



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 12.05.2025
Kabul Tarihi : 06.01.2026

Received Date : 12.05.2025
Accepted Date : 06.01.2026

FARKLI YAPISAL ÖZELLİKLERDEKİ ÖRME KUMAŞLARIN PATLAMA MUKAVEMETİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE MODELLENMESİ VE TAHMİNİ

MODELING AND PREDICTION OF THE BURSTING STRENGTH OF KNITTED FABRICS WITH DIFFERENT STRUCTURAL PROPERTIES USING MACHINE LEARNING METHODS

Bilge BERKHAN KASTACI (ORCID: 0000-0001-6897-0554)

¹ Kahramanmaraş İstiklal Üniversitesi, İş Sağlığı ve Güvenliği Koordinatörlüğü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Bilge BERKHAN KASTACI, bilgeberkhan.kastaci@istiklal.edu.tr

ÖZET

Örme kumaşların patlama mukavemeti, çok eksenli ve ani basınçlara karşı dayanımı belirleyen kritik bir mekanik özelliktir ve spor-performans, tıbbi tekstil ve koruyucu giyim uygulamalarında önemli bir rol oynar. Ancak geleneksel test yöntemleri zaman ve maliyet açısından sınırlayıcıdır. Bu nedenle, kumaşın yapısal ve fiziksel özelliklerine dayalı tahmin modellerinin geliştirilmesi üretim verimliliği ve kalite kontrol açısından önemli avantajlar sunmaktadır. Bu çalışmada, 56 farklı konstrüksiyona sahip örme kumaştan elde edilen deneysel veriler kullanılarak çeşitli makine öğrenmesi algoritmalarıyla patlama mukavemeti tahmin modelleri geliştirilmiştir. Girdi parametreleri literatür bulguları, korelasyon analizi ve Varyans Şişirme Faktörü (VIF) sonuçlarına göre belirlenmiştir. Doğrusal regresyon (LR), çok değişkenli ayarlanabilir regresyon eğrileri (MLR) ve destek vektör makinelerinde regresyon (SMOreg) modelleri, k-katlı çapraz doğrulamada en yüksek tahmin performansını göstermiştir. Duyarlılık analizi, LR ve SMOreg modellerinde çubuk sıklığının, MLR modelinde ise iplik mukavemetinin tahmin performansını en az etkileyen parametre olduğunu ortaya koymuştur. Bu bulgular, makine öğrenmesi tabanlı yaklaşımların örme kumaşların mekanik özelliklerinin öngörülmesinde etkili ve uygulanabilir bir alternatif sunduğunu göstermektedir.

Anahtar Kelimeler: Doğrusal regresyon, yapay sinir ağı, destek vektör makineleri, çok değişkenli ayarlanabilir regresyon eğrileri, duyarlılık analizi

ABSTRACT

The bursting strength of knitted fabrics is a critical mechanical property that determines resistance to multiaxial and sudden pressure loads and plays an important role in sportswear, medical textiles, and protective clothing. However, conventional testing methods are time-consuming and costly. Therefore, developing prediction models based on the structural and physical properties of fabrics provides significant advantages in production efficiency and quality control. In this study, bursting strength prediction models were developed using machine learning algorithms based on experimental data obtained from 56 knitted fabric constructions. Input parameters were selected according to literature findings, correlation analysis, and Variance Inflation Factor (VIF) results. Linear regression (LR), multiple linear regression (MLR), and support vector machine regression (SMOreg) achieved the highest predictive performance in k-fold cross-validation. Sensitivity analysis revealed that course density and yarn strength had the lowest influence on model performance. These findings indicate that machine learning-based approaches offer an effective and applicable alternative for predicting the mechanical properties of knitted fabrics.

Keywords: Linear regression, artificial neural network, support vector machines, multivariate adaptive regression curves, sensitivity analysis

GİRİŞ

Örme kumaşların patlama mukavemeti, kumaşın çok eksenli ve ani gerilme yükleri altında kopmadan dayanabilme yeteneğini ifade eden temel bir mekanik performans göstergesidir. Spor ve performans giysileri, tıbbi tekstiller, koruyucu giysiler ve dikişsiz iç giyim ürünlerinde, ürünün kullanım ömrü ve güvenilirliğini belirleyen en kritik parametrelerden biridir. Patlama mukavemetinin laboratuvar ortamında deneysel olarak ölçümü mümkün olsa da bu yöntem zaman alıcı, maliyetli ve sürekli tekrar gerektiren bir süreçtir. Kumaşın yapısal ve fiziksel özelliklerine dayanarak patlama mukavemetinin tahmin edilmesi; hataların erken tespiti, kalite kontrol süreçlerinin hızlanması ve maliyetlerin azaltılması açısından önemli avantajlar sunmaktadır.

Literatürdeki çalışmalar, patlama mukavemetinin tahmininde çoğunlukla iplik ve temel kumaş parametrelerine odaklanmıştır. Ertuğrul ve Uçar (2000), pamuklu düz örme kumaşlarda gramaj, iplik mukavemeti ve uzama gibi girdileri kullanarak ANN ve ANFIS modelleri geliştirmiş ve yüksek doğrulukta sonuçlar elde etmiştir. Ünal vd. (2010), iplik büküm katsayısı, düzgünsüzlük ve mukavemet gibi parametrelerle ANN tabanlı tahmin modelleri oluşturmuş ve $R=0,97$ değerine ulaşmıştır. 2012'de yapılan çalışmada süprem kumaşlarda patlama mukavemeti ve hava geçirgenliği; ilmek geometrisi ve iplik parametreleri kullanılarak ANN ve regresyon modelleriyle başarıyla tahmin edilmiştir. Jamshaid vd. (2013), düz örme kumaşlarda regresyon ve ANFIS modellerini karşılaştırmış; ANFIS'in karmaşık ilişkileri daha iyi temsil ettiğini, regresyonun ise üretim süreçlerinde yorumlanabilirlik sağladığını belirtmiştir.

Hossain vd. (2016), viskon/spandeks örme kumaşlarda bulanık uzman sistemlerle patlama mukavemetini tahmin etmiş; düşük MAPE değerleri ve yüksek doğruluk elde etmiştir. Liyew ve Rotich (2020), polyester süprem kumaşlarda başlangıç yırtığı, ilmek yapısı ve ilmek yoğunluklarının mekanik performans üzerindeki belirleyici rolünü göstermiştir. Ghosh (2022), süprem kumaşlarda ilmek uzunluğu, kalınlık, gözeneklilik, sıklık faktörü ve kumaş ağırlığı gibi parametrelerin patlama mukavemeti üzerindeki etkisini ANOVA yöntemiyle incelemiş ve özellikle kumaş ağırlığının patlama mukavemetini güçlü şekilde belirlediğini ($R^2 = 0,9438$) rapor etmiştir. Elias vd. (2023) ise lif kompozisyonunun (pamuk–polyester–spandeks oranları) patlama mukavemetine etkisini analiz ederek uygun karışımın regresyon modelleri ile öngörülebileceğini ortaya koymuştur. Son olarak, İslam vd. (2024) üç iplikli polar kumaşlarda ANN kullanarak hem patlama mukavemetini hem de boncuklanma derecesini çok düşük MAPE değerleriyle tahmin etmiş ve ANN'in çoklu çıktı sorunlarında etkili olduğunu göstermiştir.

Bu çalışmalar patlama mukavemetinin tahmini için önemli bir temel oluşturursa da modellerin çoğunda iplik özellikleri, ilmek uzunluğu, kumaş ağırlığı ve sıklık faktörü gibi temel fiziksel parametrelerle sınırlı kalındığı görülmektedir. Örme kumaşlarda patlama mukavemeti, yalnızca temel fiziksel parametrelerden değil; örgü yapısı, iplik üretim teknolojisi ve ilmek yoğunlukları gibi yapısal değişkenlerin etkileşiminden de etkilenir. Özellikle örgü yapısı, ilmek geometrisini ve çok eksenli deformasyon davranışını belirleyerek patlama mukavemetinin temel belirleyicilerinden biri haline gelmektedir.

Bu nedenle, örgü yapısının ve iplik üretim teknolojisinin tahmin modellerine birlikte dahil edilmesi literatürde nadiren ele alınan ancak patlama mukavemetinin gerçeğe daha yakın tahmin edilmesi için kritik öneme sahip bir adımdır. Bu çalışmanın özgün yanı, patlama mukavemeti tahmininde yalnızca fiziksel ve iplik parametrelerini değil; örgü yapısı, iplik üretim tekniği ve ilmek yoğunluklarını birlikte değerlendiren kapsamlı bir girdi seti kullanılmasıdır. Böylece model, örme kumaşların yapısal çeşitliliğini doğrudan temsil eden çok boyutlu bir veri yapısı üzerinde eğitilmektedir.

Bu çalışma kapsamında Weka yazılımı aracılığıyla çeşitli makine öğrenmesi algoritmalarının (IBk, LR, MLR, MLP, SMOReg) performansları karşılaştırmalı olarak incelenmiştir. Hem eğitim hem de k-katlı çapraz doğrulama testlerindeki tahmin başarıları değerlendirilmiş ve örme kumaşlarda patlama mukavemetinin öngörülmesinde en etkili modellerin belirlenmesine odaklanılmıştır. Çalışma aynı zamanda duyarlılık analizi ile hangi girdilerin modele en fazla katkıyı sağladığını ortaya koyarak literatürde eksik kalan yapısal etki değerlendirmesine de katkı sunmayı amaçlamaktadır.

MATERYAL VE METOD

Bu çalışmada ring ve açık uçlu rotor iplik teknolojileri ile Ne 20/1, Ne 30/1 ve Ne 40/1 iplik numaralarında, süprem, ribana ve interlok olmak üzere üç farklı desende farklı çubuk ve sıra sıklığında 44 farklı kumaşın patlama mukavemetleri test sonuçları eğitim verisi olarak işlenmiştir. Makine öğrenmesi ile patlama mukavemeti tahmin

edilmesine yönelik modeller oluşturulurken WEKA (Waikato Environment for Knowledge Analysis) programı kullanılmıştır. Oluşturulan modeller 12 farklı veri ile test edilmiş, toplamda 56 adet farklı kumaş verisi kullanılmıştır. Patlama mukavemeti ölçümleri ISO 13938-2 standardına uygun olarak diyafram metodu ile gerçekleştirilmiştir.

Değişkenlerin patlama mukavemeti ile ilişkileri Pearson korelasyon analiziyle, çoklu doğrusal bağlantı durumları ise VIF analiziyle incelenmiştir. Korelasyon analizi, özellikle örgü tipinin, iplik üretim teknolojisinin ve ilmek yoğunluklarının patlama mukavemeti ile belirli düzeylerde ilişkiler sergilediğini göstermiştir. Bu bulgu, ilmek geometrisini, ilmek bağlantı noktalarını ve çok eksenli deformasyon davranışını doğrudan belirleyen örgü yapısının, örme kumaşlarda patlama mukavemetinin en temel belirleyicisi olduğunu ortaya koymaktadır. İplik numarası, iplik büküm katsayısı ve iplik mukavemeti tek değişkenli korelasyonda düşük ilişki değerleri göstermiş olsa da, örme kumaşların hammaddesi iplik olduğundan, lineer yoğunluk, lif tutarlılığı ve iplik dayanımı gibi mikromekanik özelliklerin kumaş dayanımına hem doğrudan hem dolaylı katkılar sunduğu bilinmektedir. VIF analizi bazı değişkenlerde yüksek değerler göstermiştir. Ancak kullanılan IBk, MLP, SMOreg ve MARS gibi doğrusal olmayan veya düzenleme temelli algoritmalar multikolineariteye karşı daha dayanıklı yapılardır. Bu nedenle yüksek korelasyonlu değişkenlerin model performansına etkisi sınırlıdır; yapısal ve mekanik gerekçelerle modelde tutulmaları bilimsel açıdan uygundur.

Bu değerlendirmeler doğrultusunda modele dahil edilecek girdi değişkenleri; kumaş türü, iplik üretim türü, iplik numarası (Ne), iplik bükümü (tur/metre), iplik mukavemeti (kgf/Nm) ile kumaş çubuk ve sıra sıklıkları (adet/1 inç) olarak düzenlenmiştir. Kumaş türlerinde 1 kodu süprem, 2 kodu ribana, 3 kodu ise interlok kumaşlara karşılık gelmektedir. İplik üretim yönteminde açık uçlu rotor iplikler 1, ring iplikleri ise 2 olarak kodlanmıştır. Veri setinde yer alan iplik numaraları 20/1, 30/1 ve 40/1'e karşılık gelen ölçülmüş fiili değerlerdir. Modellemelerde kullanılan eğitim verileri Tablo 1'de sunulmuştur.

Bu çalışmada kullanılan veri seti, laboratuvar koşullarında üretilen sınırlı sayıdaki örme kumaştan elde edilen deneysel ölçümlere dayandığından, gözlem sayısı ve kumaş türleri arasındaki dağılım işletme ölçeğine kıyasla daha sınırlıdır. Veri miktarındaki bu doğal kısıt, geniş kapsamlı bir bağımsız doğrulama seti oluşturulmasını güçleştirdiği için model performansı küçük veri yapılarında önerilen k-katlı çapraz doğrulama yöntemiyle değerlendirilmiştir. Bu yaklaşım, veri setinin tamamının hem eğitim hem de test aşamalarında dengeli biçimde kullanılmasını sağlayarak modelin yalnızca ayrılmış bir test setine bağımlı kalmadan genelleme performansının ölçülmesine olanak tanır. Sınırlı veri setlerinde karşılaşılan başlıca metodolojik zorluklardan biri olan aşırı uyum (overfitting) riski de bu yöntemle önemli ölçüde azaltılmıştır; zira çapraz doğrulama, modelin eğitim verisini ezberlemesiyle ortaya çıkabilecek yapay doğruluk artışlarını dengeleyerek sistemin gerçek performansını daha sağlıklı biçimde ortaya koymaktadır. Bununla birlikte, bağımsız test setinin yalnızca 12 örnekten oluşması genelleme kapasitesi açısından bir sınırlılık oluşturmaya devam etmekte olup, gelecekte daha geniş ve çeşitlendirilmiş veri kümeleriyle doğrulama yapılması model güvenilirliğini artıracaktır.

Modellerin eğitimi, doğrulanması ve performans değerlendirmesi bu yaklaşım çerçevesinde gerçekleştirilmiş; her model için eğitim ve test performansları ayrı ayrı raporlanmıştır. Performansı yüksek bulunan modellerde, patlama mukavemetine en fazla katkı sağlayan girdi parametrelerini belirlemek amacıyla duyarlılık analizi yapılmıştır. Bu analiz, modellerin karar verme yapısına etki eden değişkenlerin görece önem düzeylerini ortaya koymuş ve örme kumaşlarda patlama mukavemetinin hangi yapısal ve iplik temelli parametrelerden daha güçlü biçimde etkilendiğini göstermiştir.

Çalışmanın temel amacı, örme kumaşlarda patlama mukavemetinin uygun girdi parametreleriyle makine öğrenmesi yöntemleri kullanılarak tahmin edilebilirliğini ortaya koymak olduğundan, veri miktarının sınırlılığı yöntemin geçerliliğini etkilememektedir. Ancak gelecekte, işletme ortamından daha kapsamlı ve dengeli veri setleri toplanarak modellerin farklı üretim senaryoları altında yeniden doğrulanması planlanmaktadır.

Makine öğrenmesi metotları ile modeller oluşturulduktan sonra modelin performansını doğrulamak için Tablo 2' de verilen ve modele dahil edilmemiş veriler test verisi olarak kullanılmıştır.

Model Oluşturma

Modellere dahil edilecek veri seti tanımlanıp düzenlendikten sonra, model oluşturma aşamasında öğrenme algoritmalarının eğitimi, doğrulanması ve performans değerlendirmesi sistematik bir akış içinde gerçekleştirilmiştir.

Tablo 1: Tüm Modellerde Kullanılan Eğitim Veri Seti

Kumaş Türü (kum tur)	İplik Türü (ipl tur)	İplik Numarası (ipl ne)	İplik Büküm (ipl buk)	İplik Mukavemeti (ipl muk)	Çubuk Sıklığı (cub sik)	Sıra Sıklığı (sır sık)	Patlama Mukavemeti (pat muk)
1	1	29,5	800	9,6	12	12	441
1	1	29,5	800	9,6	12	15,5	481
1	1	29,5	800	9,6	12	18	471
1	1	29,5	800	9,6	12	22	529
1	2	30,3	770	15,3	12	12	577
1	2	30,3	770	15,3	12	13,5	608
1	2	30,3	770	15,3	12	15,5	624
1	2	30,3	770	15,3	12	18	658
1	2	30,3	770	15,3	12	22	688
2	1	29,5	800	9,6	12	13	548
2	1	29,5	800	9,6	12	13,5	527
2	1	29,5	800	9,6	12	14	533
2	1	29,5	800	9,6	12	16,5	539
2	2	30,3	770	15,3	12	13	618
2	2	30,3	770	15,3	12	13,5	656
2	2	30,3	770	15,3	12	14	680
2	2	30,3	770	15,3	12	15,5	673
2	2	30,3	770	15,3	12	16,5	705
3	2	39,2	835	14,9	38,1	36	765,4
3	2	39,2	835	14,9	27,94	29	694,1
3	2	29,64	807	17,2	43,18	41	956
3	2	29,64	807	17,2	38,1	39	924,4
3	2	29,64	807	17,2	33,02	35	887,1
2	2	29,64	807	17,2	29	30	822,4
2	2	29,64	807	17,2	27	28	666,7
2	2	29,64	807	17,2	25	27	635,7
2	2	39,2	835	14,9	25	26	448,1
2	2	39,2	835	14,9	23	24	426,7
2	2	39,2	835	14,9	20	22	402,1
1	2	39,2	835	14,9	25	24	579,1
1	2	39,2	835	14,9	22	23	571,1
1	2	39,2	835	14,9	18	20	466,5
1	2	29,64	807	17,2	35,6	36	703,4
1	2	29,64	807	17,2	33	34	623,9
1	2	29,64	807	17,2	31	32	553,1
1	1	29,61	760	16	33	31	587,3
1	1	29,61	760	16	30	30	538,4
1	1	29,61	760	16	27	28	443,6
1	2	20,25	780	19,7	37	38	539,2
1	2	20,25	780	19,7	35	36	499,6

Bu kapsamda, girdi değişkenlerinin yapısal bütünlüğünün korunması, uygun model yapılarının seçilmesi, doğrulama stratejisinin belirlenmesi ve kullanılacak performans ölçütlerinin tanımlanması modelleme sürecinin temel adımlarını oluşturmuştur.

Tablo 2: Model Doğrulamalarında Kullanılan Test Verileri

Kumaş Türü (kum tur)	İplik Türü (ipl tur)	İplik Numarası (ipl ne)	İplik Büküm (İpl buk)	İplik Mukavemeti (ipl muk)	Çubuk Sıklığı (cub sik)	Sıra Sıklığı (sır sik)	Patlama Mukavemeti (pat muk)
2	1	30,28	829	16,1	24	26	352,3
2	1	30,28	829	16,1	21	23	335,8
2	1	30,28	829	16,1	19	21	329,2
2	2	29,42	862	17,32	25	27	378,7
2	2	29,42	862	17,32	22	24	373,6
2	2	29,42	862	17,32	20	22	361,4
1	1	30,28	829	16,1	23	22	298,1
1	1	30,28	829	16,1	21	21	271,4
1	1	30,28	829	16,1	19	20	258,1
1	2	29,42	862	17,32	25	25	341,2
1	2	29,42	862	17,32	23	24	324,3
1	2	29,42	862	17,32	21	22	301,3

Bu çalışmada yalnızca denetimli öğrenme yöntemleri kullanılmıştır; çünkü her bir örme kumaş için hem açıklayıcı değişkenler (iplik tipi, üretim teknolojisi, örgü yapısı, sıklık parametreleri) hem de hedef değişken olan patlama mukavemeti mevcuttur. Denetimli öğrenme, giriş-çıkış eşleşmelerinden yararlanarak yeni örnekler için doğru tahminler üretebilen bir fonksiyonun öğrenilmesini amaçlayan bir yaklaşımdır (Aydın ve Özkul, 2015; Witten vd., 2011).

Model kararlılığını ve genelleme başarımını değerlendirmek üzere k-katlı çapraz doğrulama (k-fold cross-validation) yöntemi uygulanmıştır. Veri seti K eşit alt kümeye ayrılmış; her yinelemede bu alt kümelerden biri test verisi olarak kullanılırken diğerleri eğitim için kullanılmıştır. Bu döngüsel süreç sonucunda tüm örnekler en az bir kez test verisi olarak değerlendirilmiş ve model performansı dengeli bir şekilde ölçülmüştür. Çapraz doğrulama, sınırlı veri yapılarında aşırı uyumun (overfitting) önlenmesi ve tahmin doğruluğunun güvenilir şekilde değerlendirilmesi açısından literatürde önerilen en sağlam doğrulama stratejilerinden biridir (Kuhn ve Johnson, 2013; Hastie vd., 2009).

Makine öğrenmesi tabanlı tahmin modellerinin oluşturulmasında Weka yazılımı üzerinden birden fazla algoritma değerlendirilmiştir. IBk (k-en yakın komşu algoritması), örnekler arası mesafeleri temel alan parametrik olmayan bir yöntem olup özellikle küçük veri setlerinde etkili sonuçlar verebilmektedir (Aydemir, 2019). Doğrusal regresyon (LR), bağımlı değişken ile açıklayıcı değişkenler arasındaki doğrusal ilişkileri modelleyen temel bir istatistiksel yöntemdir ve karşılaştırma modeli olarak çalışmada yer almıştır (Aydın, 2014). Yapay sinir ağları (MLP), doğrusal olmayan ilişkileri öğrenme kapasitesi sayesinde karmaşık veri yapılarında yüksek tahmin doğruluğu sunan çok katmanlı ileri beslemeli bir ağ mimarisine sahiptir (Shamey ve Hussain, 2003). Çok değişkenli uyarlanabilir regresyon eğrileri (MARS), veri uzayını yerel alt bölgelere ayırarak doğrusal olmayan ilişkileri parça-wise bir yaklaşımla modelleyen modern bir regresyon tekniğidir (Sevinli, 2009). Son olarak, Destek Vektör Regresyonu (SVR/SMOreg), yüksek boyutlu uzaylarda optimum ayırım aralığını öğrenerek sürekli değer tahmini yapan güçlü bir yöntemdir ve küçük veri setleri için önemli avantajlar sunmaktadır (Hyndman ve Koehler, 2006; Vapnik, 1995). Bu algoritmaların her biri farklı öğrenme stratejileri ve veri işleme mekanizmalarıyla model performansına özgün katkılar sağlamaktadır. Tüm modeller aynı veri seti ve aynı doğrulama prosedürü altında eğitilip test edilerek karşılaştırılmış; böylece örme kumaşlarda patlama mukavemetinin hangi yöntemlerle daha yüksek doğrulukla tahmin edilebildiği bütüncül şekilde değerlendirilmiştir.

Model Performanslarının Değerlendirme Kriterleri

Modellerin performansı, tahmin edilen değerlerle gerçek değerler arasındaki uyumu nicel olarak ifade eden çeşitli hataların ve doğruluk ölçütlerinin hesaplanmasıyla değerlendirilmiştir. Bu amaçla korelasyon katsayısı (r), ortalama mutlak hata (MAE), kök ortalama kare hata (RMSE), bağıl mutlak hata (RAE), kök bağıl kare hata (RRSE) ve ortalama mutlak yüzde hata (MAPE) kullanılmıştır.

Korelasyon katsayısı (r), tahmin edilen değerlerle gerçek değerler arasındaki doğrusal ilişkinin yönünü ve gücünü ölçer. Değer ± 1 'e yaklaştıkça ilişkinin kuvveti artar; +1 aynı yönlü, -1 ise ters yönlü güçlü bir ilişkiyi ifade eder (Aydemir, 2019).

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (1)$$

Ortalama mutlak hata (MAE), her bir gözlem için gerçek değer ile tahmin edilen değer arasındaki farkın mutlak değerinin ortalamasıdır. Daha düşük MAE, modelin daha tutarlı tahmin ürettiğini gösterir.

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2)$$

Kök ortalama kare hata (RMSE), tahmin hatalarının karesinin ortalamasının kareköküdür ve özellikle büyük hatalara duyarlıdır. Bu nedenle RMSE'nin düşük olması daha yüksek doğruluk düzeyini işaret eder.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

Bağıl mutlak hata (RAE), modelin performansını basit bir referans tahmin ediciye göre karşılaştırır ve mutlak hatanın normalize edilmiş biçimini sunar. Değerin sıfıra yaklaşması model hatalarının düşük olduğunu gösterir.

$$RAE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{\sum_{i=1}^n (y_i - y_m)} \quad (4)$$

Kök bağıl kare hata (RRSE), RMSE'nin referans modele göre normalize edilmiş biçimidir ve tahmin edicinin başarımını kıyaslamada kullanılır.

$$RRSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - y_m)^2}} \quad (5)$$

Ortalama mutlak yüzde hata (MAPE), tahmin hatalarını yüzdelik olarak ifade ederek farklı veri setlerinin karşılaştırılmasına olanak tanır.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \quad (6)$$

Formüllerde; y_i gerçek değeri, \hat{y}_i tahmin edilen değeri, n ise gözlem sayısını verir.

Modellerde Duyarlılık Analizi

Duyarlılık analizi, bir modelin giriş değişkenlerinde meydana gelen değişimlerin çıktı üzerindeki etkilerini sistematik olarak değerlendirmeyi amaçlayan bir yöntemdir. Bu analiz, modelin hangi değişkenlere daha duyarlı olduğunu belirlemek, önemsiz veya düşük etkili değişkenleri ayıklayarak modeli sadeleştirmek ve tahmin performansının hangi girdiler tarafından daha güçlü biçimde yönlendirildiğini ortaya koymak için kullanılır.

Duyarlılık analizinin uygulanmasıyla:

- Modelin hangi giriş değişkenlerine daha duyarlı olduğu belirlenir,
- Önemsiz değişkenler ayıklanarak model basitleştirilebilir,
- Sistemin kritik bileşenleri anlaşılır,
- Tahmin modellerinin güvenilirliği ve açıklanabilirliği artırılır.

Bu çalışmada duyarlılık analizi, giriş değişkenlerinin modele katkısını değerlendirmek amacıyla mevcut model üzerinden her seferinde bir değişken çıkarılarak gerçekleştirilmiştir. Bu işlem sonucunda model performansındaki değişim gözlenmiş ve değişkenlerin göreceli etkisi oran (ratio) değeri ile hesaplanmıştır. Ratio değeri:

$$\text{Ratio} = \frac{\text{Esas model performansı (korelasyon katsayısı } r)}{\text{Elimine edilmiş giriş değişkeni ile yeni model performansı (korelasyon katsayısı } r)} \quad (7)$$

şeklinde tanımlanmıştır. Bu ölçüte göre:

- **Ratio > 1** ise, ilgili değişken çıkarıldığında model performansı düşmüş demektir; bu durumda söz konusu değişkenin modele katkısı yüksektir.
- **Ratio < 1** ise, değişken çıkarıldığında model performansı artmış veya değişmemiştir; bu da değişkenin modele katkısının düşük olduğunu gösterir.

Değişkenlerin önem sıralaması ratio değerlerinin yüksekten düşüğe doğru dizilmesiyle elde edilmiştir. Böylece modele en fazla katkı sağlayan giriş değişkenleri sistematik olarak belirlenmiştir. Ayrıca Weka yazılımında değişken önemini değerlendirilmesi için özellik değerlendirme yöntemleri (attribute evaluators) kullanılmıştır. Bu yöntemler, her bir giriş değişkeni ile çıktı değişkeni arasındaki ilişkinin gücünü ölçerek ek bir önem sıralaması oluşturur. Bu sıralamada düşük değer alan değişkenlerin modele katkısının sınırlı olduğu anlaşılır.

BULGULAR

Makine öğrenmesi tabanlı modellerin performansı eğitim ve test verileri üzerinde değerlendirilmiş, sonuçlar Tablo 3'te sunulmuştur. Değerlendirmede r , MAE, RMSE, RAE, RRSE ve MAPE ölçütleri kullanılmış; bu metrikler doğruluk, hata düzeyi ve genellenebilirliğin birlikte yorumlanmasına olanak sağlamıştır.

Tablo 3: Model Performans Çıktıları

MODEL	Veri Türü		r	MAE	RMSE	MAPE	RAE	RRSE
	Eğitim	Test						
IBk	Eğitim		0,93	36,51	49,97	6,10	34,00	37,24
	Test		0,81	223,43	226,95	-	-	-
LR	Eğitim		0,79	60,65	79,65	10,62	56,49	59,36
	Test		0,87	143,19	148,74	-	-	-
MLR	Eğitim		0,84	51,69	69,56	8,94	48,14	51,84
	Test		0,78	60,86	71,46	-	-	-
MLP	Eğitim		0,97	24,53	31,19	4,16	22,84	23,24
	Test		0,43	311,05	324,46	-	-	-
SMOreg	Eğitim		0,75	64,14	86,92	11,32	59,73	64,78
	Test		0,94	38,11	45,60	-	-	-

Model performanslarının yer aldığı Tablo 3'ü incelediğimizde;

IBk modeli; eğitim verisi üzerinde yüksek doğruluk ($r = 0,93$) ve düşük hata değerleri ($MAE = 36,51$; $RMSE = 49,97$; $MAPE = \%6,10$) elde ederek güçlü bir performans sergilemiştir. Bu sonuçlar, komşuluk temelli yaklaşımın eğitim veri yapısını başarılı biçimde yakaladığını göstermektedir. Bununla birlikte test verisinde korelasyon kabul edilebilir düzeyde ($r = 0,81$) olmasına rağmen hata değerlerinin dramatik biçimde yükseldiği görülmektedir ($MAE = 223,43$; $RMSE = 226,95$). Bu bulgu, IBk modelinin örnek yoğunluk dağılımına aşırı duyarlı olduğunu, eğitim verisini yerel komşuluk ilişkileri üzerinden iyi öğrenmesine karşın genellenebilirlik kapasitesinin düşük olduğunu ortaya

koymaktadır. Dolayısıyla IBk modeli, eğitim verisine aşırı uyum (local overfitting) sergileyerek yeni veri üzerinde kararsız performans vermektedir.

LR modeli; eğitim verisinde orta düzeyde doğruluk ($r = 0,79$) ve kabul edilebilir hata oranları (MAE = 60,65; RMSE = 79,65) üretmiştir. Test verisinde ise korelasyon belirgin biçimde artmış ($r = 0,87$) ve hata değerleri orta seviyede kalmıştır (MAE = 143,19; RMSE = 148,74). Bu durum, LR modelinde eğitim verisine göre daha iyi genelleme eğilimi olduğunu göstermektedir. Ancak RAE ve RRSE değerlerinin yüksekliği, modelin doğrusal varsayımları nedeniyle karmaşık ilişkileri temsil etmekte zorlandığını, ancak veri setinde güçlü doğrusal bileşenler bulunduğu daha stabil performans gösterdiğini ortaya koymaktadır. Dolayısıyla LR modeli doğrusallık içeren yapılarda çalışabilir, fakat karmaşık ilişkilerde sınırlıdır.

MLR modeli; eğitim verisinde güçlü bir doğruluk ($r = 0,84$) ve düşük hata seviyeleri (MAE = 51,69; RMSE = 69,56; MAPE = %8,94) üreterek LR modelinden daha iyi bir performans göstermiştir. Test verisinde ise korelasyon orta düzeyde ($r = 0,78$) olup hata miktarları düşük seviyededir (MAE = 60,86; RMSE = 71,46). Bu sonuçlar, MLR modelinin çoklu etkileşimleri ve doğrusal olmayan bileşenleri LR'den daha başarılı biçimde temsil ettiğini, eğitim ve test verisi arasında daha dengeli bir performans sunduğunu göstermektedir. MLR modeli hem doğruluk hem de genellenebilirlik bakımından istikrarlıdır.

MLP modeli eğitim verisinde tüm modeller arasında en yüksek doğruluğu ($r = 0,97$) ve en düşük hata değerlerini (MAE = 24,53; RMSE = 31,19; MAPE = %4,16) elde ederek olağanüstü bir uyum göstermiştir. Ancak test verisinde korelasyon çok düşük seviyeye düşmüş ($r = 0,43$) ve hata değerleri aşırı yükselmiştir (MAE = 311,05; RMSE = 324,46). Bu çarpıcı fark, MLP modelinin aşırı uyum (overfitting) sergilediğini; eğitim verisini ezberlerken genel veri yapısını temsil edemediğini göstermektedir. Dolayısıyla MLP, eğitim setinde mükemmel yakın performans sunsa da gerçek tahmin problemleri için güvenilir değildir.

SMOreg modeli, eğitim verisinde orta düzey doğruluk ($r = 0,75$) ve yüksek hata oranları (MAE = 64,14; RMSE = 86,92) üretmiştir. Buna karşın test verisinde tüm modeller arasında en yüksek doğruluğa ($r = 0,94$) ve en düşük hata seviyelerine (MAE = 38,11; RMSE = 45,60) ulaşarak en iyi genellenebilirlik performansını sergilemiştir. Bu bulgu, SVR tabanlı modellerin karmaşık desenleri yakalama kapasitesi, düzenleme (regularization) avantajı ve gürültüye karşı dayanıklı yapısı sayesinde yeni verilerde tutarlı tahmin üretme yeteneğinin en yüksek olduğunu göstermektedir. SMOreg modeli bu çalışma bağlamında en güvenilir ve en güçlü tahmin modeli olarak öne çıkmıştır.

Modellerin test verisi üzerindeki performansları karşılaştırıldığında, SMOreg algoritmasının genel hata metrikleri açısından diğer modellerden daha başarılı olduğu görülmüştür. SMOreg modeli, LR modeline göre yaklaşık %69, MLR modeline göre ise %36 oranında daha düşük RMSE değeri üretmiştir. Ayrıca SMOreg'in doğrusal olmayan ilişkileri yakalama kapasitesi sayesinde, tüm modeller arasında en yüksek korelasyon katsayısına ($r = 0,94$) ulaştığı belirlenmiştir. Bu bulgular, SMOreg algoritmasının örme kumaşların çok boyutlu yapısal davranışlarını temsil etmede daha güçlü bir tahmin performansı sunduğunu göstermektedir.

Weka yazılımı ile gerçekleştirilen özellik değerlendirme analizinde, patlama mukavemetini en fazla etkileyen değişkenlerin sırasıyla kumaş türü, iplik türü, sıra sıklığı ve çubuk sıklığı olduğu görülmüştür (Şekil 1). İplik numarası ve iplik bükümü gibi parametrelerin etkisi nispeten zayıf olup bu durum pamuk esaslı örme yapılarda iplik inceliğinin patlama mukavemeti üzerindeki etkisinin sınırlı olmasına bağlanabilir. Genel olarak, yapısal parametrelerin (kumaş türü, örgü yapısı, ilmek geometrisi) mukavemet üzerinde iplik bazlı parametrelere göre daha güçlü belirleyiciler olduğu doğrulanmıştır.

Tablo 5'te verilen duyarlılık analizi sonuçları, modellerin girdi değişkenlerine verdikleri tepkilerin farklılaştığını göstermektedir. LR modelinde kumaş türü en duyarlı değişken olarak öne çıkarken, çubuk sıklığı model performansını en az etkileyen parametre olmuştur. MLR modelinde ise en kritik değişken iplik numarası olarak belirlenmiş, çubuk sıklığı yine en düşük katkı yapan değişken konumunda kalmıştır. SMOreg modelinde duyarlılık sıralaması değişmiş; iplik türü model performansı açısından en önemli parametre olurken, iplik numarası en düşük duyarlılık seviyesinde yer almıştır. Bu bulgular, örgü yapısı ve iplik parametrelerinin modeller tarafından farklı ağırlıklarla değerlendirildiğini ve patlama mukavemetinin tahmininde yapısal değişkenlerin önemli bir rol oynadığını ortaya koymaktadır.

AttributeSelectedClassifier yöntemiyle oluşturulan alt küme modellerinin performansları Tablo 6'da verilmiştir. LR ve MLR alt modellerinde korelasyon değerleri düşmüş, hata miktarları artmış ve genelleme yeteneği zayıflamıştır.

Buna karşın SMOreg alt modeli, tam modele yakın bir doğruluk ($r = 0,6319$) sergilemiş ve hata değerlerini makul seviyede tutmuştur. Bu bulgular, SMOreg modelinin değişken alt kümelerinde dahi yapısal genelleme kapasitesinin güçlü olduğunu göstermekte; SVR tabanlı modellerin değişken azaltma koşullarında dahi kararlı tahmin performansı sunduğunu doğrulamaktadır.

```

Evaluator: weka.attributeSelection.CorrelationAttributeEval
Search: weka.attributeSelection.Ranker -T -1.7976931348623157E308 -N -1
Relation: WekaExcel
Instances: 44
Attributes: 8
           kum_tur
           ipl_tur
           ipl_ne
           ipl_buk
           ipl_muk
           cub_sik
           sir_sik
           pat_muk
Evaluation mode: evaluate on all training data

=== Attribute Selection on all input data ===

Search Method:
  Attribute ranking.

Attribute Evaluator (supervised, Class (numeric): 8 pat_muk):
  Correlation Ranking Filter
Ranked attributes:
0.6001  1 kum_tur
0.4604  2 ipl_tur
0.4225  7 sir_sik
0.4077  6 cub_sik
0.3966  5 ipl_muk
-0.0115 3 ipl_ne
-0.0162 4 ipl_buk

Selected attributes: 1,2,7,6,5,3,4 : 7

```

Şekil 1: Weka Yazılımı Attribute Evaluators (özellik değerlendiricisi) Çıktısı

Tablo 5: Model Girdi Değişkenlerinin Duyarlılık Analizi

MODEL	r (eğitim)	r (kum_tur elimine)	r (ipl_tur elimine)	r (ipl_ne elimine)	r (ipl_buk elimine)	r (ipl_muk elimine)	r (cub_sik elimine)	r (sir_sik elimine)
LR	0,7897	0,3659	0,6408	0,797	0,6348	0,729	0,8162	0,7565
MLR	0,8443	0,7996	0,8081	0,7647	0,8234	0,8345	0,8582	0,847
SMOreg	0,7455	0,5422	0,5051	0,7926	0,5084	0,6334	0,7636	0,7099
DUYARLILIK								
LR_ratio		2,1582	1,2323	0,9908	1,2440	1,0832	0,9675	1,0438
LR_ranke		1	3	6	2	4	7	5
MLR_ratio		1,0559	1,0447	1,1040	1,0253	1,0117	0,9838	0,9968
MLR_ranke		2	3	1	4	5	7	6
SMOreg_ratio		1,3749	1,4759	0,9405	1,4663	1,1769	0,9762	1,0501
SMOreg_ranke		3	1	7	2	4	6	5

Tablo 6: En İyi Alt Küme İle Oluşturulan Yeni Modeller

MODEL	r (att.)	MAE	RMSE	RAE	RRSE
LR	0,636	76,7	100,7	71,43	75,04
MLR	0,6452	83,18	99,93	77,47	74,47
SMOreg	0,6319	74,00	100,88	68,92	75,18

SONUÇ

Bu çalışmada, farklı yapısal ve iplik parametrelerine sahip örme kumaşlarda patlama mukavemetinin tahmin edilmesi amacıyla çeşitli makine öğrenmesi algoritmaları değerlendirilmiştir. Korelasyon–VIF analizleri ile fiziksel ve mekanik gerekçeler doğrultusunda belirlenen girdi değişkenleri kullanılarak oluşturulan modeller k-katlı çapraz doğrulama ile test edilmiştir. Performans ölçütleri değerlendirildiğinde, SMOreg algoritmasının genel doğruluk ve hata seviyeleri açısından en başarılı model olduğu görülmüştür. Buna karşın LR ve MLR modelleri, veri setindeki doğrusal ilişkileri yakalayabilmelerine rağmen doğrusal olmayan örüntülerde SMOreg modelinin performansına ulaşamamıştır.

MLP modelinde eğitim performansının yüksek, test performansının ise daha düşük olması, sınırlı veri seti nedeniyle ortaya çıkan aşırı uyum (overfitting) eğilimini göstermektedir. Veri miktarı, modelin parametre sayısına kıyasla yetersiz kaldığında yapay sinir ağları genelleme kapasitesini kaybedebilmektedir. Benzer şekilde IBk algoritması, düşük k değerlerinde eğitim verisine fazla uyum sağlayarak test performansını sınırlayabilmektedir. Buna karşın LR, MLR ve özellikle SMOreg modelleri, doğrusal/düzenleştirme temelli yapıları sayesinde genelleme performansını korumuştur. Daha büyük ve dengeli veri setleri ile hiperparametre optimizasyonu sağlandığında bu modellerin doğrulama performanslarının daha da iyileştirilmesi mümkündür.

Duyarlılık analizi, modellerin değişkenlere verdiği tepkilerin farklılaştığını ortaya koymuştur. LR ve SMOreg modelleri için çubuk sıklığı, MLR modeli için ise iplik mukavemeti performansı en az etkileyen değişkenler olarak belirlenmiştir. Bu bulgular, patlama mukavemetinin iplik ve örgü parametreleri tarafından farklı ağırlıklarda belirlendiğini göstermektedir. Duyarlılık analizi sonuçları, tüm modellerde kumaş türünün en etkili ilk üç parametre arasında yer aldığını göstermiştir. Bu bulgu, literatürde çoğunlukla göz ardı edilen örgü yapısının patlama mukavemeti üzerindeki belirleyici etkisini ortaya koymakta ve bu çalışmanın özgün katkısını açıkça desteklemektedir.

Genel olarak çalışma, makine öğrenmesi tabanlı yaklaşımların örme kumaşların patlama mukavemetinin hızlı ve güvenilir biçimde tahmin edilmesine olanak sağladığını ve özellikle SMOreg algoritmasının doğrusal olmayan ilişkileri modelleme kabiliyeti sayesinde öne çıktığını göstermektedir. Gelecek araştırmalarda daha kapsamlı ve dengeli veri setleri ile hiperparametre optimizasyonu uygulanarak modellerin doğrulama performanslarının artırılması mümkündür.

Yapay Zekâ Katkı Beyanı

Bu makale tamamen herhangi bir yapay zeka aracının yardımı olmadan yazılmış, düzenlenmiş, analiz edilmiş ve hazırlanmıştır. Metin, veri analizi ve şekiller dahil tüm içeriğin yalnızca yazarlar tarafından oluşturulduğunu beyan ederim.

KAYNAKÇA

Aydemir, E. (2019). Weka ile Yapay Zekâ (2.bs.). Ankara: Seçkin Yayıncılık.

Aydın, D. (2014). Uygulamalı Regresyon Analizi (1. bs.). Ankara: Nobel Yayıncılık.

Aydın, S., Özkul, E. (2015). Veri madenciliği ve Anadolu Üniversitesi açık öğretim sisteminde bir uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 10–15. <https://jret.elapublishing.net/makale/7168>

- Elias, K. M., Rahman, M. O., Hossain, H. M. Z. (2023). Predicting bursting strength behavior of weft knitted fabrics using various percentages of cotton, polyester, and spandex fibers. *Journal of Textile Science and Technology*, 9(4), 273–290. <https://doi.org/10.4236/jtst.2023.94019>
- Ertuğrul, Ş., Uçar, N. (2000). Predicting bursting strength of cotton plain knitted fabrics using intelligent techniques. *Textile Research Journal*, 70(10), 845–851. <https://doi.org/10.1177/004051750007100101>
- Ghosh, K. (2022). An Investigation of Bursting Strength on Weft Knitted Fabrics. *IOSR Journal of Polymer and Textile Engineering*, 9(5), 9–20. <https://doi.org/10.9790/019X-09050920>
- Hossain, I., Choudhury, I. A., Mamat, A. B., Shahid, A., Khan, A. N., Hossain, A. (2016). Prediction of mechanical properties of viscose/spandex knitted fabrics using fuzzy expert system. *Advances in Fuzzy Systems*, Article ID 3632895. <https://doi.org/10.1155/2016/3632895>
- Hyndman, R. J., Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Islam, R., Islam, M. A., Jisan, J. R., Haider, A. M., Al-Muntasir, A. (2024). Prediction of bursting strength and pilling grade of three thread fleece fabric using artificial neural network. *Textile Technicals*, 1(1), 22–27. <https://doi.org/10.63261/ijtem115>
- Jamshaid, H., Hussain, T., Malik, Z. A. (2013). Comparison of regression and adaptive models for predicting the bursting strength of plain knitted fabrics. *Fibers and Polymers*, 14(7), 1203–1207. <https://doi.org/10.1007/s12221-013-1203-3>
- Kargı, V. (2015). Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama (1. bs.). Bursa: Ekin Yayınları.
- Kızılkaya, M. Y., Oğuzlar, A. (2018). Bazı denetimli öğrenme algoritmalarının R programlama dili ile kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, 2018(37), 90–98. <https://doi.org/10.17498/kdeniz.405746>
- Kuhn, M., Johnson, K. (2013). *Applied Predictive Modeling*. Springer. <https://doi.org/10.1007/978-1-4614-6849-3>
- Li, C., Jiang, L. (2006). Using locally weighted learning to improve SMOreg for regression. *Proceedings of the 9th Pacific Rim International Conference on Artificial Intelligence*, 1290–1299, China. https://doi.org/10.1007/11801603_41
- Ljewy, E. Z., Rotich, G. K. (2020). The study of mechanical properties of knitted fabrics: Tear and bursting strength. *Journal of Advanced Research in Polymer and Textile Engineering*, 1(1), 34-40. <https://thejournalshouse.com/index.php/polymer-textile-engineering/article/view/685>
- Mitchell, T. M. (1997). *Machine Learning* (2nd ed.). New York: McGraw–Hill.
- Sevimli, Y. (2009). Çok değişkenli uygulanabilir regresyon uzmanlarının bir split–mouth çalışmasında uygulanması. Yüksek Lisans Tezi. Marmara Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Anabilim Dalı, İstanbul 87s.
- Shamey, R. and Hussain, T. (2003). Artificial Intelligence in the Colour and Textile Industry, *Journal of Color*, 33: 33-45. <https://doi.org/10.1111/j.1478-4408.2003.tb00142.x>
- Smola, A. J., Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Ünal, P. G., Üreyen, M. E., Arınak, D. M. (2010). Predicting bursting strength of plain knitted fabrics using artificial neural networks. *Proceedings of the 2nd International Conference on Agents and Artificial Intelligence (ICAART)*, 615–618. <https://doi.org/10.5220/0002730706150618>
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory* (2nd ed.). Germany: Springer. <https://doi.org/10.1007/978-1-4757-2440-0>
- Witten, I. H., Frank, E., Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (3rd ed.). United States: Morgan Kaufmann.