



Research Paper / Makale

**Makine Öğrenmesi Algoritmaları ile Betonarme Kirişlerin
Burulma Momenti Tahmini**

Gamze DOĞAN^{1a}

Civil Engineering Department, Konya Technical University, Konya, Türkiye
gdogan@ktun.edu.tr

Received/Geliş: 03.12.2021

Accepted/Kabul: 01.03.2022

Öz: Bu çalışmada betonarme kiriş deneylerinden elde edilen burulma dayanımı değerlerinin, deneysel çalışmaya gerek duyulmadan yapay zekâ algoritmaları ile tahmini amaçlanmıştır. Bu kapsamda yapılan kiriş deney verileri ile bir veri havuzu oluşturulmuş ve bu veriler ile makine öğrenmesi regresyon algoritmaları geliştirilmiştir. Deneysel çalışmalarda yer alan kiriş boyutları, beton dayanımı, etriye dayanımı, etriye kolları arası mesafe ve aralığı, etriye ve boyuna burulma donatısı akma dayanımı, etriye ve boyuna donatı oranı ile boyuna burulma donatısı alanı verileri algoritmalar için giriş parametreleri olarak, burulma dayanımı değeri ise çıkış (hedef) parametresi olarak seçilmiştir. Regresyon algoritması olarak Çoklu Lineer Regresyon, Destek Vektör Regresyon, Karar Ağaçları ve Rassal Orman algoritma modelleri seçilmiştir. Sonuç olarak ise betonarme kirişlerde malzeme ve kesit özelliklerinin bilinmesi ile burulma dayanımının tahmini için en iyi sonucu %97,59 tahmin başarı oranı ile Destek Vektör Regresyon modeli vermiştir.

Anahtar Kelimeler: kiriş burulma momenti; makine öğrenmesi, regresyon algoritmaları.

**Estimation of Torsional Moment of Reinforced Concrete Beams
with Machine Learning Algorithms**

Abstract: In this study, it is aimed to estimate the torsional strength values obtained from reinforced concrete beam tests with artificial intelligence algorithms without the need for experimental work. In this context, a data pool was created with the beam test data and machine learning regression algorithms were developed with these data. The beam dimensions, concrete compressive strength, stirrup strength, distance and spacing between stirrup arms, yield strength of stirrups and longitudinal torsion reinforcement, ratio of stirrups and longitudinal reinforcement, and longitudinal torsion reinforcement area data included in the experimental studies are input parameters for the algorithms, and the torsional strength value is output (target) selected as the parameter. Multiple Linear Regression, Support Vector Regression, Decision Trees, and Random Forest algorithm models were chosen as regression algorithms. As a result, the Support Vector Regression model gave the best result with a prediction success rate of 97.59 % for the estimation of the torsional strength by knowing the material and section properties of reinforced concrete beams.

Keywords: beam torsion moment; machine learning; regression algorithm.

1. Giriş

Sistem geometrisi ve simetrik olmayan yükleme etkileri sebebiyle meydana gelen burulma momenti yapılar da diğer etkilere (eğilme, kesme) ek olarak oluşur. Burulma momentinin yapı elemanı için en önemli etkisi eleman üzerinde kesme gerilmeleri oluşturmasıdır. Gerilmeler ile çekme dayanımı düşük olan betonarme elemanlarda asal çekme gerilmelerine dik yönde çekme çatlakları oluşur ve

How to cite this article


Doğan, G., "Makine Öğrenmesi Algoritmaları ile Betonarme Kirişlerin Burulma Momenti Tahmini", El-Cezeri Fen ve Mühendislik Dergisi, 2022, 9 (2); 912-924.

Bu makaleye atıf yapmak için

Özdemir C., Öztürk S., Şengül Ö., Kuncan F., "Estimation of Torsional Moment of Reinforced Concrete Beams with Machine Learning Algorithms" El-Cezeri Fen ve Mühendislik Dergisi 2022, 9 (2); 912-924.
ORCID: 0000-0002-0339-8048

bu çatlaklar genişledikçe elemanın göçmesine sebep olur. Şekil 1’de betonarme kirişe etki eden burulma momenti ve oluşturacağı olası çatlak dağılımı şematik olarak gösterilmiştir. Kesitte burulma çatlaklarının oluşması ile burulma rijitliği azalmaktadır.

Betonarme kesitlerde burulma etkilerini azaltmak için çekme gerilmelerini karşılayabilecek nitelikte enine donatı ve burulma donatısı yerleştirilmelidir [1]. Kirişlerde burulma momenti ise özellikle saplama kiriş modellerinde sıklıkla görülmektedir. Kiriş uçlarında oluşan eğilme momentleri saplandığı kirişte burulma momenti oluşturabilmektedir. Burulma momenti hesabı yönetmeliklerde betonarme kesit alanı hesaplarına bağlı olarak Tablo 1’de verilmiştir [2].



Şekil 1. Kiriş üzerinde burulma davranışı-hasar oluşumu

Tablo 1. Yönetmeliklere Göre Burulma Dayanımı Hesabı

Referans	Formül	Simgeler
ACI 318 [3]	$T = f_y \cdot \left(\frac{A_{sw}}{S} \right) \cdot 2A_o \cot \theta$	<ul style="list-style-type: none"> ▪ f_y = çelik akma dayanımı ▪ A_{sw} = etriye alanı ▪ S = etriye aralığı ▪ A_o = etriye çubuğu kesit alanı ▪ θ = dönme açısı ▪ $\cot \theta = \sqrt{\frac{A_l f_{yl} S}{A_{sw} f_y \rho_h}}$ A_l = boyuna burulma donatısı alanı ρ_h = enine burulma takviye donatısı çevresi
Eurocode-2 [4]	$T = 2A_k \cdot \sqrt{\frac{A_{sw} \cdot f_{ywd}}{S}} \cdot \sqrt{\frac{A_{sl} \cdot f_{yld}}{u_k}}$	<ul style="list-style-type: none"> ▪ A_k = Boyuna donatılar arası kiriş kesiti ▪ f_{ywd} = etriye dizayn dayanımı ▪ A_{sl} = boyuna donatı kesit alanı ▪ f_{yld} = boyuna donatı akma dayanımı ▪ u_k = boyuna donatılar sınırı kesit çevresi
BS110 [5]	$T = \frac{A_{sv} 0.8x_1y_1 (0.87f_{ys})}{S}$	<ul style="list-style-type: none"> ▪ A_{sv} = iki etriye arası kesit alanı ▪ x_1 = etriye kolu kısa kenar uzunluğu ▪ y_1 = etriye koluuzun kenar uzunluğu
TS 500 [6]	$T = \frac{A_{sw} 2A_k f_{ywd}}{S}$	<ul style="list-style-type: none"> ▪ A_{sw} = Burulma için gerekli etriye alanı ▪ A_k = Kesit köşelerindeki donatı merkezlerini birleştiren sınır içinde kalan alan. Kutu kesitlerde duvar kalınlığı ortasından geçen çevre içinde kalan alan

Betonarme elemanlarda eğilme ve kesme kuvveti nedeni ile oluşan etkiler, kesit üzerinde burulmanın varlığı ile daha da karmaşık bir problem oluşturur. Burulma momenti hesapları bu anlamda zorlayıcıdır. Burulma dayanımının belirlenmesinde çözüm kolaylığı sağlayabilmek için yapay zekâ yöntemleri bu çalışma kapsamında sınanmıştır. Çalışmada betonarme kirişler üzerinde yapılan deneyler neticesinde belirlenen burulma dayanımının; benzer üretim parametreleri bilinmesi koşuluyla yapay zekâ algoritmaları ile belirlenmesi amaçlanmaktadır. Bu kapsamda kirişler

üzerinde yapılan deneysel çalışmalar derlenerek algoritma geliştirmek üzere veri seti oluşturulmuştur. Arslan'ın [7] ve Çevik ve arkadaşlarının [8] yaptığı çalışmada literatürde yapılan giriş deneyleri [3, 9-13] parametreleri ve elde edilen burulma dayanımı değerleri makine öğrenmesi algoritmalarının eğitilmesi ve tahmin başarılarının test edilmesi için kullanılmıştır.

2. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi (ML) insandan insana bilgi aktarım sürecinin benzer nitelikte makineler tarafından gerçekleştirilmesi işlemidir. Bu işlem için veriler aracılığıyla bir eğitim modeli oluşturulup sistemin karar verme niteliği geliştirilmektedir. Böylelikle bir öğrenme sağlanarak daha sonra sisteme benzer veriler sunulduğunda başarılı tahmin ya da başarılı bir kategorizasyon yapması beklenmektedir. Kısacası insan fizyolojisinde mümkün olan eğitim ve öğrenme süreçlerinin geliştirilen algoritmalar sayesinde makineler üzerinde gerçekleştirilmesi olarak tanımlanabilmektedir.

ML problemin niteliğine göre çözüm üretme esaslı bir algoritma sistemidir. Algoritma kurulurken giriş ve çıkış verilerinin ağ yapısına nasıl tanıtılacağı bir ağ modelinin kodlamadaki başarısı için önemlidir. ML algoritmaları sınıflandırma, tahmin ve obje tanıma gibi işleri yapabilmemize olanak tanımaktadır. Bu işlemler için verilerin eğitim durumuna göre ML gözetimli (eğitilmiş) ve gözetimsiz (eğitimsiz) öğrenme olarak ikiye ayrılmaktadır. Gözetimli öğrenme, eğitim verilerine bağlı sonuç (çıkış) üreten ML branşıdır. Regresyon (tahmin) ve sınıflandırma bir gözetimli öğrenme metodudur. Bu çalışmada veriler için tahmin problemi üzerinde çalışılacağı için ML için regresyon algoritmaları kullanılmıştır. Regresyon algoritmaları ve algoritma sonucu elde edilen başarının yorumlanmasını sağlayan metrikler de bu bölüm kapsamında anlatılacaktır.

2.1. Regresyon (tahmin) Algoritmaları

Regresyon tabanlı makine öğrenmesi algoritmaları, veriler için bilinmeyen değerlerin tahmini için kullanılmaktadır. Özellikle mühendislik problemlerinde veriler arasındaki ilişkiyle bağlantılı bir regresyon algoritması ile çözüm aranabilmektedir. Algoritmanın eğitimi ile öğrenebilen ağlar yeni verileri tanıyabilmekte ve veriye ait değerleri tahmin edebilmektedir. Regresyon birden fazla değişken arasındaki ilişkiyi tanımlamaktadır. Bağımlı değişken (y) ve bağımsız değişken (x) olması durumunda (y)'nin (x)'e bağlı bir fonksiyonu olarak tanımlanan regresyon metodu, verideki değişkenler arasındaki fonksiyon türüne göre çeşitlendirilmektedir. Bu bölümde Lineer Regresyon (Basit-Çoklu), Karar Ağacı, Rassal Orman ve Destek Vektör Regresyon modellerinden bahsedilecektir.

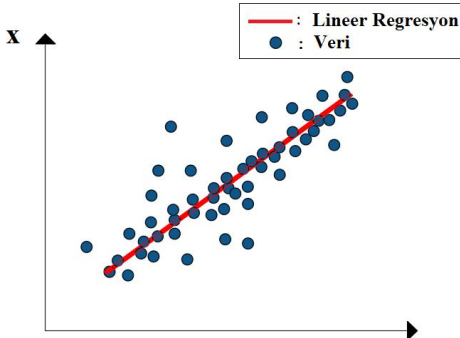
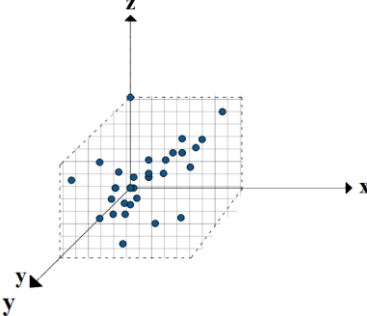
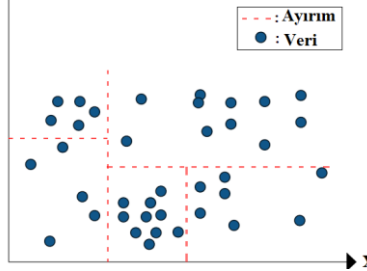
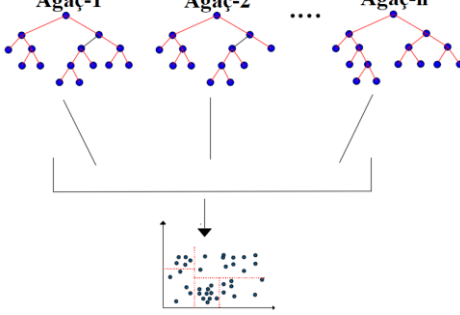
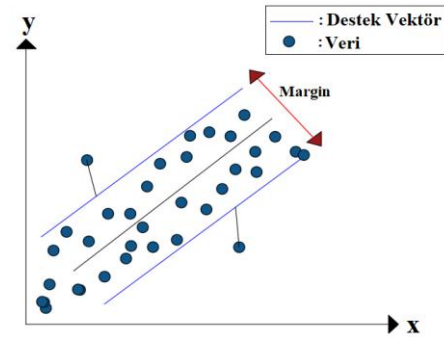
Basit Lineer Regresyon; (x) ve (y) arasındaki ilişkinin doğrusal bir yayılım gösterdiği istatistik tabanlı bir algoritmadır (Denklem 1). Giriş verisi bağımsız (x) değişkeni, çıkış verisi ise (x)'e bağlı bir bağımlı (y) değişkeni olarak isimlendirir ve (y) değişkeni yalnızca bir (x) değişkenine bağlı olmaktadır. Eğer bağımlı değişken (y) birden fazla bağımsız değişkene (x) bağlı ise Çoklu Lineer Regresyon algoritması kullanılmalıdır (Denklem 2).

$$y = ax + b \quad (1)$$

$$y = ax_1 + bx_2 + cx_2 \dots + d \quad (2)$$

Karar ağaçları, tıpkı bir ağacın kökten yapraklara uzanan fizyolojisi gibi giriş verisinin daha küçük kümelerle ayrılması ile kurgulanan bir algoritmadır. Bu kümeleme işleminde verinin özellikleri esastır ve aynı türden verilerin yer aldığı düğümler bir küme oluşturabilir.

Tablo 2. Makine Öğrenmesi Regresyon Algoritma Modelleri

Algoritma Modeli	Grafik	Avantajı	Dezavantajı
Basit Doğrusal Regresyon		Veri boyutundan bağımsız olarak doğrusal ilişki üzerine kurulur.	Doğrusallık kabulü aynı zamanda hatadır.
Çoklu Doğrusal Regresyon		Anlaşılabilir, ölçeklemeye ihtiyaç duymaz, doğrusal veya doğrusal olmayan problemlerde çalışır.	Sonuçlar sabitlenmiştir, küçük veri kümelerinde ezberleme olması yüksek ihtimaldir.
Karar Ağacı		Ölçeklenmeye ihtiyaç duymaz, doğrusal veya doğrusal olmayan problemlerde çalışır, ezber veya sabit sonuç riski düşüktür.	Çıktıların yorumu ve görselleşmesi nispeten zordur.
Rassal Orman		Kernel seçimine göre Doğrusal veya doğrusal olmayan modellerde çalışır, marjinal değerlere karşı ölçekleme ile dayanıklı olur.	Ölçekleme önemlidir, anlaşılması nispeten karışıktır, doğru kernel fonksiyonu seçimi önemlidir.
Destek Vektör Regresyon			

Algoritma yapısal olarak kök, karar ve yaprak düğümlerinden oluşur. Kök düğümü başlangıç olarak tüm veri setini temsil etmektedir. Kök düğümden sonra veri kümelerine ayrılır. Kümelenen veri daha

alt gruplara ayrılabilirse karar düğümü olarak nitelendirilebilir. Algoritma yapısındaki bölünemeyen en alt düğüm ise yaprak düğümü olarak bilinmektedir [14]. Rassal Orman, birden çok karar ağaçlarının aynı veri kümesi için bir araya gelmesi ile sonuç üreten birleşik bir algoritmadır. Bu metotta karar ağaçlarının veri tahmin başarısı değerlendirilerek oluşturulan orman içinden en optimum veri başarısı sonuç olarak belirlenir. Algoritma oluşturulurken önemli parametrelerden biri orman oluşturan karar ağacı sayısıdır.

Destek Vektör Regresyon (DVR) Vapnik [15] tarafından sınıflandırma ve regresyon analizi için geliştirilen istatistiksel bir gözetimli öğrenme metodudur. Veri setindeki iki farklı grubu birbirinden ayırabilecek en uygun hiper düzlem (sınır çizgisi) belirlenir ve bu çizgiye en yakın destek vektörler çizilerek uygun bir marjin aralığı oluşturulur. Bu aralığın dışında kalan veriler ise tahminde başarısız sayılmaktadır. DVR için doğrusal bir veri seti mevcutsa, daha küçük bir marjin aralığı elde etmek için çekirdek fonksiyonu (kernel) olarak “linear” kullanmak daha doğru olacaktır. DVR algoritmasını diğer algoritmalara göre verilerde hassasiyet göstermektedir. Ölçek olarak farklı boyutlarda veri içeren bir veri seti var ise veriler için bir standart ölçeklendirme yapmak gereklidir. Örnek olarak bir eğitim kümesinde 1-8 arasında ve 3000-7000 arasında değişken farklı bağımsız değişkenler mevcut ise DVR algoritması doğru sonuçlar üretmeyebilir. Bu sebeple ölçeklendirme parametresi “StandartScaler” kullanılarak veriler bir ön işlemden geçirilir ve veri seti ölçeklenir. Makine öğrenmesi regresyon algoritma model grafikleri, model avantaj ve dezavantaj durumları ile birlikte kısa özeti Tablo 2’de verilmiştir.

2.2. Tahmin (başarı) Metrikleri

Makine öğrenmesi modellerinin performansını değerlendirmek için çeşitli başarı ölçütleri mevcuttur. Sınıflandırma ve regresyon modelleri için farklı türde başarı metrikleri vardır. Başarı metrikleri istatistik tabanlı olarak ortaya çıkmıştır. Metriklerden bu çalışmada kullanılan R-kare (R^2), korelasyon katsayısının karesi bir değer olup 0 ile 1 arasındadır. R^2 değeri yüzde (%) değer olarakta verilebilmektedir. R^2 model başarısının bir değeri olup, yüksek R^2 değeri modelin uyumlu olduğunu göstermektedir (Denklem 3). Hata/başarı metrikleri Python [16] yazılımında sklearn kütüphanesi metrics sınıfında çeşitlendirilmiştir. Python’da bir modeldeki R^2 başarısını elde edebilmek için “score()” metodu kullanılır.

Doğrusal veri setinin kullanıldığı modellerde başarı ölçütü bir başka metrik ise ortalama hata karelerinin karekökü (root mean square error (RMSE)) değeridir. Bu değer istatistiksel hesabı Denklem 4’te gösterilmiştir. Modelde başarının iyi olması için RMSE değerinin düşük olması beklenmektedir. Python yazılımında bu değeri hesap edebilmek için mean_squared_error() fonksiyonu kullanılır fakat elde edilen bu sonuç ortalama hata karelerini vereceği için elde edilen değerinde karekökünü almak gerekir. Python kodlarından elde edilen RMSE değerinin yüksek ya da düşük olduğunu anlamak için bağımlı değişken (y) değerlerinin standart sapması ile karşılaştırılarak bu değerden daha düşük olması beklenmektedir. Eğer RMSE değeri bağımlı değişken standart sapma değerinden düşük ise modelin başarılı olduğu söylenebilmektedir [17].

Regresyon algoritmalarında sıklıkla kullanılan bir diğer başarı ölçütü ise Ortalama Mutlak Hata (Mean Absolute Error- MAE) metriğidir (Denklem 5). İki değişken arasındaki farkı temsil eden MAE metriği, veri ile veriye en uyan çizgi arasındaki yatay mesafeyi temsil etmekte, 0-∞ arası değerler alabilmektedir. Algoritma model başarısının iyi olması için MAE değerinin düşük olması beklenmektedir.

$$R^2 = 1 - \frac{\sum_i (y_i - \bar{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{n}} \quad (4)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \bar{y}_i|}{n} \quad (5)$$

Denklemlerde n veri sayısını, y_i bağımlı değişkenin gözlemlenen değerini, değerini, \bar{y}_i ise model sonucu tahmin edilen değeri temsil etmektedir.

3. Analitik Çalışma

3.1. Veri Setinin Oluşturulması

Çalışma kapsamında betonarme kirişler üzerinde yapılan deneyler neticesinde belirlenen burulma dayanımının; benzer üretim parametreleri bilinmesi koşuluyla yapay zekâ algoritmaları ile belirlenmesi amaçlanmaktadır. Bu amaç doğrultusunda literatürde betonarme kirişler için burulma dayanımının belirlendiği deneysel çalışmalara ait veriler derlenmiştir. Deneysel çalışmalar için Arslan'ın [7] ve Çevik ve arkadaşlarının [8] çalışmalarında yer alan çalışmalardaki [3, 9-13] kiriş burulma deney verileri düzenlenmiştir. Kiriş deneylerine ait veriler Tablo 3'te verilmiştir. Deneysel çalışmalarda yer alan kiriş boyutları, beton dayanımı, etriye dayanımı, etriye kolları arası mesafe ve aralığı, etriye ve boyuna burulma donatısı akma dayanımı, etriye ve boyuna donatı oranı ile boyuna burulma donatısı alanı verileri algoritmalar için giriş parametreleri olarak, burulma dayanımı değeri ise çıkış (hedef) parametresi olarak seçilmiştir.

3.2. Makine Öğrenmesi Uygulaması

Betonarme kirişlerde belirli parametrelere bağlı olarak burulma momenti tahmini için yapay zekâ yöntemlerinden olan makine öğrenmesi algoritmaları kullanılmıştır. Çalışmada betonarme kiriş kesit ve malzeme bilgilerine bağlı olarak yapılan deney verilerine bağlı olarak burulma dayanımları tahmin edilmiştir. Bu sebeple çalışmada makine öğrenmesi regresyon (tahmin) algoritmalarından “Çoklu doğrusal regresyon”, “Karar ağaçları”, “Rassal orman” ve “Destek vektör regresyonu” kullanılmıştır.

Algoritmanın kodlama işlemi açık kaynak kodlu Python 3.7 yazılım programında gerçekleştirilmiştir. İlk olarak yazılım üzerinde gerekli kütüphanelerden Numpy ve Pandas kütüphaneleri veriyi işlemek üzere Python ortamına yüklenmiştir. Ardından veriler üzerinde eğitim ve tahmin yapabilmek için Sci-Kit Learn (sklearn) kütüphanesi kullanılmıştır. Sklearn kütüphanesinin “fit ()” fonksiyonu ile veriler eğitilmiş, “predict ()” fonksiyonu ile tahminde bulunulmuştur.

Veriler ilk olarak CSV (Comma Separated Values-Virgülle ayrılmış değerler) dosyası olarak Python ortamında okunmuştur. Veri seti eğitim ve test olmak üzere bölütlenmiştir. Tahmin algoritmaları eğitim seti kullanılarak eğitilmekte ve algoritmanın bu şekilde öğrenmesi sağlanmaktadır. Algoritmada daha sonra test verisi kullanılarak model tahmin başarısı test edilmektedir. Verilerde rassal ayırma (random split) yöntemi kullanılarak 0.33 gibi bir oranda test verisi boyutu belirlenmiştir. Bunun anlamı şudur; tüm verilerin yaklaşık 2/3'lük bir kısmı eğitim seti olarak 1/3'ü ise test seti olarak rastgele ayrılmıştır. Bu sebeple 76 adet kiriş deney verisinden 51 veri eğitim seti, 25 veri ise test seti olarak rastgele ayrılmıştır.

Tablo 3. Betonarme kirişler burulma deney verileri [3, 7-13]

Kiriş kısa boyu (mm)	Kiriş uzun boyu (mm)	Etriye kolları arası kısa mesafe (mm)	Etriye kolları arası uzun mesafe (mm)	Beton dayanımı f_c (MPa)	Etriye aralığı S (mm)	Etriye alanı A_{sw} (mm ²)	Etriye akma dayanımı f_{ywd} (MPa)	Burulma donatısı alanı A_l (mm ²)	Burulma donatısı akma dayanımı f_{yl} (MPa)	Enine donatı oranı ρ_{sw} (%)	Burulma donatısı oranı ρ_l (%)	Burulma dayanımı T (kN,m)
350	500	300	450	78,5	100	71,33	440	1196,6	440,00	0,61	0,68	92,0
350	500	300	450	78,5	100	71,33	440	2027,2	410,00	0,61	1,16	115,1
350	500	300	450	78,5	50	71,33	440	2027,2	410,00	1,22	1,16	155,3
350	500	300	450	78,5	50	71,33	440	2865,0	520,00	1,22	1,64	196,0
350	500	300	450	78,5	55	126,7	440	3438,0	560,00	1,97	1,96	239,0
350	500	300	450	68,4	90	71,33	420	1719,0	500,00	0,68	0,98	126,7
350	500	300	450	68,4	80	126,7	360	1719,0	500,00	1,36	0,98	135,2
350	500	300	450	68,4	90	71,33	440	2865,0	500,00	0,68	1,64	144,5
350	500	300	450	35,5	100	71,33	440	1191,6	440,00	0,61	0,68	79,7
350	500	300	450	35,5	100	71,33	440	2027,2	410,00	0,61	1,16	95,2
350	500	300	450	35,5	50	71,33	440	2027,2	410,00	1,22	1,16	116,8
350	500	300	450	35,5	50	71,33	440	2865,0	520,00	1,22	1,64	138,0
350	500	300	450	35,5	55	126,70	440	3438,0	560,00	1,97	1,96	158,0
350	500	300	450	35,5	90	71,33	420	1719,0	500,00	0,68	0,98	111,7
350	500	300	450	35,5	80	126,70	360	1719,0	500,00	1,36	0,98	125,0
350	500	300	450	35,5	90	71,33	420	2865,0	500,00	0,68	1,64	117,3
203	305	165	267	39,6	108	71,33	373	506,8	380,00	0,92	0,82	19,4
203	305	165	267	64,6	108	71,33	399	506,8	380,00	0,92	0,82	18,9
203	305	165	267	75	108	71,33	373	506,8	380,00	0,92	0,82	21,1
203	305	165	267	80,6	108	71,33	399	506,8	380,00	0,92	0,82	19,4
203	305	165	267	93,9	108	71,33	386	506,8	380,00	0,92	0,82	21,0
203	305	165	267	76,2	102	71,33	386	506,8	380,00	0,98	0,82	18,4
203	305	165	267	72,9	95	71,33	386	649,4	373,00	1,05	1,05	22,5

203	305	165	267	75,9	90	71,33	386	760,2	373,00	1,11	1,23	23,7
203	305	165	267	76,7	70	71,33	386	794,4	380,00	1,42	1,28	24,0
160	275	130	245	41,7	90	78,54	665	1543,9	620,00	1,49	3,51	16,6
160	275	130	245	38,2	90	78,54	669	1543,9	638,00	1,49	3,51	15,3
160	275	130	245	36,3	90	78,54	672	1543,9	605,00	1,49	3,51	15,3
160	275	130	245	61,8	90	78,54	665	1543,9	612,00	1,49	3,51	20,0
160	275	130	245	57,1	90	78,54	665	1543,9	614,00	1,49	3,51	18,5
160	275	130	245	61,7	90	78,54	665	1543,9	612,00	1,49	3,51	19,1
160	275	130	245	77,3	90	78,54	658	1543,9	617,00	1,49	3,51	20,1
160	275	130	245	76,9	90	78,54	656	1543,9	614,00	1,49	3,51	20,7
160	275	130	245	76,2	90	78,54	663	1543,9	617,00	1,49	3,51	21,0
160	275	130	245	109,8	90	78,54	655	1526,8	618,00	1,49	3,51	24,7
160	275	130	245	105	90	78,54	660	1526,8	634,00	1,49	3,51	23,6
160	275	130	245	105,1	90	78,54	655	1543,9	629,00	1,49	3,51	24,8
254	381	215,9	342,9	27,58	152,4	71,33	341,29	508,0	313,71	0,54	0,52	22,3
254	381	215,9	342,9	28,61	181,1	126,70	319,92	635,0	316,47	0,81	0,66	29,3
254	381	215,9	342,9	28,06	127,0	126,70	319,92	762,0	327,5	1,15	0,79	37,5
254	381	215,9	342,9	30,54	92,2	126,70	323,56	889,0	319,92	1,59	0,92	47,3
254	381	215,9	342,9	29,03	69,9	126,70	321,3	1016,0	332,33	2,09	1,05	56,2
254	381	215,9	342,9	28,82	57,2	126,70	322,67	1143,0	331,64	2,56	1,18	61,7
254	381	215,9	342,9	25,99	127,0	126,70	318,54	508,0	319,92	1,15	0,52	26,9
254	381	215,9	342,9	26,75	57,2	126,70	319,92	508,0	321,99	2,56	0,52	32,5
254	381	215,9	342,9	28,82	152,4	126,70	342,67	762,0	319,23	0,96	0,79	29,8
254	381	215,9	342,9	26,48	152,4	126,70	341,98	1143,0	334,40	0,96	1,18	34,4
254	381	215,9	342,9	26,61	152,4	71,33	337,84	508,0	333,02	0,54	0,52	22,4
254	381	215,9	342,9	25,58	181,1	126,70	330,95	635,0	322,67	0,81	0,66	27,7
254	381	215,9	342,9	28,41	127,0	126,70	333,02	762,0	341,67	1,15	0,79	40,2

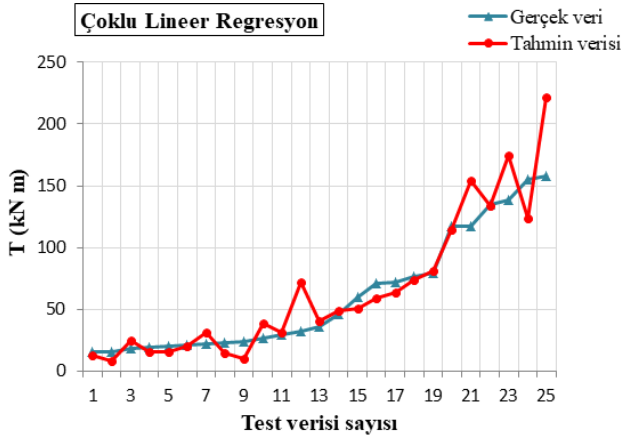
254	381	215,9	342,9	30,61	92,2	126,70	333,02	889,0	330,26	1,59	0,92	47,9
254	381	215,9	342,9	29,85	149,4	71,33	353,01	635,0	326,12	0,55	0,66	30,4
254	381	215,9	342,9	30,54	104,9	71,33	357,15	762,0	328,88	0,79	0,79	40,6
254	381	215,9	342,9	26,75	139,7	126,70	326,12	889,0	321,99	1,05	0,92	43,8
254	381	215,9	342,9	26,54	104,9	126,70	326,81	1016,0	318,54	1,39	1,05	49,6
254	381	215,9	342,9	27,99	82,6	126,70	330,95	1143,0	335,09	1,77	1,18	55,7
254	381	215,9	342,9	29,37	69,9	126,70	340,6	2288,0	317,85	2,09	2,36	60,1
254	381	215,9	342,9	45,23	98,6	71,33	348,87	635,0	325,43	0,84	0,66	36,0
254	381	215,9	342,9	44,75	127	126,70	333,71	762,0	343,36	1,15	0,79	45,6
254	381	215,9	342,9	44,95	92,2	126,70	326,12	889,0	315,09	1,59	0,92	58,1
254	381	215,9	342,9	45,02	69,9	126,70	325,43	1016,0	310,26	2,09	1,05	70,7
254	381	215,9	342,9	45,78	57,2	126,70	328,88	1143,0	325,43	2,56	1,18	76,7
254	508	215,9	469,9	29,79	187,5	71,33	339,22	508,0	321,99	0,4	0,39	26,8
254	508	215,9	469,9	30,89	120,7	71,33	333,71	635,0	322,67	0,63	0,49	40,3
254	508	215,9	469,9	26,82	155,7	126,70	327,5	762,0	338,53	0,87	0,59	49,6
254	508	215,9	469,9	28,27	114,3	126,70	341,98	889,0	325,43	1,18	0,69	64,9
254	508	215,9	469,9	26,89	85,9	126,70	327,5	1016,0	330,95	1,57	0,79	72,0
254	508	215,9	469,9	29,92	127,0	126,70	349,56	1144,0	334,40	1,06	0,89	39,1
254	508	215,9	469,9	30,96	146,1	126,70	322,67	1430,0	319,23	0,92	1,11	52,7
254	508	215,9	469,9	28,34	104,9	126,70	328,88	1716,0	321,99	1,28	1,33	63,3
254	508	215,9	215,9	27,03	215,9	71,33	341,29	381,0	341,29	0,22	0,3	11,3
254	508	215,9	215,9	26,54	117,6	71,33	344,74	508,0	334,40	0,41	0,39	15,3
254	508	215,9	215,9	26,89	139,7	126,70	329,57	635,0	330,95	0,61	0,49	20
254	508	215,9	215,9	27,17	98,6	126,70	327,5	762,0	336,46	0,86	0,59	25,3
254	508	215,9	215,9	27,23	73,2	126,70	328,88	889,0	328,19	1,16	0,69	29,7
254	508	215,9	215,9	27,58	54,1	126,70	327,5	1016,0	315,78	1,57	0,79	34,2

Tablo 4. Betonarme kirişler için deneysel ve tahmin burulma dayanım sonuçlarının karşılaştırılması (ML algoritmaları)


$T_{\text{Gerçek (deneysel)}}$ (kN.m)	T_{Tahmin} (kN.m)			$T_{\text{Gerçek-ölçekli}}$ (deneysel) (kN.m)	$T_{\text{Tahmin-ölçekli}}$ (kN.m)
	Çoklu Liner Regresyon Tahmin Verisi	Karar Ağacı Tahmin Verisi	Rassal Orman Tahmin Verisi	DVR Test verisi	DVR Tahmin Verisi
15,3	13,0	19,4	22,4	-0,9679	-0,9725
15,3	8,0	18,5	18,7	-0,9679	-1,2872
18,4	25,0	21,0	21,6	-0,9024	-0,8022
19,1	15,2	20,0	19,2	-0,8876	-0,9449
20,0	15,3	25,3	23,1	-0,8686	-0,9230
21,0	19,8	20,0	20,2	-0,8475	-0,7471
22,4	31,3	30,4	28,7	-0,8179	-0,9177
22,5	14,1	24,0	22,8	-0,8158	-0,8036
23,7	10,0	24,0	22,8	-0,7905	-0,7264
26,9	38,2	40,3	40,3	-0,7229	-0,7585
29,7	31,5	25,3	28,7	-0,6638	-0,6360
32,5	72,2	61,7	46,9	-0,6046	-0,1831
36,0	40,0	40,3	39,9	-0,5307	-0,5044
45,6	48,4	40,2	39,9	-0,3279	-0,4284
60,1	50,8	56,2	122,0	-0,0217	0,0784
70,7	58,5	56,2	55,5	0,2021	-0,0017
72,0	63,5	64,9	48,2	0,2296	0,2948
76,7	73,7	61,7	52,8	0,3289	0,2286
79,7	81,5	92,0	78,8	0,3922	0,7772
116,8	113,9	196,0	117,0	1,1758	1,2757
117,3	153,9	144,5	152,4	1,1864	1,2862
135,2	133,4	126,7	126,3	1,5645	1,5401
138,0	174,5	196,0	183,0	1,6236	1,5232
155,3	123,4	196,0	131,8	1,9890	1,8703
158,0	221,28	239,0	219,1	2,0460	1,9464

Tablo 5. Algoritma Tahmin başarısı


Algoritma	Tahmin Metrikleri		
	R^2 (%)	MAE	RMSE
Çoklu Doğrusal Regresyon	81,75	12,95	20,23
Karar Ağaçları	63,33	17,24	28,67
Rassal Orman	76,08	14,54	23,15
Destek Vektör Regresyon	97,59	0,11	0,155



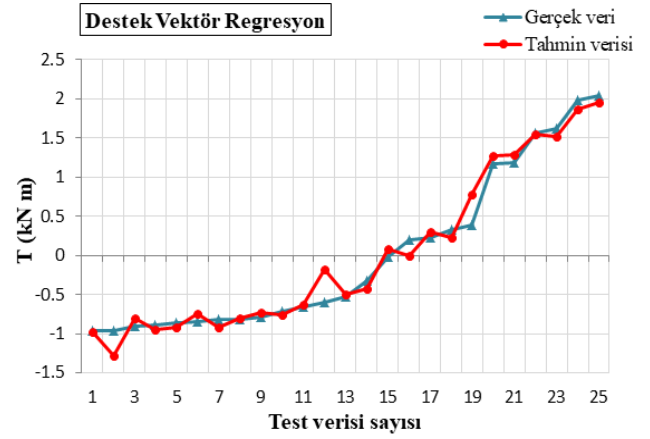
Şekil 2. Çoklu Linear Regresyon modeli grafiği



Şekil 3. Karar ağacı modeli grafiği



Şekil 4. Rassal Orman modeli grafiği



Şekil 5. Destek Vektör Regresyon modeli grafiği

Betonarme kirişlerde burulma momenti için literatürden elde edilen değerler doğrusal verilerdir. Bu sebeple regresyon algoritması olarak lineer modeller için tahmin yapabilen algoritmalar seçilmiştir. Bu algoritmalarından biri “lineer regresyon”dur. Lineer model olarak çıkış verisi birden fazla bağımsız giriş verisine bağlı olduğu için çoklu lineer (doğrusal) regresyon (ÇLR) modeli kullanılmıştır.

Destek Vektör Regresyon (DVR) algoritması için verilerin daha iyi tahminini sağlamak üzere veriler üzerinde standartlaştırma işlemi gerçekleştirilmiştir. Standart Scaler ölçeği ile veriler daha küçük ve tek tip veri niteliğine indirgenmiştir. DVR tahmin modeli için veri seti doğrusal olması sebebiyle “linear” çekirdek (kernel) kullanılmıştır.

Karar ağaçları algoritması yapı olarak diğer algoritmalarına benzemektedir. “Sklearn.tree” kütüphanesinden “DecisionTreeRegressor” sınıfından türetilmiş, veriler üzerinde “fit ()” metodu ile model oluşturulmuştur.

Rassal orman algoritması alt yapı olarak Karar Ağaçları algoritması kullanılmış, sklearn kütüphanesinde RandomForestRegressor sınıfından üretilen nesne ile “fit ()” ve “predict ()” fonksiyonları kullanılarak makine öğrenmesi gerçekleştirilmiştir. Tüm regresyon algoritmalarından elde edilen tahmin burulma dayanımı değerleri, gerçek (deneysel) veriler ile karşılaştırmalı olarak Tablo 4’te gösterilmiştir.

Eğitilmiş olan modellerin başarı performansı; “r2_score”, “mean_absolute_error”, “root_mean_square_error” metrikleri ile ölçülmüştür. Ölçüm için Numpy dizisi olan gerçek veriler ile predict () fonksiyonun çalıştığı modelden elde edilen tahmin verileri karşılaştırılmış ve modelin

ne kadar başarılı tahmin yaptığı başarı metrikleri ile sınanmıştır. Tablo 5'te kiriş burulma dayanımlarının makine öğrenmesi algoritmalarına göre tahmin başarısı gösterilmiştir. Betonarme kiriş burulma dayanımı için deneysel çalışma sonucu gerçek burulma değeri ile algoritmalarından elde edilen tahmin değerleri arasındaki yakınsama Çoklu Lineer Regresyon algoritması için Şekil 2'de, Karar Ağacı algoritması için Şekil 3'te, Rassal Orman algoritması için Şekil 4'te ve Destek Vektör Regresyon algoritması için ise Şekil 5'te gösterilmiştir. Yüksek başarı değeri olarak R^2 değerinin en yüksek MAE ve RMSE değerlerinin en düşük olduğu algortima modeli Destek Vektör Regresyon modeli olmuştur. DVR algoritmasından %97,59 gibi yüksek bir R^2 doğruluk oranı elde edilmiştir. Diğer başarı metriklerinden MAE ve RMSE değerleri sıfıra oldukça yakınsamış ve yüksek bir tahmin başarısı elde edilmiştir.

4. Sonuç

Bu çalışmada malzeme özellikleri ve kesitleri bilinen betonarme kirişler için burulma dayanımı tahmini yapabilen algoritma geliştirilmiştir. Deneysel verilerden elde edilen sonuçlar ile algoritma modelleri eğitilmiş ve eğitilen model üzerinde kiriş burulma dayanım değerinin tahmin başarısı sınanmıştır. Çalışmadan da görüldüğü gibi seçilen her algoritma problem çözümünde yeterli başarıya ulaşmamaktadır. Bu çalışmada veri setine göre en uygun sonucu DVR algoritması vermiştir.

Modellerin başarısının artırılması için; veri sayısının artırılmasına ihtiyaç vardır. Ayrıca algoritma parametrelerinde değişiklik yapılarakta (Rassal orman algoritmasında kaç adet karar ağacının alınacağı, lineer regresyonda hangi parametrelerin sisteme dâhil edileceği gibi) veriler üzerinden modeller yeniden sınanabilir.

Burada ayrıca önemli olan bir diğer konuda veri setinde bulunan verilerin dağılımıdır. Bu çalışmada dikkate alınan betonarme kirişlerde burulma dayanımını iyileştirecek çeşitli güçlendirme tekniklerini (ultra performanslı beton kullanımı, çeşitli lif içerikli kirişler) içeren modellerin yapılması gelecekte planlanan çalışmalardan olup önemli sonuçlar verecektir.

Teşekkür

Yazar makalede veri setinin oluşturmasında çalışmasıyla katkı sunan Prof.Dr. Musa Hakan Arslan'a teşekkür eder.

Yazarın Katkıları

Yazar makalede verilerin düzenlenmesi, algoritmaların oluşturulması, Python ortamında kodlama işlemleri ve analizleri gerçekleştirmiştir. Yazar makalenin son halini okumuş ve onaylamıştır.

Çıkar Çatışması

Yazar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. Ersoy, U., Canbay, E., Özcebe, G., 2019, Betonarme Cilt 1 Davranış ve Hesap İlkeleri, Evrim yayınları, ISBN: 9789755032399.
- [2]. Aydın, A.C., Bayrak, B., 2016, Kendiliğinden Yerleşen ve Normal Betonlu Betonarme Kirişlerin Burulma Davranışının Deneysel ve Teorik Olarak İncelenmesi, Sinop Uni J Nat Sci 1(1): 23- 32 (2016).

- [3]. ACI 318, Committee A, 2008, A.C. Institute, and I.O.f. Standardization, Building Code Requirements for Structural Concrete (ACI 318-08) and Commentary, American Concrete Institute.
- [4]. EuroCode-2, EN, B., 1-2: 2004, Eurocode 2: Design of Concrete Structures-Part 1-2: General Rules-Structural Fire Design, European Standards, London, 2004.
- [5]. BS 8110 Rowe, R.E., Handbook to British Standard BS 8110: 1985: Structural Use of Concrete 1987, Palladian Publications.
- [6]. TS500, 2000, TS500 Betonarme Yapıların Tasarım ve Yapım Kuralları, 2000, Türk Standartları Enstitüsü, Ankara, Türkiye.
- [7]. Arslan, M.H., 2010, Predicting of Torsional Strength of RC Beams by Using Different Artificial Neural Network Algorithms and Building Codes, *Advances in Engineering Software* 41 (2010) 946–955.
- [8]. Cevik, A., Arslan, M.H., Koroglu, M.A., 2010, Genetic-Programming Based Modeling of RC Beam Torsional Strength, *KSCE J Civil Eng* 2010;14(3):371–84.
- [9]. Victor, D.J., Muthukrishnan, R., 1973, Effect of Stirrups on Ultimate Torque of Reinforced Concrete Beams, *ACI J* 1973;70–32:300–6.
- [10]. McMullen, A.E., Rangan, B.V., 1978, Pure Torsion in Rectangular Section-A Reexamination, *ACI J* 1978;75(52):511–9.
- [11]. Koutchoukali, N.E., Belarbi, G., 2001, Torsion of High Strength Reinforced Concrete Beams and Minimum Reinforcement Requirement, *ACI Struct J* 2001;98(4):462–9.
- [12]. Collins, C.P., Mitchell, D., 1980, Shear and Torsion Design of Prestressed and Nonprestressed Concrete Beams, *PCI J* 1980;25(5):32–100.
- [13]. ACI Committee 318-95, 1995, Building Code Requirements for Structural Concrete and Commentary, Detroit: American Concrete Institute; 1995.
- [14]. Tang, C.W., 2006, Using Radial Basis Function Neural Networks to Model Torsional Strength of Reinforced Concrete Beams, *Comput Concr* 2006;3(5):335–55.
- [15]. URL 1: <https://veribilimcisi.com/2018/02/23/karar-agaclari-decision-trees/>
- [16]. Vapnik, V.N., 1998, *Statistical Learning Theory*, New York: John Wiley and Sons. Python Programming, 1995, Van Rossum, G. & Drake, Jr., F.L., 1995, *Python Reference Manual*, Centrum voor Wiskunde en Informatica Amsterdam.
- [17]. Arslan, İ., 2019, *Python ile Veri Bilimi*, Pusula yayıncılık.