım özelliğinin kısmen ilişkili olduğunu ancak tamamen aynı şeyi ölçmediğini göstermektedir.

- Veri setinin korelasyon katsayıları ısı haritasına göre ÇF Uzunluğu ve ÇF Çekme Dayanımı arasında negatif bir korelasyon vardır. Bu, ÇF Uzunluğunun artmasının ÇF Çekme Dayanımını olumsuz etkileyebileceğini göstermektedir. Buna ek olarak, ÇF Uzunluğu ile Eğilme Dayanımı arasında da zayıf bir negatif korelasyon bulunur. Ayrıca, Molarity ile ÇF Çekme Dayanımı arasında düşük bir negatif korelasyon vardır. Bu, çözelti molaritesinin çekme dayanımı üzerindeki etkisinin belirgin olmadığını göstermektedir.
- Veri setinin korelasyon katsayıları ısı haritasına göre ÇF En/Boy Oranı ve diğer özellikler arasında genel olarak düşük korelasyon görülmektedir. Bu özelliğin diğerleriyle ilişkisinin zayıf olduğunu ve bağımsız bilgi sağlayabileceğini göstermektedir.
- Çelik fiberli geopolimer betonun eğilme dayanımının tahmininde ANN makine öğrenmesi algoritmasının başarılı sonuçlar verdiği ve modelin kullanılabilirliğinin test edildiği gözlemlenmiştir.
- ANN makine öğrenmesi algoritmasının tahmin ettiği değerlerin gerçek değerlere çok yakın olduğu gözlemlenmiştir. Bu yüzden geopolimer beton ile yapılacak yapıların maliyetleri önceden daha doğru belirlenebileceği öngörülmüştür.
- Kullanılan ANN'nin ve veri seti'nin özelliklerinin eğitilen modelin tahmin ettiği değerlerin üzerinde etki ettiği, ayrıca Python tabanlı programlama ile ANN makine öğrenmesi algoritmasının kurulumu ve kullanımının kolay olduğu sonucuna varılmıştır.
- Sunulan model yalnızca çelik fiberli geopolimer betonun eğilme dayanımını dikkate almıştır; farklı mekanik testler içeren daha büyük bir girdi veri seti, ANN modelinin tahmin yeteneğini arttırmak için kullanılabilir.

Kaynaklar

- [1] Niveditha M, Koniki S. Effect of Durability properties on Geopolymer concrete—A Review. E3S Web of Conferences EDP Sciences 2020; Vol. 184. <https://doi.org/10.1051/e3sconf/202018401092>
- [2] Eren NA. Punching shear behavior of geopolymer concrete two-way flat slabs incorporating a combination of nano silica and steel fibers. Construction and Building Materials 2022; Volume 346, 128351. <https://doi.org/10.1016/j.conbuildmat.2022.128351>
- [3] Bernal SA, Rodri'guez ED, Meji'a de Gutie'rrez R, Marisol Gordillo M, Provis JL. Mechanical and thermal characterisation of geopolymers based on silicate-activated metakaolin/slag blends. Journal of Materials Science 2011; volume 46, pages 5477–5486.
- [4] Davidovits J. Geopolymers and geopolymeric materials. Journal of thermal analysis, 1989; volume 35, pages 429–441.
- [5] Duxson P, Provis JL, Lukey GC, Deventer JSJ. The role of inorganic polymer technology in the development of 'green concrete'. Cement and Concrete Research 2007; 37 1590–1597.
- [6] Davidovits J. Properties of Geopolymer Cements. In First International Conference on Alkaline Cements and Concretes 1994; 131–149.
- [7] Deng F, He Y, Zhou S, Yu Y, Cheng H, Wu X. Compressive strength prediction of recycled concrete based on deep learning. Construction and Building Materials 2018; Vol. 175, pp. 562-569. <https://doi.org/10.1016/j.conbuildmat.2018.04.169>
- [8] Şimşek O. Beton ve Beton Teknolojisi, Seçkin Yayınevi, 2016; ISBN: 9789750261930, Türkiye.
- [9] Arunkumar K, Muthukannan M, Sureshkumar A. Experimental Behaviour of Fiber Reinforced Reactive Powder Concrete International Journal of Engineering and Advanced Technology (IJEAT) 2019; 9 (1S4) (2019) 454-459.
- [10] Aggarwal P, Aggarwal Y, Siddique R, Gupta S and Garg H. Fuzzy logic modeling of compressive strength of high-strength concrete (HSC) with supplementary cementitious material. Journal of Sustainable Cement-Based Materials, 2013; pp.1-16

- [11] Razavi SU, Jumaat MZ and El-Shafie AH. Load-deflection Analysis of CFRF strengthened RC slab using focused feedforward time delay neural network. *Concrete Research Letters*, 5(3), 2014; pp.858-872.
- [12] Moghaddam MG and Khajeh M. Comparison of Response Surface Methodology and Artificial Network in predicting microwave-assisted extraction procedure to determine zinc in fish muscles. *Food and Nutrition Sciences*, 2, 2011; pp.803- 808.
- [13] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Duchesnay É. Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 2011; 12, 2825-2830.
- [14] Gomes RF, Dias DP, Silva FA. Determination of the fracture parameters of steel fiber-reinforced geopolymer concrete, *Theoretical and Applied Fracture Mechanics*, 2020; Volume 107, <https://doi.org/10.1016/j.tafmec.2020.102568>
- [15] Ding Y, Bai YL. Fracture properties and softening curves of steel fiber-reinforced slag-based geopolymer mortar and concrete. *Materials* 2018; 11(8), 1445.
- [16] Pham KV, Nguyen TK, Le TA, Han SW, Lee G, Lee K. Assessment of performance of fiber reinforced geopolymer composites by experiment and simulation analysis. *Applied Sciences* 2019; 9(16), 3424.
- [17] Aisheh YIA, Atrushi DS, Akeed MH, Qaidi S, Tayeh BA. Influence of polypropylene and steel fibers on the mechanical properties of ultra-high-performance fiber-reinforced geopolymer concrete. *Case Studies in Construction Materials* 2022; 17, e01234.
- [18] Zhang P, Wang J, Li Q, Wan J, Ling Y. Mechanical and fracture properties of steel fiber-reinforced geopolymer concrete. *Science and Engineering of Composite Materials* 2021; 28(1), 299-313.
- [19] Sukontasukkul P, Pongsopha P, Chindaprasirt P, Songpiriyakij S. Flexural performance and toughness of hybrid steel and polypropylene fibre reinforced geopolymer. *Construction and Building Materials* 2018; 161, 37-44.
- [20] Liu Y, Shi C, Zhang Z, Li N, Shi D. Mechanical and fracture properties of ultra-high performance geopolymer concrete: Effects of steel fiber and silica fume. *Cement and Concrete Composites* 2020; 112, 103665.
- [21] Khan MZN, Hao Y, Hao H, Shaikh FUA. Mechanical properties of ambient cured high strength hybrid steel and synthetic fibers reinforced geopolymer composites. *Cement and Concrete Composites* 2018; 85, 133-152.
- [22] Liu Y, Zhang Z, Shi C, Zhu D, Li N, Deng Y. Development of ultra-high performance geopolymer concrete (UHPC): Influence of steel fiber on mechanical properties. *Cement and Concrete Composites* 2020; 112:103670. <https://doi.org/10.1016/j.cemconcomp.2020.103670>
- [23] Vijai K, Kumutha R, Vishnuram BG. Effect of Inclusion of Steel Fibres on The Properties of Geopolymer Concrete Composites. *Asian Journal of Civil Engineering (Building and Housing)* 2012; 13(3), 381-389. <https://sid.ir/paper/298940/en>
- [24] Zaid O, Martínez-García R, Abadel AA, Fraile-Fernández FJ, Alshaikh IM, Palencia-Coto C. To determine the performance of metakaolin-based fiber-reinforced geopolymer concrete with recycled aggregates. *Archives of Civil and Mechanical Engineering* 2022; 22(3), 114.
- [25] Sanjayan JG, Nazari A, Pouraliakbar H. FEA modelling of fracture toughness of steel fibre-reinforced geopolymer composites. *Materials & Design* 2015; 76, 215-222.
- [26] Rabiaa E, Mohamed RAS, Sofi WH, Tawfik TA. Developing geopolymer concrete properties by using nanomaterials and steel fibers. *Advances in Materials Science and Engineering* 2020; 2020, 1-12.
- [27] Bellum RR. Influence of steel and PP fibers on mechanical and microstructural properties of fly ash-GGBFS based geopolymer composites. *Ceramics International* 2022; 48(5), 6808-6818.
- [28] Faris MA, Abdullah MMAB, Muniandy R, Abu Hashim MF, Błoch K, Jeż B, Garus S, Palutkiewicz P, Mohd Mortar NA, Ghazali MF. Comparison of Hook and Straight Steel Fibers Addition on Malaysian Fly Ash-Based Geopolymer Concrete on the Slump, Density, Water Absorption and Mechanical Properties. *Materials*. 2021; 14(5):1310. <https://doi.org/10.3390/ma14051310>
- [29] Wang Y, Aslani F, Valizadeh A. An investigation into the mechanical behaviour of fibre-reinforced geopolymer concrete incorporating NiTi shape memory alloy, steel and polypropylene fibres.

- Construction and Building Materials 2020; Volume 259, 119765
<https://doi.org/10.1016/j.conbuildmat.2020.119765>
- [30] Bernal S, De Gutierrez R, Delvasto S, Rodriguez E. Performance of an alkali-activated slag concrete reinforced with steel fibers. Construction and Building Materials 2010; 24(2), 208-214.
- [31] Eren NA, Alzeebaree R, Çevik A, Niş A, Mohammedameen A, Gülşan ME. Fresh and hardened state performance of self-compacting slag based alkali activated concrete using nanosilica and steel fiber. Journal of Composite Materials 2021; 55(28):4125-4139. doi:10.1177/00219983211032390
- [32] Shah SFA, Chen B, Oderji SY, Haque MA, Ahmad MR. Comparative study on the effect of fiber type and content on the performance of one-part alkali-activated mortar. Construction and Building Materials 2020; 243:118221. <https://doi.org/10.1016/j.conbuildmat.2020.118221>
- [33] Ganesh AC, Sowmiya K, Muthukannan M. Investigation on the effect of steel fibers in geopolymer concrete. In IOP Conference Series: Materials Science and Engineering 2020; Vol. 872, No. 1, p. 012156. IOP Publishing. doi:10.1088/1757-899X/872/1/012156
- [34] Bhutta A, Borges PH, Zanotti C, Farooq M, Banthia N. Flexural behavior of geopolymer composites reinforced with steel and polypropylene macro fibers. Cement and Concrete Composites 2017; 80, 31-40. <http://dx.doi.org/10.1016/j.cemconcomp.2016.11.014>
- [35] Simon H. Neural networks: a comprehensive foundation. Prentice Hall PTR, 1998.
- [36] Mohammad R, Toufigh V. Evaluation of geopolymer concrete at high temperatures: An experimental study using machine learning. Journal of Cleaner Production 2022; 372: 133608. <https://doi.org/10.1016/j.jclepro.2022.133608>
- [37] Al-Jabery, K.K., Obafemi-Ajayi, T., Olbricht, G.R. and Wunsch Ii, D.C. (2020), “9 – Data analysis and machine learning tools in MATLAB and python”, in Al-Jabery, K.K., Obafemi-Ajayi, T., Olbricht, G.R. and Wunsch Ii, D.C., (Eds), Computational Learning Approaches to Data Analytics in Biomedical Applications, Academic Press, pp. 231-290.
- [38] Géron A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media 2019.
- [39] Kaya M. Geopolimer Betonun Yangın Dayanımının Makine Öğrenmesi Algoritmaları Kullanılarak Modellenmesi. Yüksek Lisans Tezi, Iğdır Üniversitesi İnşaat Mühendisliği Ana Bilim Dalı 2023.