



## İÇİ BETON DOLU DAİRESEL KESİTLİ ÇELİK BORULARIN EKSENEL YÜK KAPASİTELERİNİN YAPAY SİNİR AĞLARI VE RASSAL ORMAN YÖNTEMLERİ İLE TAHMİNİ

Cumhur COSGUN\*

New Jersey Institute of Technology, College of Engineering, Civil Engineering Department, New Jersey, USA

### Anahtar Kelimeler

İçi Beton Dolu Çelik Boru,  
Eksenel Yük Kapasitesi,  
Makine Öğrenmesi.

### Öz

Bu çalışmada, makine öğrenme teknikleri kullanılarak içi beton dolu dairesel kesitli çelik boruların (BDÇK) basınç altındaki nihai eksenel yük kapasiteleri tahmin edilmiştir. BDÇK kolonlar hem eksenel yükler, hem de yatay yükler altındaki performanslarından dolayı yapılarda çok tercih edilmektedirler. Bunun başlıca nedeni betonun ve çeliğin süneklilik ve rijitlik özelliklerinden kaynaklanmaktadır. Özellikle deprem etkisi altındaki yapısal elemanların davranışı yapının toptan davranışını etkilemektedir. Yapısal elemanların yük taşıma kapasitesinin makine öğrenme yöntemleri kullanılarak değerlendirilmesi araştırmacılar arasında oldukça popüler hale gelmiştir. Bu çalışma ile eksenel yük etkisi altındaki BDÇK kolonların eksenel yük kapasitesi yapay sinir ağları (YSA) ve rassal orman (RO) makine öğrenme yöntemleri kullanılarak tahmin edilmeye çalışılmış ve literatürdeki deney sonuçları ile karşılaştırılmıştır. Kapasite tahmini için literatürdeki 215 deney sonucu kullanılarak makine öğrenme yöntemleri arasında kıyaslama yapılmış, karşılaştırma sonucunda RO yönteminin daha iyi sonuç verdiği görülmüştür.

## PREDICTION OF AXIAL LOAD CAPACITY OF CONCRETE-FILLED STEEL TUBES WITH CIRCULAR SECTIONS UNDER AXIAL LOAD BY USING ARTIFICIAL NEURAL NETWORKS AND RANDOM FOREST METHODS

### Keywords

Concrete Filled Steel Tube,  
Axial Load Capacity,  
Machine Learning.

### Abstract

This paper focuses on the prediction of the ultimate compressive capacity of axially loaded concrete-filled steel (CFST) tube section columns using machine learning (ML) techniques. The use of CFST columns in the construction industry has been popular due to their superior structural performance both under axial loads as well as under lateral seismic loads. Studies carried out on the contribution of CFST members on lateral seismic resistance have revealed that the ideal combination of stiffness and ductility inherent in concrete and steel, respectively, results in superior performance under lateral loads. The evaluation of the load-carrying capacity of structural members ML-based predictive techniques has been popular among researchers. In this study, the case of CFST columns under axial loading is studied. The dataset needed for the prediction was acquired from the related existing research which provided the results of 215 experimental studies. The ML techniques that were used included two prevalent techniques namely Artificial Neural Networks (ANN) and Random Forest (RF). In this study, the axial compressive capacity was predicted using these techniques and finally, the performances of the techniques were compared. Overall, the RF prediction technique was found to be in very close agreement with the experimental results acquired from the literature.

### Alıntı / Cite

Cosgun, C., (2023). İçi Beton Dolu Dairesel Kesitli Çelik Boruların Eksenel Yük Kapasitelerinin Yapay Sinir Ağları ve Rassal Orman Yöntemleri ile Tahmini, Mühendislik Bilimleri ve Tasarım Dergisi, 11(2), 564-574.

### Yazar Kimliği / Author ID (ORCID Number)

C.Cosgun, 0000-0001-8345-622X

### Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	03.12.2021
Revizyon Tarihi / Revision Date	02.12.2022
Kabul Tarihi / Accepted Date	20.01.2023
Yayın Tarihi / Published Date	28.06.2023

\* İlgili yazar / Corresponding author: cumhur.cosgun@njit.edu

# PREDICTION OF AXIAL LOAD CAPACITY OF CONCRETE-FILLED STEEL TUBES WITH CIRCULAR SECTIONS UNDER AXIAL LOAD BY USING ARTIFICIAL NEURAL NETWORKS AND RANDOM FOREST METHODS

Cumhur COSGUN<sup>†</sup>

New Jersey Institute of Technology, College of Engineering, Civil Engineering Department, New Jersey, USA

---

## Highlights (At least 3 and maximum 4 sentences)

---

- Axial load capacity of CFST tube columns have been predicted by using ML techniques
- ANN and RF techniques have been employed
- The RF prediction technique has the highest accuracy performance in terms of R2 and RMSE
- The RF has a good fit in the prediction of the compression axial load capacity of CFST tube columns

---

## Purpose and Scope

The purpose of this study is to predict the ultimate compressive load capacity of axially loaded CFST tube columns using ML techniques. In the structural engineering literature, there has been many experimental and analytical studies about the design of CFST tube columns and their structural behavior. However, experimental studies are costly that require more time, equipment, effort, and financial resources. Therefore, we proposed a machine learning model for the prediction to save time, effort, and financial problems.

## Design/methodology/approach

In this study, the case of CFST tube columns under axial loading has been studied. The dataset needed for the prediction was acquired from the related existing research which involves the results of 215 experimental studies. The ML techniques that were used in this study included two prevalent techniques namely ANN and RF. The ML techniques were used to predict the axial compressive capacity of CFST. In order to see how well the prediction techniques work, 80% of the data were allocated as training data and 20% as test data. After the ML techniques were run, some performance criteria were used to evaluate and compare the performances of ML techniques. To validate the techniques, the k-fold cross-validation technique was used for performance evaluations of ML techniques. The RMSE and the R2 were used as the performance criteria. The high R2 value and low RMSE value indicate that the algorithm performs well, and the model makes a good prediction. Microsoft Excel was used for data processing and preparation, R programming language was used for ML analysis and JMP software was used to visualize the results.

## Findings

According to the results, RF provides a 94.25% R2 value whereas ANN provides only 44.68%. That is, in the RF technique, the variables explain 94.25% of the variability in the explanation of the axial load capacity. In addition, the RMSE value (495.108) obtained from the RF technique was also much lower than the RMSE value (2707.252) obtained from the ANN technique. Moreover, the mean ratio of the predicted results obtained by the RF technique and actual experimental results was calculated as 1.03, which also supports that RF has a good fit in the prediction of the compression axial load capacity of the CFST tube columns. The results show that the RF technique can be used as an alternative way to experimental studies to save time, cost, and effort.

## Practical implications (if applicable)

Our study underlines the importance of the successful usage of ML techniques in the decision-making process. ML techniques are competent enough to predict complicated procedures such as predicting the axial load capacity of CFST tube columns. It allows us to save time, cost, and effort.

## Originality

The use of ML prediction techniques in the field of civil/structural engineering is very limited in the literature. Only a few studies have used predictive analytical techniques related to civil/structural engineering. Therefore, in this study, ANN and RF, which are the most widely used machine learning estimation techniques, were used to estimate the axial load capacities of CFST tube columns. These ML techniques will be helpful in estimating the axial load capacity of CFST tube columns.

---

<sup>†</sup> İlgili yazar / Corresponding author: cumhurcosgun@gmail.com

## 1. Giriş (Introduction)

Literatürde içi beton dolu çelik kolonların (BDÇK) aksenal yük altındaki davranışı deneysel ve analitik olarak çokça çalışılmıştır (Giakoumelis and Lam, 2004; Chang et al., 2014; Han et al., 2014; Tran et al., 2020). Binalar, gökdelenler, köprü ayakları, tüneller ve kuleler, BDÇK kolonların kullanım alanları olarak örnek verilebilir (Kitada, 1998; Abdelkarim et al., 2015). BDÇK elemanlar yapılarda genellikle ana taşıyıcı kolon olarak kullanılırlar (Giakoumelis and Lam, 2004; Chang et al., 2014; Han et al., 2014; Xu, 2014). Ayrıca BDÇK kolonlar deprem bölgelerinde betonarme kolonların güçlendirmesi için de kullanılmıştır (Lai and Ho, 2014; Sakino ve Sun, 2000). BDÇK kolonların yapı elemanı olarak kullanılmasının nedenleri; enerji yutma kapasiteleri, basınç ve çekme dayanımları, süneklilikleri, rijtlikleri ve eğilme kapasitelerinin oldukça yüksek olmasıdır. Ayrıca düşük maliyet, betonda donatı kullanılmaması, sargı etkisini artırması, kesit boyutunun küçülmesi ve burkulma probleminin çözülmesi gibi faktörler de sıralanabilir. Literatürde BDÇK kolonların aksenal yük altındaki göçme yükünün çeliğin ve betonun malzeme özelliklerine ve çelik oranına bağlı olduğu belirtilmiştir (O'Shea and Bridge, 2000; Schneider, 1998; Sakino et al., 2004; Johansson and Gylltoft, 2002; Han and Yao, 2004; Han et al., 2005). Genellikle dairesel, dikdörtgen ve kare BDÇK kolonları çalışılmıştır. Çoğunlukla da içi boş çelik boruların içine donatısız beton dökülmüştür. Sünekliliğin ve ateşe dayanıklılığın araştırıldığı diğer çalışmalarda ise betonun içine elyaf ilave edilmiştir. Ayrıca bazı diğer araştırmalarda çelik borunun içine farklı basınç dayanımlarına sahip beton konularak boru kesitin aksenal yük altındaki dayanımı çalışılmıştır (Liu et al., 2003; Liu and Gho, 2005; Lue et al., 2007; Yu et al., 2008; Uy, 2001; Aslani et al., 2015). Başka bir deneysel çalışmalarında üç farklı beton basınç dayanımı (30, 60 ve 100MPa) kullanarak BDÇK kolonların aksenal yük kapasitesini bulmaya çalışmışlardır. Çalışma sonucunda American, Avustralya ve Eurocode 4'ün normal ve yüksek basınç dayanımlı betonlarda BDÇK kolonların aksenal yük kapasitesini bulmada çok güvenli tarafta kaldığı görülmüştür (Giakoumelis, Lam, 2004 ve Ellobody et al., 2006).

Literatürde BDÇK kolonların aksenal yük altındaki davranışı ile ilgili başka birçok çalışma vardır (Aslani et al., 2015; Clark, 1994; Cheng and Cao, 2016). Bu çalışmalar genellikle BDÇK kolonların basınç dayanımının tahmin edilmesi üzerinedir. Yapısal davranışın anlaşılmasında yarı veya tam ölçekli deneysel çalışmalar çok önemlidir. Fakat deneysel çalışmalar laboratuvar ortamında yapıldığında yüklü miktarda ekipman, işgücü ve finansal kaynak gerektirmektedir (Xiong et al., 2017; Cosgun et al., 2012; Cosgun et al., 2019; Cosgun et al., 2020a). Daha önce yapılan deney sonuçları ile başarısı test edilmiş makine öğrenmesi yöntemleri kullanılarak tüm bu maliyet ve iş gücü kayıpları engellenebilir (Hamit, E., 2015). Bu nedenlerden dolayı, bu çalışmada, aksenal basınç yükü altındaki BDÇK kolonların yük kapasitesinin tahmini için makine öğrenmesi alanında sıklıkla kullanılan ve iyi sonuçlar veren YSA ve RO makine öğrenme yöntemleri kullanılarak belirtilen gereksinimler ortadan kaldırılmaya çalışılmış, R2 ve RMSE performans kriterleri açısından kıyaslamaları yapılmıştır. Literatürde araştırmacılar BDÇK kısa kolonların aksenal yük kapasitesini bulmak için destek vektor makinesi (DVM) ve parçacık sürüsü optimizasyonu (PSO) yöntemleri (Ren et al., 2019), çoklu doğrusal regresyon (Cosgun et al., 2020b) ve çok değişkenli uygulanabilir regresyon (MARS) yöntemi (Karatas, 2019; Yuvaraj et al., 2013; Li and Yang, 2018) kullanılmıştır. MARS yöntemi ile beton basınç dayanımı, yüksek beton dayanımına sahip betonarme kirişlerin kırılma özellikleri ve elyaf takviyeli çimento esaslı kompozitlerin çekme şekil değiştirme kapasitesi tahmin edilmeye çalışılmıştır (Karatas, 2019; Yuvaraj et al., 2013; Li and Yang, 2018).

Literatürde makine öğrenme tahmin modellerinin inşaat/yapı mühendisliği alanında kullanımı oldukça sınırlıdır (Karatas, 2019). Sadece birkaç araştırmada inşaat/yapı mühendisliği ile ilgili tahmine dayalı analitik yöntemler kullanılmıştır (Dutta et al., 2017; Erdem, 2017). Bu nedenle bu çalışmada, en çok kullanılan makine öğrenme tahmin tekniklerinden olan YSA ve RO, BDÇK kolonların aksenal yük kapasitelerinin tahmininde kullanılmıştır. Bu makine tahmin modelleri BDÇK kolonların aksenal yük kapasitesinin tahmin edilmesinde yardımcı olacaktır. Makine öğrenme yöntemleri için literatürdeki 215 deney sonucu kullanılmıştır. YSA ve RO yöntemlerinin karşılaştırılması sonucunda RO yöntemi tahminlerinin gerçek deney sonuçları ile hemen hemen örtüştüğü görülmüştür. Böylece BDÇK kolonların aksenal yük kapasitesinin makine öğrenmesi yöntemleri ile tahmin edilebileceği görülmüştür.

## 2. Metodoloji (Methodology)

Çalışmada takip edilen metodoloji kısaca şu şekildedir: Öncelikle literatürden mevcut deneysel çalışmalarda kullanılan veriler elde edilmiş ve kullanılacak tahmin modelleri için uygun olup olmadığı kontrol edilmiştir. Daha sonra tahmin modellerinin nasıl çalıştığını gözlemleyebilmek için verilerin bir kısmı eğitim verisi, bir kısmı da test verisi olarak ayrılmıştır. Bir sonraki adımda, tahmin modellerinde literatürde sıklıkla kullanılan yöntemlerden YSA ve RO makine öğrenmesi teknikleri kapasite tahmini için kullanılmış ve makine öğrenmesi yöntemlerinin performanslarını değerlendirmek ve kıyaslama yapabilmek için kullanılan performans ölçütlerine yer verilmiştir. K-katlı capraz doğrulama yöntemi ile kullanılan makine öğrenmesi tekniklerinin performans değerlendirmeleri yapılmıştır.

Şekil 1’de çalışmada kullanılan metodoloji adımları görülmektedir. Veri işleme ve hazırlama için Excel programı, makine öğrenmesi analizleri için de R programlama dili ve sonuçların görselleştirilmesi için JMP yazılımı kullanılmıştır.



Şekil 1. Metodoloji adımları (Methodology steps)

## 2.1. Veri Toplama ve hazırlama (Dataset)

Birçok araştırmacı, BDÇK kolonların aksel basıncı yükü altındaki davranışını deneysel ve analitik olarak araştırmıştır. Literatüre bakıldığında BDÇK kolonların nihai aksel yük kapasitesi  $Nu$ , birçok etkene bağlıdır. Bu etkenler Tablo 1’de gösterilmiştir.

**Tablo 1.** Bu çalışmada kullanılan değişkenler (Variables used in this study)

DEĞİŞKENLER	AÇIKLAMA	KATMANLAR	VERİ TİPLERİ
D (mm)	Çelik Boru Dış Çapı	Girdi	Sayısal
t (mm)	Çelik Boru Et Kanlığı	Girdi	Sayısal
$f_c$ (MPa)	Sargısız Betonun Basınç Dayanımı	Girdi	Sayısal
$f_y$ (MPa)	Çeliğin Akma Dayanımı	Girdi	Sayısal
$E_c$ (MPa)	Betonun Elastisite Modülü	Girdi	Sayısal
$E_s$ (MPa)	Çeliğin Elastisite Modülü	Girdi	Sayısal
L (mm)	BDÇK Boru Uzunluğu	Girdi	Sayısal
$\xi$	Sargılama faktörü	Girdi	Sayısal
D/t	D/t oranı	Girdi	Sayısal
L/D	L/D oranı	Girdi	Sayısal
<b>Nu (kN)</b>	<b>Eksenel Yük Kapasitesi</b>	<b>Çıktı</b>	<b>Sayısal</b>

Bu çalışmada 215 deneysel veri kullanılmıştır. Veriler mevcut literatürdeki 22 farklı deneysel kaynaktan elde edilmiştir (Tablo 2). Kullanılan veri setinde çok geniş yelpazeye sahip çelik kolon çapı ve malzeme değerleri kullanılmıştır. Veri hazırlama aşamasında ise elde edilen verinin tahmin modellerine uygun olup olmadığı kontrol edilmiş, eksik veri olup olmaması, değerler arasında büyük farklılıklar olup olmaması vb. hiçbir problem olmadığı için veri seti sadece excel programında tablo haline getirilmiştir.

**Tablo 2.** Mevcut literatürden elde edilen deneysel veriler (Experimental data obtained from the existing literature)

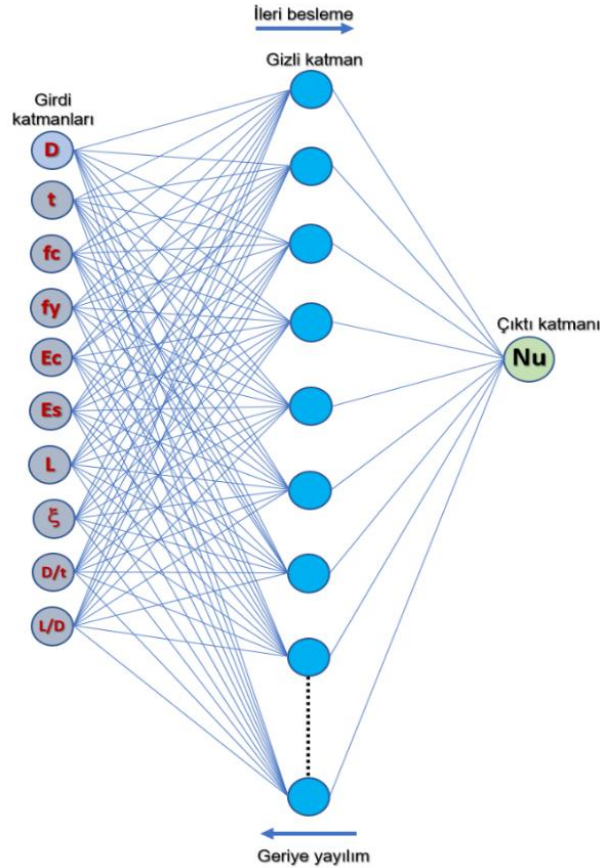
Veri Kaynağı	Numune Sayısı	D (mm)	t (mm)	fc (MPa)	Ec (MPa)	fy (MPa)	Es (MPa)	L (mm)	Nu (kN)
Gardener and Jacobson (Gardener and Jacobson 1967, Gardener 1968)	8	(101.7, 169.3)	(2.62, 4.09)	(23.1, 36.54)	(21482, 28411)	(317, 605)	(191536, 207050)	(203.3, 304.8)	(1068, 1307)
Tomii et al. (1977)	23	(150, 150)	(2, 4.3)	(18.03, 28.71)	(19957, 25183)	(280, 336)	(190120, 211680)	(450, 450)	(638, 1096)
Sakino and Hayashi (1991)	12	(174, 178)	(3, 9)	(22.15, 45.67)	(22120, 31762)	(248, 283)	(200000, 200000)	(360, 360)	(1467, 2677)
O'Shea and Bridge (1994, 1998)	10	(190, 190)	(0.86, 2.82)	(41, 110.3)	(17810, 28445)	(186, 363)	(177000, 207400)	(580.5, 664.5)	(1350, 2991)
Tan et al. (1999)	12	(125, 141.4)	(1, 6.5)	(23.81, 106)	(23528, 48389)	(232, 352)	(189475, 200000)	(438, 602)	(790, 2273)
Yamamoto et al. (2000)	6	(101.8, 318.5)	(3.03, 10.36)	(23.2, 52.2)	(22638, 33957)	(334, 452)	(200000, 200000)	(305, 950)	(628, 8289)
Huang et al. (2002)	3	(200, 300)	(2, 5)	(27.15, 31.15)	(24490, 26232)	(273, 342)	(200000, 200000)	(600, 900)	(1951, 3025)
Han and Yao (2004)	2	(220, 200)	(3, 3)	(49.5, 49.5)	(37420, 37420)	(304, 304)	(206500, 206500)	(600, 600)	(2256, 2383)
Giakomelis and Lam (2004)	12	(114.09, 115.04)	(3.75, 5.02)	(31.9, 104.9)	(23831, 45786)	(343, 365)	(200000, 200000)	(299.3, 300.5)	(929, 1787)
Sakino et al. (2004)	6	(108, 450)	(2.96, 6.47)	(40.5, 85.1)	(29911, 43357)	(279, 853)	(200000, 200000)	(324, 1350)	(1064, 13776)
Han et al. (2005)	22	(60, 250)	(1.87, 2)	(75.2, 80)	(41540, 41540)	(282, 404)	(201500, 207000)	(180, 750)	(312, 4800)
Gupta et al. (2007)	8	(89.32, 112.6)	(2.74, 2.89)	(25.28, 33)	(23631, 26999)	(360, 360)	(200000, 200000)	(340, 340)	(478, 757)
Yu et al. (2007)	2	(165, 165)	(2.72, 2.73)	(48, 67.2)	(32563, 38529)	(350, 350)	(213000, 213000)	(510, 510)	(1750, 2080)
de Oliveira (2009)	4	(114.3, 114.3)	(3.35, 3.35)	(32.7, 105.5)	(26876, 48275)	(287, 287)	(206000, 206000)	(342.9, 342.9)	(669, 1453)
Lee et al. (2011)	1	(360, 360)	(6, 6)	(31.5, 31.5)	(26379, 26379)	(498, 498)	(202000, 202000)	(1760, 1760)	(6888, 6888)
Xiong et al. (2017)	16	(114.3, 219.1)	(3.6, 10)	(51.6, 193.3)	(28000, 66000)	(300, 428)	(202000, 213000)	(250, 600)	(2340, 9187)
Guler et al. (2013, 2014)	4	(16.18, 114.2)	(2.99, 5.98)	(115, 145)	(50402, 56595)	(278, 314)	(200000, 200000)	(300, 400)	(795, 1833)
Han et al. (2014)	17	(133, 194)	(2.49, 6.11)	(32.8, 51)	(32600, 33900)	(299.4, 412)	(134600, 200000)	(400, 480)	(1071, 2759)
O'Shea & Bridge (2000)	18	(165, 190)	(0.86, 2.82)	(38.2, 108)	(16140, 29820)	(185.7, 363.3)	(170000, 207400)	(562.5, 664.5)	(1240, 3220)
He et al. (2019)	6	(165.2, 230)	(2.3, 3.7)	(29.5, 81.6)	(25560, 37000)	(360.8, 366)	(200000, 200000)	(495, 690)	(1264, 3147)
Han (2000)	11	(108, 108)	(4.5, 4.5)	(31.8, 46.8)	(27600, 28400)	(348.1, 348.1)	(202000, 202000)	(3510, 4158)	(292, 440)
Ekmek Yapar and AL-Eliwi, 2016	12	(114.3, 114.3)	(2.74, 5.9)	(56.2, 107.2)	(45800, 38400)	(235, 355)	(210000, 210000)	(600, 900)	(947.75, 1968.06)

## 2.2. Tahmin Modelleri (Prediction Models)

Çalışmada, eksenel yük etkisi altındaki BDÇK kolonların eksenel yük kapasitesinin tahmini için makine öğrenmesi yöntemlerinden olan YSA ve RO modelleri kullanılmıştır. Tablo 2'de verilen verilerden Nu modelin çıktısı, diğer tüm değişkenler de girdi olarak alınmıştır. Verilerin %80'i eğitim verisi, %20'si de modellerin performansını değerlendirmek için test verisi olarak kullanılmıştır. Modellerin doğruluğunu kontrol etmek için k-katlı çapraz doğrulama yöntemi (k-fold cross validation), performans ölçütü olarak da hata kareleri ortalamasının karekökü (RMSE) ve karar verme katsayısı (R2) kullanılmıştır. R2, regresyon tahminlerinin gerçek verilere ne kadar yaklaştığını gösteren istatistiksel bir ölçüttür ve 0% ve 100% arasında bir değer almaktadır. R2 değeri 1'e ne kadar yakınsa (yani ne kadar yuksekse) model o kadar iyi çalışıyor demektir. RMSE ise, tahmin edilen verideki hatanın standart sapmasını ve tahmindeki hata dağılımının ne kadar olduğunu bulmak için kullanılan ölçüm aracıdır. Bir başka deyişle, verilerin en uygun çizgi etrafında ne kadar yoğun olduğunu gösterir. Bu değer de ne kadar sıfıra yakınsa (yani düşük değer alıyorsa) model o kadar iyi tahmin etme kabiliyetine sahiptir. Sonuç olarak, yüksek R2 değeri ve düşük RMSE değeri modelin iyi çalıştığını ve modeldeki çıktının verilen girdilerle iyi tahmin edildiğini gösterir.

### 2.2.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları (YSA), en çok kullanılan makine öğrenme tekniklerinden biridir. Bu teknik insan beynini ve biyolojik organizmalarda öğrenme mekanizmasını simüle eder. YSA algoritması kendi kendine öğrenme yeteneğine sahip olduğu için veri sayısının çokluğu, gerçeğe daha yakın sonuç vereceği anlamına gelmektedir. Bu algoritma ile sıralı algoritmaların olmadığı doğrusal olmayan karmaşık yapıdaki problemler çözülür. YSA 3 ana katmanda incelenir, girdi katmanı, çıktı katmanı ve ara (gizli) katmanlar. Öğrenme esnasında girdi çıktı bilgileri verilerek kurallar koyulur ve görülmemiş çıktılar için sonuç üretilir. Bilgiler ağa girdi katmanından iletilir, ara katmanlarda işlenir ve buradan çıktı katmanına gönderilir. Bilginin ara katmanlarda işlenmesi gelen verilerin ağırlık değerleri kullanılarak çıktıya dönüştürülmesidir. YSA tek gizli katman içeriyorsa tek katmanlı sinir ağları, birden fazla gizli katman içeriyorsa çok katmanlı sinir ağları olarak adlandırılır. Bu çalışmada, tahmin için çok katmanlı algılayıcı yapı yöntemi (Multi Layer Perceptron - MLP) kullanılmıştır. MLP yönteminde birden fazla gizli katman girdi ve çıktı katmanları arasında yer alabilir (Aggarwal, 2018). Bu çalışmada sadece 1 gizli katman kullanılmıştır. Şekil 2' de bu çalışma için kullanılan YSA algoritma yapısı grafiksel olarak gösterilmiştir.



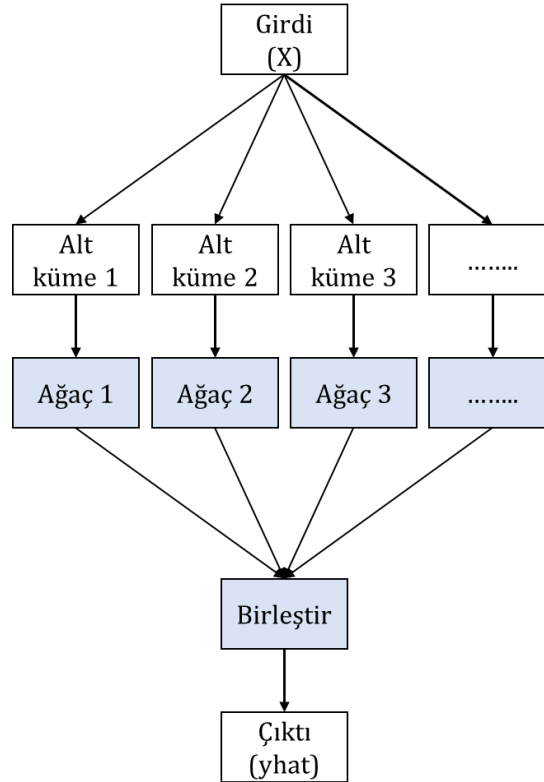
Şekil 2. YSA algoritmasının MLP yapısının grafiksel olarak gösterilmesi (Graphical representation of a multi-layer perceptron type ANN)

### 2.2.2. Rassal Orman (Random Forest)

Rassal orman (RO), çoklu karar ağaçlarının kullanıldığı hem regresyon hem de sınıflandırma amacıyla kullanılan bir makine öğrenmesi tekniğidir. RO yöntemi çıktısını tahmin ederken sadece bir karar ağacına güvenmez, bütün tahmin ağaçları topluluğunu kullanır. Bir başka deyiş ile bu yöntem, tahmin aşamasında hataları aza indirmek için tüm bireysel karar ağaçlarının tahminlerinin ortalamasını alır (Cheng and Cao, 2016). Bu çalışmada her girdinin birkaç kez tahmin edilmesi için algorithmada 100 ağaç kullanılmıştır. Birçok çalışmada RO algoritmasında kaç ağaç kullanılması gerektiği çalışılmıştır. Berkeley Üniversitesin'de yapılan bir çalışmada RO yönteminin iyi sonuç vermediği durumda istenildiği kadar ağaç kullanılabileceği belirtilmiştir (Breiman, L., 2001). Yine başka bir çalışmada RO algoritmasında kullanılacak ağaç sayısının 64 ile 128 arasında olması gerektiği fakat eğri altındaki alan (Area Under Curve – AUC) ile işlem süresi arasında iyi bir denge olması gerektiği belirtilmiştir (Oshiro et al., 2012).

Ayrıca, RO algoritması her bir ağacın her bir kesişim noktasında kesişim noktasını bölmek için rasgele bir alt küme seçer. Bu kümeler tahmin edicilerin sayısından daha küçüktür. Bu algorithmada, her bölme için iki değişken aday olarak seçilmiştir. Bu rassallığın amacı ağaçların ilişkisini düzenlemek ve varyansı azaltmaktır (Ishwaran, 2014).

RO algoritması, birden fazla karar ağacı modelinin çıktıları sonucunda oranlama yapılarak oluşturulduğu için karar ağaçlarında görülen aşırı öğrenmenin ve ezber yapmanın önüne geçmiştir. Her bir karar ağacı için de farklı veri seti kullanıldığı için aykırı veri sorununu minimuma düşürmektedir. RO bir torbalama (bagging) yöntemidir. Şekil 3' te gösterildiği gibi orjinal veri kümesinden birçok alt küme oluşturulur ve her küme paralel olarak eğitilip tüm modellerden elde edilen sonuç birleştirilerek nihai sonuç ortaya çıkarılır.



Şekil 3. Torbalama yöntemi (Bagging method)

### 2.3. K-katlı Çapraz Doğrulama (K-fold Cross Validation)

Tahmin modellerinin doğruluğunu kontrol etmek için k-katlı çapraz doğrulama yöntemi kullanılmıştır. Çapraz doğrulama tahmin modellerinin değerlendirilmesi sürecinde datayı eğitim ve test verisi olmak üzere ikiye ayırır ve eğitim verisi üzerinde model eğitilir, test verisi üzerinde de modelin ne kadar doğru çalıştığı test edilir. K-katlı çapraz doğrulama yöntemi ise veriyi rassal olarak k eşit parçaya böler, Bu k parçadan sadece bir tanesi test verisi diğerleri ise modelin eğitimi için kullanılır ve bu işlem k kez tekrarlanır. Böylece her veri parçası mutlaka modelin eğitimi ve test edilmesi aşamasında kullanılmış olur.

Tahmin modellerinin doğruluğu aşağıdaki formülasyon ile hesaplanır (Rodriguez et al., 2009):

$$\text{Toplam dogruluk} = \frac{1}{k} \sum_{i=1}^k \text{Dogruluk}_i \quad (1)$$

Çalışmada, k değeri literatürde en çok kullanılan ve iyi sonuçlar verdiği belirtilen k=10 olarak alınmıştır (Delen et al., 2007).

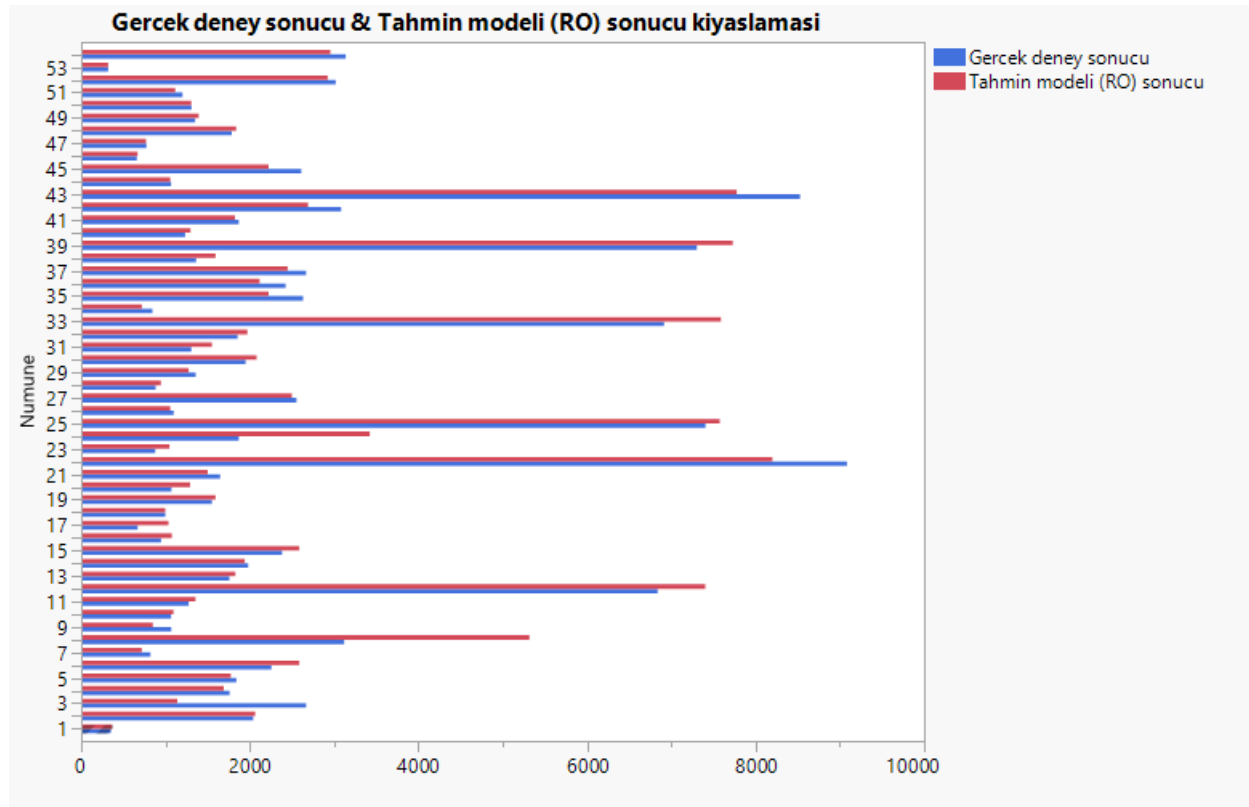
### 3. Sonuçlar ve Tartışma (Results and Discussion)

Tahmin algoritmalarının nasıl performans gösterdikleri Tablo 3'te verilmiştir. Yüksek R2 değeri ve düşük RMSE değeri algoritmanın yüksek bir performans gösterdiği ve modelin iyi bir tahmin yaptığını göstermektedir. Tablo 3'deki sonuçlara bakıldığında R2 ve RMSE ölçütleri açısından RO yönteminin daha iyi performans gösterdiği görülmüştür. RO sonucuna göre deney sonuçları %94.25 doğrulukla tahmin edilmiştir. Başka bir deyişle, model girdileri olarak kullanılan değişkenler, model çıktısı olan eksenel yük etkisi altındaki BDÇK kolonların eksenel yük kapasitesindeki değişkenliğin %94.25' ini açıklayabilmektedir. Ayrıca RO yönteminden elde edilen RMSE değerinin de YSA modelinden elde edilen RMSE değerine göre çok daha düşük olduğu görülmektedir.

**Table 3.** Tahmin yöntemlerinin R2 ve RMSE değerleri (R2 and RMSE values of predictive models)

TAHMİN YÖNTEMLERİ	R2 DEĞERİ	RMSE
YSA	%44.68	2707.252
RO	%94.25	495.108

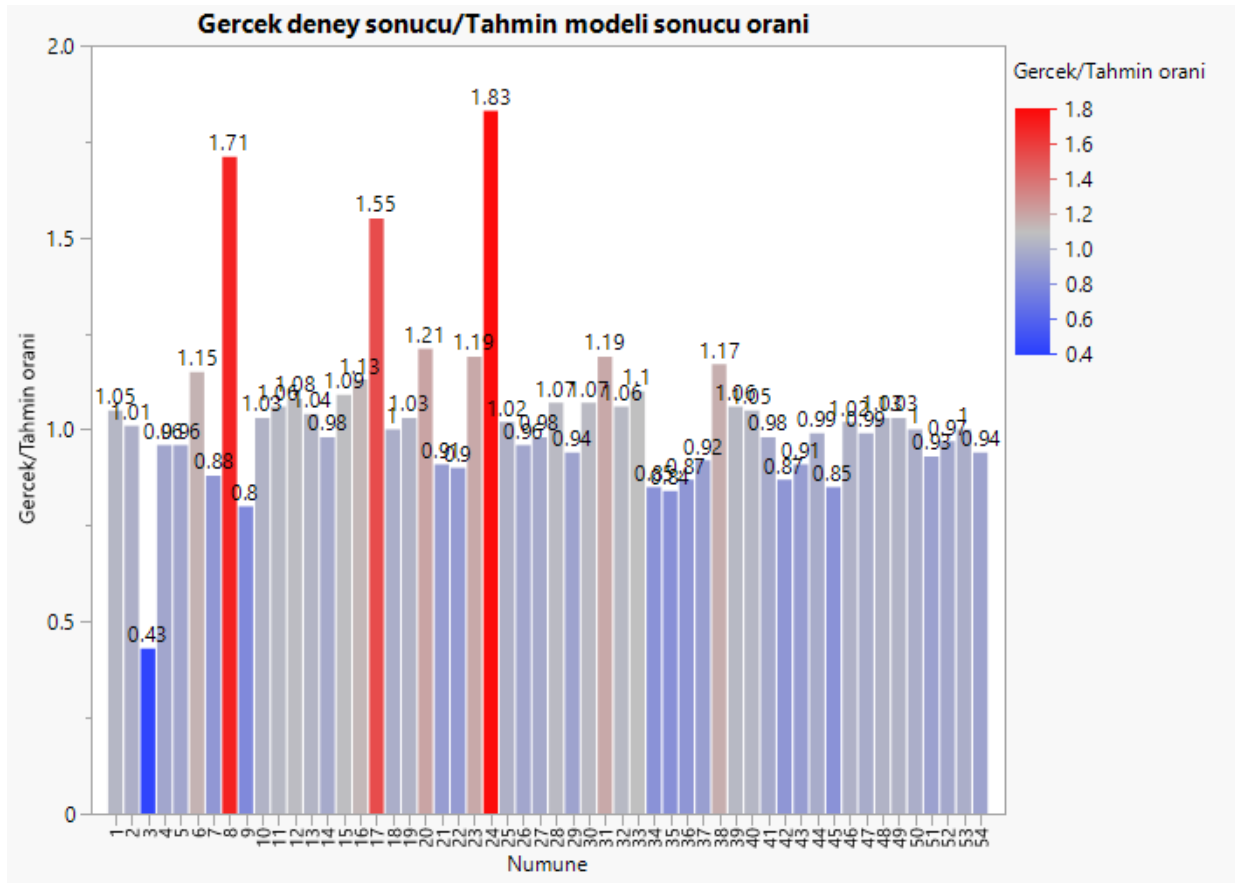
Sekil 4'te test verisi olarak kullanılan ve toplam veri seti'nin 20%'sini oluşturan numunelerin gerçek deney sonuçları ve RO modelinden elde edilen tahmin sonuçları karşılaştırılmıştır. Sekil 4'ten de görüldüğü gibi RO yönteminden elde edilen tahmin sonuçları gerçek deney sonuçlarına çok yakındır.



**Sekil 4.** BDÇK kolonların nihai yük kapasitesi deney sonuçlarının RO tahmin yöntemi ile karşılaştırılması (Comparison of the experimental load capacity of CFST columns with RF prediction method)

Ayrıca, Şekil 5'te literatürden elde edilen gerçek deney sonuçlarının RO yöntemi ile elde edilen tahmin sonuçları ile, birkaç numune dışında (kırmızı ve mavi ile gösterilen), örtüşükleri daha açık bir şekilde görülmektedir. RO modeli ve gerçek deney sonuçlarının ortalama oranının 1.03 olması da bunu desteklemektedir.





**Şekil 5.** Gerçek deney sonuçları ve RO yöntemi tahmin sonuçları oranları (Experimental test result and RF prediction method ratios)

#### 4. Sonuç (Conclusion)

Bu çalışma ile eksenel yük etkisi altındaki BDÇK kolonların basınç altındaki eksenel yük kapasitesi, YSA ve RO makine öğrenmesi yöntemleri kullanılarak tahmin edilmiştir. Çalışmada kullanılan veri seti literatürdeki mevcut deneysel çalışmalardan elde edilmiştir. Yapı mühendisliği alanında BDÇK'nın eksenel yük altındaki davranışını araştıran deneysel ve analitik çalışma sayısı oldukça fazladır. Fakat deneysel çalışmalar yüklü miktarda ekipman, işgücü ve finansal kaynak gerektiren, maliyetli çalışmalardır. Bu çalışmada, daha önce yapılan deney sonuçları ile birçok alanda çok iyi performans gösteren makine öğrenme yöntemleri kullanılarak BDÇK kolonların eksenel yük kapasitesi tahmini yapılmıştır. Ayrıca kullanılan makine öğrenmesi yöntemleri ile maliyet ve iş gücü kayıplarının engellenebileceği düşünülmüştür.

Bu çalışmada, iki farklı makine öğrenmesi yöntemi (YSA ve RO) kullanılmış ve RMSE ve R2 performans ölçütleri açısından performansları değerlendirilmiştir. Yapılan analizler sonucunda RO yönteminin, RMSE ve R2 performans ölçütleri açısından çok iyi sonuçlar verdiği görülmüştür. RO sonucuna göre, modelin çıktısı olan Nu eksenel yük kapasitesi değişkeninin değişkenliği kullanılan girdi değişkenleri ile %94.25 gibi büyük bir olasılıkla açıklanmaktadır. Elde edilen RMSE değerinin de çok düşük olduğu görülmektedir.

#### Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

#### Kaynakça (References)

- Abdelkarim, O.I., Ghani, A., Anumolu, S., Wang, S. and ElGawady, M., 2015. Hollow-Core FRP-Concrete-Steel Bridge Columns Under Extreme Loading. Report No. cmr15-008; Missouri Department of Transportation Research, Development and Technology, Missouri University of Science and Technology, MO, USA.
- Aggarwal, C.C., 2018. Neural Networks and Deep Learning A Textbook. Springer ISBN 978-3-319-94462-3.
- Aslani, F., Uy, B. and Tao, Z. and Mashiri, F., 2015. Behavior And Design Composite Columns Incorporating Compact High Strength Steel Plates. Journal of Construction Steel Research., 107, 94-110.
- Breiman, L., 2001. Random Forests Book. Machine Learning, 45(1): 5-32.

- Chang, X., Luo, X., Zhu, C., Tang, C., 2014. Analysis Of Circular Concrete-Filled Steel Tube (CFT) Support In High Ground Stress Conditions. *Tunnel Underground Space Technol.* 43, 41-48.
- Cheng, M.Y. and Cao, M.T., 2016. Estimating Strength Of Rubberized Concrete Using Evolutionary Multivariate Adaptive Regression Splines. *Journal of Civil Engineering Management*, 22(5), 711-720.
- Clark, W.S., 1994. Axial Load Capacity Of Circular Steel Tube Columns Filled With High Strength Concrete. Master thesis, Victoria University of Technology, Australia.
- Cosgun C., Comert M., Demir C., Ilki A., 2012. FRP Retrofit a Full Scale 3D RC Frame. 6th International Conference on FRP Composites in Civil Engineering 13-15 June 2012, Roma, Italy.
- Cosgun, C., Comert, M., Demir, C. and Ilki, A., 2019. Seismic Retrofit of Joints of a Full-Scale 3D Reinforced Concrete Frame with FRP Composites. *Journal of Composites for Construction* April 2019 Volume 23, Issue 2, [https://doi.org/10.1061/\(ASCE\)CC.1943-5614.0000923](https://doi.org/10.1061/(ASCE)CC.1943-5614.0000923).
- Cosgun, C., Turk, A.M., Mangir, A. Cosgun, T. and Kiyamaz, G., 2020a. Experimental Behaviour And Failure Of Beam-Column Joints With Plain Bars, Low-Strength Concrete And Different Anchorage Details. *Engineering Failure Analysis*, Volume 109, 2020, 104247, <https://doi.org/10.1016/j.engfailanal.2019.104247>.
- Cosgun, C., Cosgun, O., Sadeghian, R. and Aram, S., 2020b. Prediction of Ultimate Load Capacity of Concrete-Filled Steel Tubes with Circular Sections under Axial Load by Using Predictive Analytics Methods. 2020 International Conference on Computational Science and Computational Intelligence (CSCI).
- de Oliveira, W.L.A., de Nardin, S., de Cresce El Debs, A.L.H. and El Debs, M.K., 2009. Influence Of Concrete Strength And Length/Diameter On The Axial Capacity Of CFT Columns. *Journal of Construction Steel Research*, 65(12), 2103-2110.
- Delen, D., Tomak, L., Topuz, K., and Eryarsoy, E., 2017. Investigating injury severity risk factors in automobile crashes with predictive analytics and sensitivity analysis methods. *Journal of Transport & Health* 4 (2017) 118-131.
- Dutta, S., Murthy, A.R., Kim, D. and Samui, P., 2017. Prediction Of Compressive Strength Of Self-Compacting Concrete Using Intelligent Computational Modelling. *CMC: Computers, Materials & Continua*, 53(2), 157-174.
- Ekmekyapar, T and AL-Eliwi, B. J. M., 2016. Experimental Behaviour Of Circular Concrete Filled Steel Tube Columns And Design Specifications. *Thin-Walled Structures*, vol. 105, pp. 220-230.
- Ellobody, E., Young, B. and Lam, D. (2006), "Behavior of normal and high strength concrete-filled compact steel tube circular stub columns", *J. Constr. Steel Res.*, 62(7), 706-715. <https://doi.org/10.1016/j.jcsr.2005.11.002>
- Erdem, H., 2017. Predicting The Moment Capacity Of RC Slabs With Insulation Materials Exposed To Fire By ANN. *Structural Engineering and Mechanics*, Volume 64 issue 3, Pages 339-346.
- Gardener, N.J. and Jacobson, R., 1967. Structural Behavior Of Concrete Filled Steel Tubes. *J. Am. Concrete Inst. (ACI)*, 64(7), 404-413.
- Gardener, N.J., 1968. Use Of Spiral Welded Steel Tubes In Pipe Columns. *J. Am. Concrete Inst. (ACI)*, 65(11), 937-942.
- Giakoumelis, G. and Lam, D., 2004. Axial capacity of circular concrete-filled tube columns. *J. Constr. Steel Res.*, 60(7), 1049-1068. <https://doi.org/10.1016/j.jcsr.2003.10.001>.
- Gupta, P.K., Sarda, S.M. and Kumar, M.S., 2007. Experimental And Computational Study Of Concrete Filled Steel Tubular Columns Under Axial Loads. *J. Constr. Steel Res.*, 63(2), 182-193. <https://doi.org/10.1016/j.jcsr.2006.04.004>.
- Hamit, E., (2015). Makine Öğrenmesi Yöntemlerinin İnşaat Sektörüne Katkısı: Basınç Dayanımı Tahminlemesi. *JOUR - Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, VL-21, SP109-114.
- Han, L.H., Yao, G.H. and Zhao, X.L., 2005. Tests And Calculations For Hollow Structural Steel (HSS) Stub Columns Filled With Self-Consolidating Concrete (SCC). *J. Constr. Steel Res.*, 61(9), 1241-1269.
- Han, L.H. and Yao, G.H., 2004. Experimental Behaviour Of Thin-walled Hollow Structural Steel (HSS) Columns Filled With Selfconsolidating Concrete (SCC). *Thin-Wall. Struct.*, 42(9), 1357- 1377. <https://doi.org/10.1016/j.tws.2004.03.016>.
- Han, L.H., Li, W. and Bjorhovde, R., 2014. Developments And Advanced Applications Of Concrete-Filled Steel Tubular (CFST) Structures Members. *J. Constr. Steel Res.* 100, 211-228.
- Han, L.H., 2000. Tests on Concrete Filled Steel Tubular Columns With High Slenderness Ratio. *Advances in Structural Engineering*, vol. 3, no. 4, pp. 337-344.
- Huang, C.S., Yeh, Y.K., Liu, G.Y., Hu, H.T., Tsai, K.C., Weng, Y.T., Wang, S.H. and Wu, M.H., 2002. Axial Load Behavior Of Stiffened Concrete-Filled Steel Columns. *Journal of Structural Engineering*, ASCE, 128(9), 1222-1230.
- Ishwaran, H., 2014. The Effect of Splitting on Random Forests. *Machine learning*, 99(1), 75-118. <https://doi.org/10.1007/s10994-014-5451-2>.
- Johansson, M. and Gylltoft, K., 2002. Mechanical Behavior Of Circular Steel-Concrete Composite Stub Columns. *J. Struct. Eng.*, ASCE, 128(8), 1073-1081. [https://doi.org/10.1061/\(ASCE\)0733-9445\(2002\)128:8\(1073\)](https://doi.org/10.1061/(ASCE)0733-9445(2002)128:8(1073)).
- Karatas, C., 2019. Prediction Of Ultimate Load Capacity Of Concrete-Filled Steel Tube Columns Using Multivariate Adaptive Regression Splines (MARS). *Steel and Composite Structures*, Vol 33, No. 4 (2019) 583-594.
- Kitada, T., 1998. Ultimate Strength And Ductility Of State-Of-The-art Concrete-Filled Steel Bridge Piers In Japan. *Eng. Struct.*, 20(4- 6), 347-354. [https://doi.org/10.1016/S0141-0296\(97\)00026-6](https://doi.org/10.1016/S0141-0296(97)00026-6).
- Lai, M.H., Ho, J.C.M., 2014. Confinement Effect Of Ring-Confined Concrete-Filled-Steel Tube Columns Under Uni-Axial Load. *Eng. Structures*. 67, 123-141.
- Lee, S.H., Uy, B., Kim, S.H., Choi, Y.H. and Choi, S.M., 2011. Behavior Of High strength Circular Concrete-Filled Steel Tubular (CFST) Column Under Eccentric Loading. *J. Constr. Steel Res.*, 67, 1-13. <https://doi.org/10.1016/j.jcsr.2010.07.003>.
- Li, J. and Yang, E.H., 2018. Probabilistic-Based Assessment For Tensile Strain-Hardening Potential Of Fiber-Reinforced Cementitious Composites. *Cement and Concrete Composites*, 91, 108-117.
- Liu, D.L., Gho, W.M. and Yuan, J., 2003. Ultimate Capacity Of High-Strength Rectangular Concrete-Filled Steel Hollow Section Stub Columns. *J Constr Steel Res.*, 59 (12), 1499-1515. [https://doi.org/10.1016/S0143-974X\(03\)00106-8](https://doi.org/10.1016/S0143-974X(03)00106-8).
- Liu, D.L. and Gho, W.M., 2005. Axial Load Behaviour Of High strength Rectangular Concrete Filled Steel Tubular Stub Columns. *Thin Wall Struct.*, 43(8), 1131-1142. <https://doi.org/10.1016/j.tws.2005.03.007>.
- Lue, D.M., Liu, J.L. and Yen, T., 2007. Experimental Study On Rectangular CFST Columns With High-Strength Concrete. *J. Constr. Steel Res.*, 63(1), 37-44. <https://doi.org/10.1016/j.jcsr.2006.03.007>.

- Oshiro, T.M., Peres, P.S., and Baranauskas, J.A., 2012. How Many Trees in a Random Forest?. 8th International Conference on Machine Learning and Data Mining in Pattern Recognition, MLDM 2012, 7376, 54–168.
- O’Shea, M.D. and Bridge, R.Q., 1994. Tests On Thin-Walled Concrete-Filled Steel Tubes. Proceedings of the 12th International Specialty Conference on Cold-Formed Steel Structures, St. Louis, MO, USA, October, pp. 399-419.
- O’Shea, M.D. and Bridge, R.Q., 1998. Tests On Circular Thin-Walled Steel Tubes Filled With Medium And High Strength Concrete. Austral. Civil Eng. Transact., 40, 15-27.
- O’Shea, M.D. and Bridge, R.Q., 2000. Design Of Circular Thin-walled Concrete-Filled Steel Tubes. J. Struct. Eng., ASCE, 126(11), 1295-1303.
- Ren, Q., Li, M., Zhang, M., Shen, Y. and Si, W., 2019. Prediction Of Ultimate Axial Capacity Of Square Concrete-Filled Steel Tubular Short Columns Using A Hybrid Intelligent Algorithm. Appl. Sci., 9(14), 2802.
- Rodriguez, J. D., Perez, A., & Lozano, J. A., 2009. Sensitivity Analysis Of K-Fold Cross-Validation In Prediction Error Estimation. IEEE transactions on pattern analysis and machine intelligence, 32(3), 569-575.
- Sakino, K. and Hayashi, H., 1991. Behavior Of Concrete Filled Steel Tubular Stub Columns Under Concentric Loading. Proceedings of the 3rd International Conference on Steel Concrete Composite Structures, Fukuoka, Japan, September, pp.25-30.
- Sakino, K., Nakahara, H., Morino, S. and Nishiyama, I., 2004. Behavior Of Centrally Loaded Concrete-Filled Steel-Tube Short Columns. J. of Structural Engineering, 130(2), 180-188. [https://doi.org/10.1061/\(ASCE\)0733-9445\(2004\)130:2\(180\)](https://doi.org/10.1061/(ASCE)0733-9445(2004)130:2(180)).
- Sakino, K. and Sun, Y., 2000. Steel Jacketing For Improvement Of Column Strength And Ductility. Proceedings of the 12th World Conference on Earthquake Engineering, New Zealand.
- Schneider, S.P., 1998. Axially Loaded Concrete-Filled Steel Tubes. Journal of Structural Engineering, ASCE, 124(10), 1125-1138. [https://doi.org/10.1061/\(ASCE\)0733-9445\(1998\)124:10\(1125\)](https://doi.org/10.1061/(ASCE)0733-9445(1998)124:10(1125)).
- Tan, K.F., Pu, X.C. and Cai, S.H., 1999. Study On Mechanical Properties Of Extra Strength Concrete Encased In Steel Tubes. J. Build. Struct., 20(1), 10-15.
- Tomii, M., Yoshimura, K. and Morishita, Y., 1977. Experimental Studies On Concrete Filled Steel Tubular Stub Columns Under Concentric Loading. Proceedings of the International Colloquium on Stability of Structures, Washington DC, USA, May, pp. 718-741.
- Tran, V.L., Thai, D.K., and Nguyen, D.D., 2020. Practical Artificial Neural Network Tool For Predicting The Axial Compression Capacity Of Circular Concrete-Filled Steel Tube Columns With Ultra-High-Strength Concrete. Thin-Walled Structures 151 (2020) 106720.
- Uy, B., 2001. Strength Of Short Concrete Filled High Strength Steel Box Columns. Journal of Construction Steel Research, 57(2), 113-134. [https://doi.org/10.1016/S0143-974X\(00\)00014-6](https://doi.org/10.1016/S0143-974X(00)00014-6).
- Xiong, M.X., Xiong, D.X. and Liew, J.Y.R., 2017. Axial Performance Of Short Concrete Filled Steel Tubes With High-And Ultra-High- Strength Materials. Engineering Structures, 136, 494-510.
- Xu, F., Chen, J., Jin, W.L., 2014. Experimental Investigation Of Thin-Walled Concrete Filled Steel Tube Columns With Reinforced Lattice Angle. Thin-Walled Structure 84, 59–67.
- Yu, Z.W., Ding, F.X. and Cai, C.S., 2007. Experimental Behavior Of Circular Concrete filled Steel Tube Stub Columns. Journal of Construction Steel Research, 63, 165-174.
- Yu, Q., Tao, Z., Wu, Y.X., 2008. Experimental Behaviour Of High Performance Concrete Filled Steel Tubular Columns. Thin-Wall. Struct., 46(4), 362-370. <https://doi.org/10.1016/j.tws.2007.10.001>.
- Yamamoto, T., Kawaguchi, J. and Morino, S., 2000. Experimental Study Of Scale Effects On The Compressive Behavior Of Short Concrete-Filled Steel Tube Columns. Proceedings of the United Engineering Foundation Conference on Composite Construction in Steel and Concrete IV (AICE), Banff, Canada, June, pp. 879-891.
- Yuvaraj, P., Murthy, A.R., Iyer, N.R., Samui, P. and Sekar, S.K., 2013. Multivariate Adaptive Regression Splines Model To Predict Fracture Characteristics Of High Strength And Ultra High Strength Concrete Beams. CMC: Computers, Materials & Continua, 36(1), 73-97.