

PAPER DETAILS

TITLE: Farkli akiskanlar kullanilan Karsit Akisli Ranque-Hilsch Vorteks Tüp sisteminin sogutma performansinin makine ogrenimiyle karsilastirilmasi

AUTHORS: Murat Korkmaz,Ayhan Dogan,Volkan Kirmaci

PAGES: 621-631

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/3193391>



Farklı akışkanlar kullanılan Karşıt Akıslı Ranque–Hilsch Vorteks Tüp sisteminin soğutma performansının makine öğrenimiyle karşılaştırılması

Machine learning comparison of cooling performance of a Counterflow Ranque–Hilsch Vortex Tube system using different fluids

Murat Korkmaz¹ , Ayhan Doğan² , Volkan Kirmaci^{3,*}

^{1,2} Hacettepe Üniversitesi, Başkent OSB Teknik Bilimler Meslek Yüksekokulu, 06909, Ankara Türkiye

³ Bartın Üniversitesi, Mühendislik, Mimarlık ve Tasarım Fakültesi, 74110, Bartın, Türkiye

Öz

Günümüzde ısıtma veya soğutma işlemleri yapıldığında çevreye zarar veren soğutucu akışkanlar kullanılmaktadır. Karşıt Akıslı Ranque-Hilsch Vorteks Tüpü (KARHVT) basit bir borudan oluşmaktadır. RHVT de ısıtma ve soğutma işlemi basınçlı bir akışkan yardımıyla yaparak çevreye çok az zarar vermektedir. Bu çalışmada, tüm deneylerde polyamid ve pırıncı malzemelerden yapılan 2, 3, 4, 5 ve 6 orfisli nozullar kullanılmıştır. Aynı zamanda deneyler esnasında basınçlı akışkan olarak hava ve oksijen gazları ile 1.5 bar ile 7 bar arasında her 0.5 bar değişkenlerinde veriler alınmıştır. Deneylerde alınan sonuçlar ile makine öğrenimi yöntemlerinden Destek vektör makineleri (DVM), Gauss süreç regresyonu (GSR), Lineer regresyonu (LR), Ağaç toplulukları (AT) ve Regresyon Ağaçları (RA) modelleri tahmin edilmiştir. Doğrulama işlemleri için k-fold çapraz doğrulama yöntemi ile beş katlı olarak analizler yapılmıştır. Analizler sonucunda basınçlı akışkanlar oksijen ve hava, malzemelerden polyamid ve pırıncı ile yapılan karşılaştırmalarda en iyi tahmin sonucunu 0,99 ile GSR metoduyla elde edilmiştir. Sonuçlar makine öğrenimi kullanılarak deney düzeneği kurulum maliyetlerinin azaltılabilceğini ve önemli zaman tasarrufu elde edilebileceğini göstermektedir.

Anahtar kelimeler: Soğutma, Isıtma, Vorteks Tüp, Makine öğrenme

1 Giriş

Vorteks tüpleri 1931 yılında Ranque tarafından bulunan, 1947 yılında Hilsch tarafından geliştirilen ve basınçlı bir gaz ile aynı anda ısıtma ve soğutma işlemini yapmasından dolayı Ranque-Hilsch Vorteks Tüp (RHVT) olarak adlandırılmaya başlanmıştır [1]. Vortex tüpleri yapısal özellikleri bakımından düz yönlü akım ve karşıt akımlı olmak üzere imal edilmektedirler. Düz yönlü akımda ısıtma ve soğutma işlemi vorteks tübündeki kontrol vanasının olduğu kısımdan yüzeye yakın çıkıştan sıcak akışkan, merkez kısımdan ise soğuk akışkan olarak çıkmaktadır. Karşıt akımlı vorteks tüplerinde ise kontrol vanasının olduğu bölümde sıcak

Abstract

Today, when heating or cooling processes are carried out, environmentally harmful refrigerants are used. The Counterflow Ranque-Hilsch Vortex Tube (CFRHVT) consists of a simple tube. In RHVT, the heating and cooling process is done with the help of a pressurized fluid, causing little harm to the environment. In this study, 2, 3, 4, 5 and 6 orifice nozzles made of polyamide and brass materials were used in all experiments. At the same time, data were taken with air and oxygen gases as pressurized fluids during the experiments, and at every 0.5 bar, variables between 1.5bar and 7 bar. With the results obtained in the experiments, predictions were made with Support vector machines (SVM), Gaussian process regression (GPR), Linear regression (LR), Ensemble of Tree (ET) and Regression Trees (RT) models from machine learning methods. Five-fold analyses were performed with the k-fold cross-validation method for the validation processes as a result of the investigation. They obtained the best estimation result with the GSR method with 0.99 in the comparisons made with pressured fluids, oxygen and air, and polyamide and brass as the materials. The results show that the cost of experimental setup can be reduced and significant time savings can be achieved using machine learning.

Keywords: Cooling, Heating, Vortex Tube, Machine learning

akışkan, nozulların bağlı olduğu bölümde ise soğuk akışkan meydana gelmektedir.

RHVT ile ilgili literatürde bir çok farklı çalışma bulunmaktadır. Han ve ark. farklı soğutucu akışkanların vorteks tüpleri üzerindeki ısıtma ve soğutma performanslarını incelemiştir [2]. Shamsoddini ve Nezhad vorteks tüplerinde nozül sayılarının etkisi üzerinde çalışmalar yapmışlardır. Çalışmaları sonucunda daha fazla nozül sayısına sahip vorteks tüpünün daha yüksek soğutma gücüne sahip olduğunu bulmuşlardır [3]. Xue ve ark. vorteks tüpte soğuk sıvı fraksiyonunu analiz etmişlerdir. Özellikle soğuk ve sıcak çıkışlar arasındaki dönen akışların eşit bölümü olarak adlandırılan soğuk sıvı fraksiyonunu

* Sorumlu yazar / Corresponding author, e-posta / e-mail: volkankirmaci@bartin.edu.tr (V. Kirmacı)
Geliş / Received: 06.06.2023 Kabul / Accepted: 16.02.2024 Yayımlanma / Published: 15.04.2021
doi: 10.28948/ngumuh.1310811

yaptıkları çalışmada optimize etmişlerdir [4]. Bej ve Sinhamahapatra, sıcak kademeli tip vorteks tüpleri üzerinde çalışmışlardır. Yaptıkları çalışmada, birinci vorteks tüpünden çıkan sıcak gaz akışını, ikinci vorteks tüpü döngüsünün girişini olarak kullanılmışlardır [5]. Skye ve ark. vorteks tüpte CFD (Hesaplama Akışkanlar Dinamiği) sayısız modelleriyle çalışma yapmışlardır. CFD modellerinin vorteks tüpü içindeki termal dağılımin, hız alanının net ve ayrıntılı bir şekilde etkileşimiğini göstermişlerdir [6].

Behera ve ark. VT (Vorteks Tüpü) deki ikincil akış üzerindeki soğuk çıkış alanının etkisini araştırmışlardır. Soğuk çıkış alanı azaldıkça ikincil akışın arttığı sonucuna varmışlardır [7]. Qyyum ve ark. VT' deki akış kontrol vanasının şeclinin ve boyutunun optimize edilmesinin, soğuk çıkış sıcaklığı açısından gelişmiş performansla sonuçlanabileceğini öne sürmüştür. Emme basıncı, geometrik varyasyonlar ve gaz kelebeği biçimleri gibi çeşitli faktörleri dikkate almışlardır [8]. Lewins ve Bejan. VT de dönen akışkan tabakaları arasındaki sürtünmeli bağlantının nedeninin açısal hız olduğunu gözlemlemiştir [9]. Voertks tüpünün iz yapısı Wang ve diğerleri tarafından incelenmiştir [10]. Anish ve ark. VT'nü inceleyerek viskoz kuvvetlerin yaptığı işin, VT bölümünün çevresine yakın yerlerde ısınmanın ana nedeni olduğunu bulmuşlardır [11].

Liang ve ark. giriş basıncını sırasıyla 0.3 MPa, 0.5 MPa ve 0.6 MPa'ya ayarlamışlardır. Daha sonra her giriş basıncında, sıcak uç borusunun ucunda bulunan bir kontrol vanası, farklı soğuk kütle fraksiyonlarını elde edecek şekilde belirlemişler ve soğuk kütle fraksiyonu, soğuk kütle akış hızının giriş gaz kütle akış hızına oranı olarak tanımlamışlardır [12]. Akhmetov ve Akhmetov. Ranque Hilsch vorteks tüpünün akış yapısını deneyel olarak incelemiştir. VT tüm hacimindeki akım çizgileri modelini, lazer Doppleranemometri kullanılarak ölçülen hız dağılımlarından oluşturulmuştur. RHVT yüksek azimut hız radyal dağılımının, teğetsel bir girişe ve tek merkeze sahip olan girdap tüpünden farklı olduğunu göstermişlerdir. Çalışmanın sonunda akışın yapısına dayanarak, sıcaklık ayırmaya etkisinin fiziksel mekanizmasını açıklamak için basit bir nitel model önermişlerdir [13]. Liang ve ark. Ranque-Hilsch vorteks tüpünün akustik sinyal özelliklerini inceleyerek, bunun arkasındaki enerji ayrimı olgusunu tartışmışlardır. Çalışma akışkanı olarak hava kullanılarak deneyler yapılmışlardır. Çalışnanın sonucunda İlginç bir şekilde, 5 nozullu vorteks tüpü, 4 nozullu ve 6 nozullu vorteks tüplerine kıyasla maksimum SPL ve COP (performans katsayı) ürettiğini ortaya koymuşlardır. [14]. Li ve ark. VT farklı koşullar altında eksenel hız profillerinin benzer modelleri göstermesi özelliğine dayanarak sıcak tüp bölgesindeki eksenel hız bileşeni için bir denklem geliştirmiştir. Aynı zamanda çalışma akışkanını sıcak ve soğuk akışkanlara ayıran ters akış sınırının hesaplama yöntemi için, bölmeye modeline dayalı olarak girdap tüplerinin iç akış alanı için nispeten basit bir dizi hesaplama yöntemi oluşturmuştur. Çalışmanın sonucunda, bir girdap tüpü içindeki akış davranışının tahmin edilmesi ve güvenilir tahminler sağlanması için uygun bir hesaplama yöntemi önermişlerdir [15].

Günümüzde deney düzeneğinin kurulum giderlerinin yüksek olması deney düzeneğinde yeterli sayıda testlerin alınmasının önemli bir zaman gerektirebilmektedir. Bu bağlamda, zamandan kazanmak ve sahada yapılan testleri en aza indirmek için günümüzde yapay zekânın bir alt dalı olan makine öğrenimi yöntemleri giderek artan bir şekilde kullanılmaya başlanmıştır. Çalışmada, KARHVT deney sisteminde pırıncı ve polyamid malzemelerinden yapılmış iki, üç, dört, beş ve altı orfisli nozullar kullanılmıştır. KARHVT'te 0.5 bar aralıklarla 1.50 – 7.00 bar arasında giriş basıncında oksijen gazı kullanılarak, çıkan sıcak akış sıcaklığı (T_{sck}) ile çıkan soğuk akışın sıcaklığı (T_{sgk}) arasındaki fark ($\Delta T = T_{sck} - T_{sgk}$) cinsinden performansının optimizasyonunu en doğru tahmin edebilmek amacıyla LR, DVM, GSR, AT ve RA makine öğrenimi yöntemlerinin metotları kullanılmıştır.

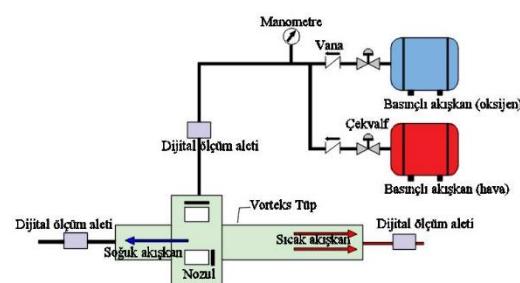
2 Materyal ve metot

Çalışmada kullanılan gövde uzunluğu 10 cm ve iç çapı 0,1 cm olan KARHVT, genişliği 55 cm, yüksekliği 33 cm ve kalınlığı 2 mm, masa üzerine **Şekil 1**'deki gibi yatay olarak sabitlenmiştir.



Şekil 1. KARHVT deney seti

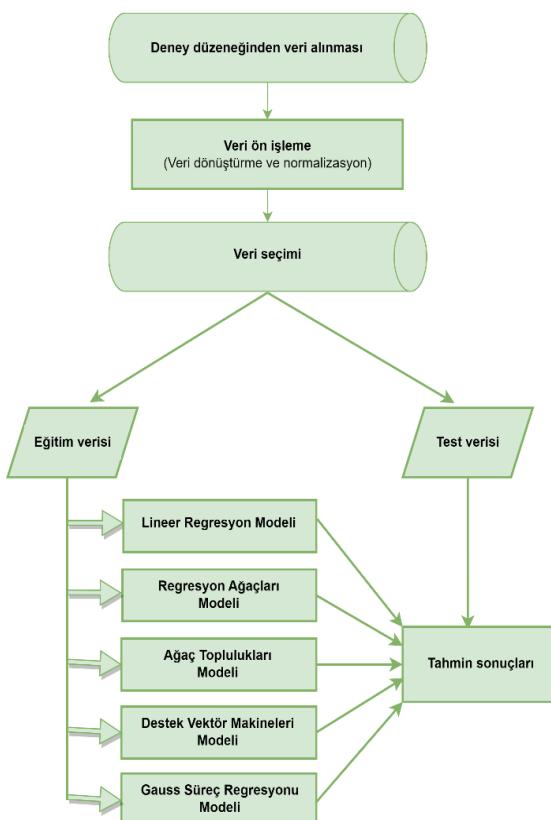
KARHVT'ne giren oksijen gazının basıncını ölçmek için %5 hassasiyetli, 0-16 bar ölçüm aralığında, kullanılabilir ortam sıcaklığının -25°C ile +60°C olduğu TSE837/1 kalite standartında olan PAKKENS tipi manometre kullanılmıştır. KARHVT çıkan sıcak ve soğuk akışın hacimsel debilerini (l/dk), sıcaklıklarını (°C) %1 hassasiyet ve basınç değerlerini (kPa) %10 hassasiyetle ölçen ve hava, azot ve oksijen gazları ile kullanılan debimetre **Şekil 2**'deki gibi yerleştirilerek ölçümleri yapılmıştır.



Şekil 2. KARHVT deney şeması

KARHVT (oksijen gazının giriş basıncını ayarlamak) girişindeki vana yardımıyla deneylerdeki başlangıç basıncı olan 1.5 bar sabitlenerek gönderilmiştir. KARHVT'nün

sıcak-soğuk akış çıkışında bulunan ölçüm cihazlarında okunan sıcaklık değerleri sabitleninceye kadar 1.5 bar basınçta oksijen gazı gönderilerek, girişteki basınç, çıkan sıcak ve soğuk akışkanın sıcaklık değerleri ile hacimsel debiler ölçülmüştür. Daha sonra sırasıyla 2 ile 7 bar basınç değerleri için yapılan deney çalışmalarında 1.5 bar basınçta yapılan işlemler bütün nozullar için tekrarlanmıştır. Deneylerin yapıldığı ortamın sıcaklığı 21°C olarak ayarlanmıştır. Deneylerin her biri üç kez tekrarlanarak ve ortalamaları alınarak deney sonuçlarının doğruluğu yapılarak çalışmada kullanılmıştır.



KARHVT soğuk kütle oranı (μ_c) [Denklem \(1\)](#)'de gösterilmektedir. KARHVT'üne giren basınçlı akışkanın, tüpün çıkışındaki soğuk akışkanın dönüşüğünün bulunmasını sağlayan termodinamiksel hesaplamalar [Denklem \(2-3\)](#)'de verilmiştir. [Denklem \(2\)](#)'de soğuk akış sıcaklık farkı ($\Delta T_{soğ}$), [Denklem \(3\)](#)'de ise sıcak akış sıcaklık farkı (ΔT_{sic}) verilmektedir. KARHVT'nin performansı ise [Denklem \(4\)](#)'de gösterilmiştir [16].

$$\xi = \frac{\text{soğuk akışın kütlesel debisi}}{\text{giriş akışının kütle debisi}} \quad (1)$$

$$\Delta T_{soğ} = T_{gir} - T_{soğ} \quad (2)$$

$$\Delta T_{sic} = T_{sic} - T_{gir} \quad (3)$$

$$\Delta T = T_{sic} - T_{soğ} \quad (4)$$

2.1 Makine Öğrenimi Yöntemleri

Makine öğrenimi metotları farklı sayıda verileri kendi içerisinde kullanarak eğitim modelleri oluşturmaktadır. Daha sonra modelleri en iyi şekilde optimize edebilmek ve uygun algoritmaları kullanarak olası en iyi tahminleri yapabilmek amacıyla büyük miktarda veriye ihtiyaç duymaktadırlar [17].

Bu çalışmada KARHVT'nın ΔT değerleri deney düzeneğinden elde edilen sonuçlar kullanılarak makine öğrenimi yöntemleriyle tahmin edilmiştir. [Şekil 3](#)'de deney düzeneği için hazırlanan makine öğrenimi işlemlerine ait akış şeması gösterilmiştir. Ayrıca analizlerde K-Fold Çapraz doğrulama yöntemi tercih edilerek makine öğrenimi metotlarının karşılaştırılması için doğruluk değerlerinin ölçüsü olan determinasyon katsayısı (R^2), kök ortalama kare hata (RMSE), ortalama kare hata (MSE), ortalama mutlak hata (MAE) değerleri hesaplanmıştır. MSE, tahmin edilen ve deneyden elde edilen sonuçlar arasındaki ortalama karesel farktır. RMSE, MSE'nin karekökü alınarak bulunur. MAE, tahmin edilen ve deneyden elde edilen sonuçlar arasındaki mutlak hataların ortalamasını verir. R^2 bağımsız değişkenlerin bağımlı değişkenin varyansını açıklama yüzdedir.

Bu çalışmada makine öğrenimi işlemleri için Matlab programı kullanılmıştır. Deney düzeneğinden elde edilen veriler üzerinde ön işlemler gerçekleştirilmiştir. Düzenekten Excel formatında derlenen verilerden akışkan ve nozul malzeme ismi barındıran sütunlar sayıya dönüştürülecek Matlab ortamında kullanıma hazır hale getirilmiştir. Bu veriler üzerinde standart normalizasyon uygulanmıştır. Bu işlem Z-score normalizasyonu olarak da bilinmektedir. Bu şekilde değerler ortalama sıfır ve standart sapması bir olan normal dağılıma dönüştürülür. Böylece veri ölçeklerindeki farklılıklar giderilerek verinin belirli bir aralığa sığdırılması sayesinde modelin daha iyi performans göstermesi sağlanır.

Makine öğrenimi çalışmalarında kullanılan girdi ve çıktı parametreleri [Tablo 1](#)'de verilmiştir.

2.1.1 Destek vektör makineleri

DVM, makine öğrenimindeki en popüler algoritmalar arasındadır ve sınıflandırma, regresyon ve aykırı değer tespiti gibi birçok sorunu çözmek için kullanılır. DVM, doğrusal ve doğrusal olmayan sınıflandırma problemleri için kullanılabilir. DVM, sınıflar arasındaki maksimum marjı sağlamak için en iyi ayırmayı yapan bir hiper düzlemler bulur. Bu hiperdüzlemler, iki sınıf arasındaki boşluğu en büyük yapan düzlemler olarak tanımlanabilir. Optimum hiperdüzleme ait [Denklem \(5-6\)](#)'da verilmektedir. Bu denklemlerde $x \in \mathbb{R}^N$ N-boyutlu uzayı, $y \in \{-1,+1\}$ sınıf etiketlerini, b eğilim değerini, w ağırlık vektörünü gösterir.

$$w \cdot x_i + b \geq +1, y = +1 \quad (5)$$

$$w \cdot x_i + b \leq +1, y = -1 \quad (6)$$

DVM aykırı değerlere karşı oldukça dirençlidir. DVM, özellik vektörlerinde aykırı değerleri tespit eder ve sınıflandırmayı etkilemeden bu aykırı değerleri yok sayar. DVM, sınıflandırma doğruluğunu artırmak için sınıf

ağırlıklarını ayarlayabilir ve DVM'nin hata oranını en aza indirmek için kısıtlama koşullarını optimize edebilir. Sonuç olarak, DVM, makine öğrenimi içinde çok popüler bir algoritmadır. DVM, veri madenciliği, görüntü işleme, biyoinformatik, finans ve diğer birçok alanda kullanılmaktadır [18,19].

Tablo 1. Makine öğrenimi çalışmalarında kullanılan girdi ve çıktı parametreleri

Girdi parametreleri					
Akışkan	Nozul Materyali	Nozul sayısı	Basınç (kPa)	k (W/mK)	Çıktı par.
Hava	Pirinç		150,		
			200,		
Hava	Polyamid	2, 3, 4,	250,		
		5, and	300, 400,	117, 0.257,	ΔT
Oksijen	Pirinç	6	450,	116,	
			500,	0.250	
Oksijen	Polyamid		550,		
			600,		
			650, 700		

2.1.2 Ağaç toplulukları

Ağaç toplulukları, daha doğru ve daha iyi bir model oluşturmak için birden fazla karar ağacını birleştiren bir yöntemdir. Bu tekninin temeli, zayıf öğrenenlerin güçlü bir öğrenen yaratmak için birlikte çalışabilmeleridir [20]. Torbalama, hızlandırma ve rastgele orman gibi bir AT oluşturmanın farklı yolları vardır. Bu yöntemler, bireysel ağaçları nasıl oluşturdukları ve birleştirildikleri konusunda farklılık gösterir ve her birinin kendi güçlü yönleri ve sınırlamaları vardır. AT, birçok gerçek dünya problemine ve alanına uygulanabilen güçlü ve çok yönlü bir tekniktir [21,22].

2.1.3 Gauss süreç regresyonu

Gauss Süreç Regresyonu, bazı girdi verilerine dayalı olarak bir fonksiyonun çıktısını tahmin etmek için olasılıksal bir model kullanan bir makine öğrenimi tekniğidir. GSR'nin avantajı, işlevin belirsizliğini ve değişkenliğini yakalayabilmesinin yanı sıra önceki bilgi ve bilgileri birleştirebilmesidir. GSR'nin ana zorluğu, farklı giriş noktaları arasındaki benzerliği tanımlayan ve işlevin şeklini belirleyen uygun bir çekirdek işlemi seçmektir [23]. Ayrıca optimal kernel fonksiyonu belirlenirken farklı kernel fonksiyonları denemeli ve cross-validasyon veya test setlerinde performansları karşılaştırılmalıdır [24, 25]. Gauss süreç fonksiyonu $f(x)$ Denklem (7)'de verilmektedir.

$$f(x) = GP(m(x), k(x, x')) \quad (7)$$

Burada $m(x)$ ortalama fonksiyonu, $k(x, x')$ kovaryans fonksiyonudur. Ortalama fonksiyonu Denklem (8)'de, kovaryans fonksiyonu ise Denklem (9)'da verilmektedir.

$$m(x) = E[f(x)] \quad (8)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x'))] \quad (9)$$

2.1.4 Lineer regresyon

LR, bağımsız ve bağımsız değişkenler arasında doğrusal bir korelasyon olduğu varsayıma dayanır. LR, gelecekteki değerleri tahmin etmek, hipotezleri test etmek veya nedensel etkileri tahmin etmek gibi çeşitli amaçlar için kullanılabilir [26]. Doğrusal regresyon, veri analizi için yaygın olarak kullanılan ve güçlü bir araçtır, ancak aynı zamanda bazı sınırlamaları ve zorlukları vardır. Bunlardan biri, bağımsız değişkenlerden bazıları birbirileyle yüksek oranda ilişkili olduğunda ortaya çıkan çoklu bağlantıdır. Bu, eğimleri ve standart hatalarını tahmin etmede sorunlara neden olabilir ve yanlıltıcı veya yanlış sonuçlara yol açabilir. Başka bir zorluk, x 'in farklı değerleri arasında hata teriminin varyansı sabit olmadığından ortaya çıkan değişen varyanstır. Bu, doğrusal regresyonun varsayımlarından birini ihlal edebilir ve hipotez testlerinin ve güven aralıklarının geçerliliğini etkileyebilir.

LR yönteminde tek bir bağımsız değişken kullanılabileceği gibi birden çok bağımsız değişken de kullanılabilir. Birden çok bağımsız değişken kullanıldığında çoklu lineer regresyon (CLR) adını alır. CLR yöntemine ait eşitlik Denklem (10)'da verilmektedir.

$$y = a_0 + a_1 X_1 + a_2 X_2 + \dots + a_n X_n + \varepsilon \quad (10)$$

Denklem (10)'da birden çok regresyon katsayıları (a_1, a_2, \dots, a_n) ve birden çok bağımsız değişken (X_1, X_2, \dots, X_n) bulunmaktadır.

2.1.5 Regresyon ağaçları

Bir regresyon ağaçısı, bir özelliğin değeri veya hedef değişkenin ortalaması gibi belirli kriterlere dayalı olarak verileri giderek daha küçük alt kümelere bölgerek çalışır. Her alt kümeye, ağaçtaki bir düğümle temsil edilir ve her bir bölme, bir dalla temsil edilir. Ağacın altındaki son düğümlere yapraklar denir ve o alt kümeye veri noktalarının ortalamasına dayalı olarak hedef değişken için tahmin edilen değeri içerirler. Bir regresyon ağaçısı, CART (Sınıflandırma ve Regresyon Ağaçları), CHAID (Ki-kare Otomatik Etkileşim Tespit) veya MARS (Çok Değişkenli Uyarlanabilir Regresyon Çizgileri) [27, 28] gibi çeşitli algoritmalar kullanılarak oluşturulabilir.

3 Bulgular ve tartışma

RHVT ile akışkan olarak hava ve oksijen, malzeme olarak pirinç ve polyamid kullanılarak deneyler gerçekleştirilmiştir. Tüm deneyler 2, 3, 4, 5 ve 6 orfisli nozul kullanılarak ayrı ayrı tekrarlanmıştır. Bu deneylerin sonuçları ile makine öğrenimi eğitimleri ve testleri yapılmıştır. Doğrulama işlemleri k-fold çapraz doğrulama yöntemi ile beş katlı olarak gerçekleştirilmiştir. Makine öğrenimi metodlarının doğruluk değerleri performans metrikleri (R^2 , RMSE, MSE, MAE) incelenerek bulunmuştur.

Hava ve pirinç kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri Şekil 4'de, performans metrikleri tablosu ise Tablo 2'de verilmektedir. Bu sonuçlar incelendiğinde en iyi sonuçların DVM ve GSR yöntemlerine

ait olduğu görülmektedir. Bunları sırasıyla LR, AT ve RA yöntemleri izlemektedir

Tablo 2. Hava ve pirinç kullanılarak gerçekleştirilen makine öğrenimi performans metrikleri

	LR	DVM	GSR	RA	AT
R ²	0.90	0.99	0.99	0.83	0.88
RMSE	5.07	1.55	1.28	6.48	5.42
MSE	25.67	2.39	1.63	41.97	29.40
MAE	4.29	1.20	0.80	5.29	4.36

Hava ve polyamid kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri [Şekil 5](#)'te, performans metrikleri tablosu [Tablo 3](#)'te verilmektedir. Sonuçlar incelendiğinde en iyi sonuçların GSR yöntemine ait olduğu görülmektedir. Onu sırasıyla DVM, AT, LR ve RA yöntemleri izlemektedir.

Tablo 3. Hava ve polyamid kullanılarak gerçekleştirilen makine öğrenimi performans metrikleri

	LR	DVM	GSR	RA	AT
R ²	0.78	0.92	0.99	0.72	0.86
RMSE	5.61	3.45	1.04	6.43	4.46
MSE	31.44	11.91	1.08	41.39	19.91
MAE	4.63	2.65	0.73	5.63	3.80

Oksijen ve pirinç kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri [Şekil 6](#)'da, performans metrikleri tablosu [Tablo 4](#)'te verilmektedir. Bu sonuçlara göre en iyi performansı DVM ve GSR yöntemleri göstermektedir. Bunları sırasıyla LR, AT ve RA yöntemleri izlemektedir.

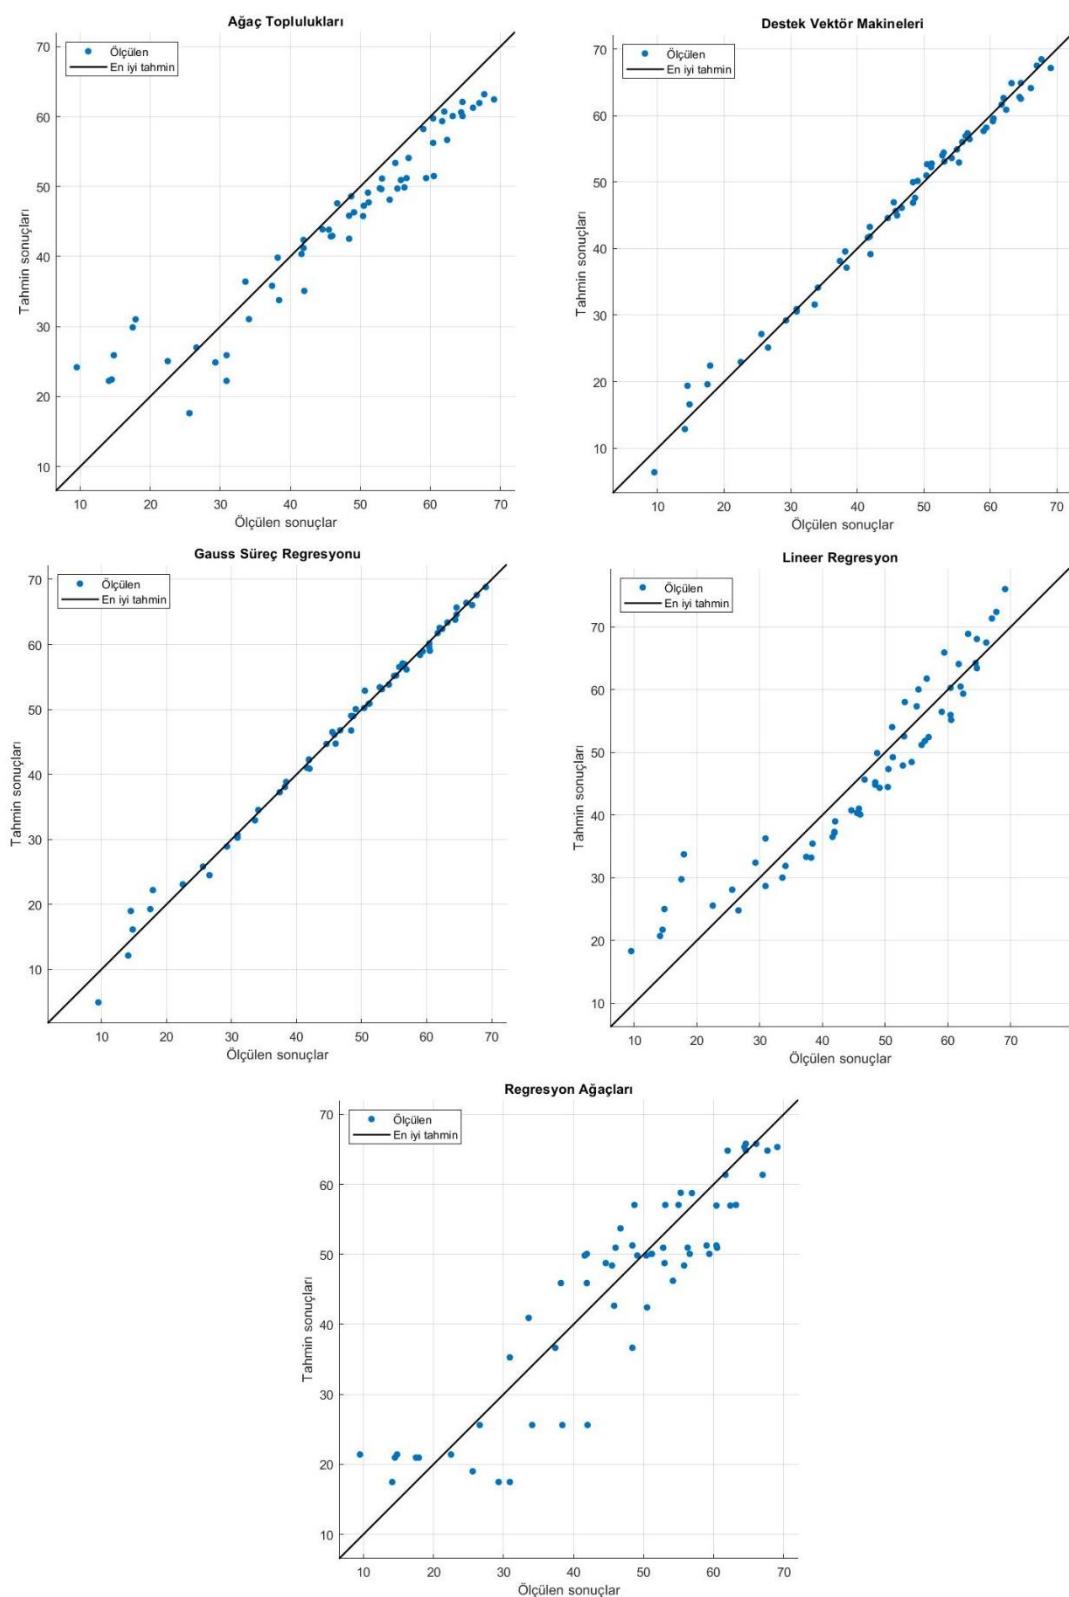
Tablo 4. Oksijen ve pirinç kullanılarak gerçekleştirilen makine öğrenimi performans metrikleri

	LR	DVM	GSR	RA	AT
R ²	0.95	0.99	0.99	0.86	0.91
RMSE	3.70	1.25	0.73	6.01	4.79
MSE	13.68	1.57	0.53	36.14	22.97
MAE	3.05	1.03	0.56	4.95	3.99

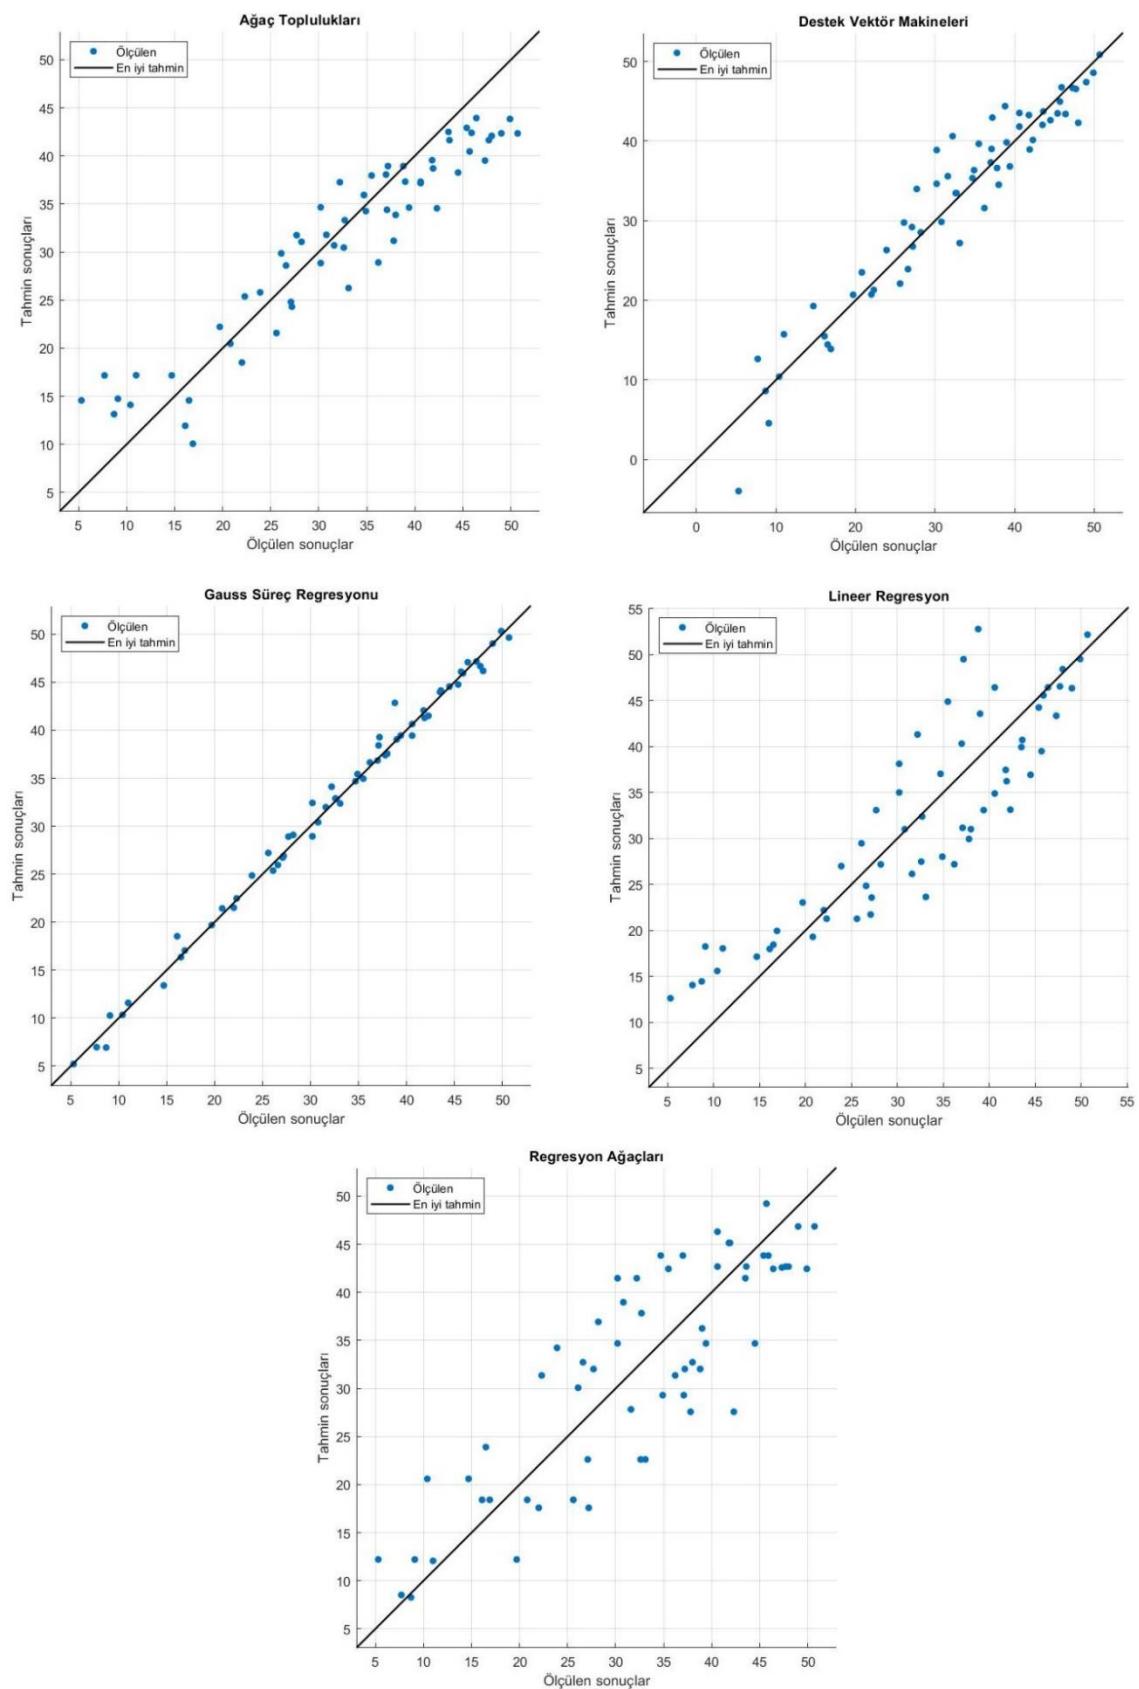
Oksijen ve polyamid kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri [Şekil 7](#)'de, performans metrikleri tablosu [Tablo 5](#)'te verilmektedir. Sonuçlar incelendiğinde en iyi sonucun GSR yöntemine ait olduğu, ona çok yakın değerlerle DVM yönteminin izlediği görülmektedir. Bunları sırasıyla LR, AT ve RA yöntemleri izlemektedir.

Tablo 5. Oksijen ve polyamid kullanılarak gerçekleştirilen makine öğrenimi performans metrikleri

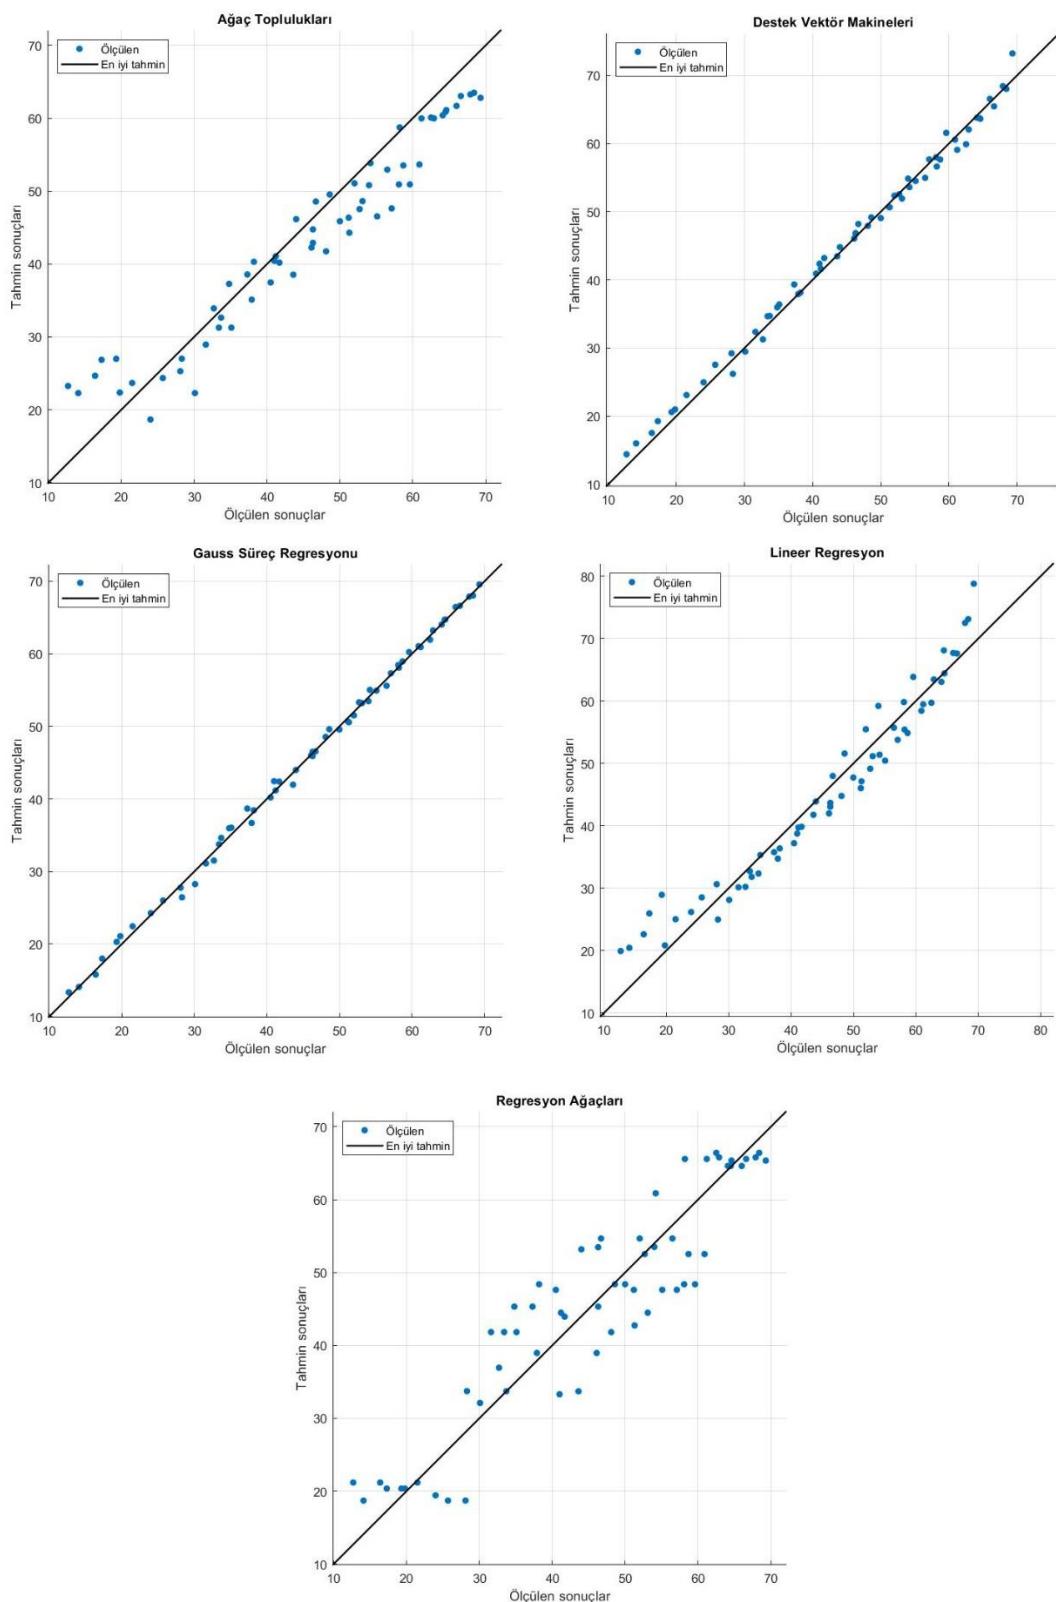
	LR	DVM	GSR	RA	AT
R ²	0.95	0.98	0.99	0.87	0.94
RMSE	3.07	2.08	1.11	4.84	3.45
MSE	9.44	4.34	1.24	23.39	11.91
MAE	2.48	1.66	0.77	4.10	2.77



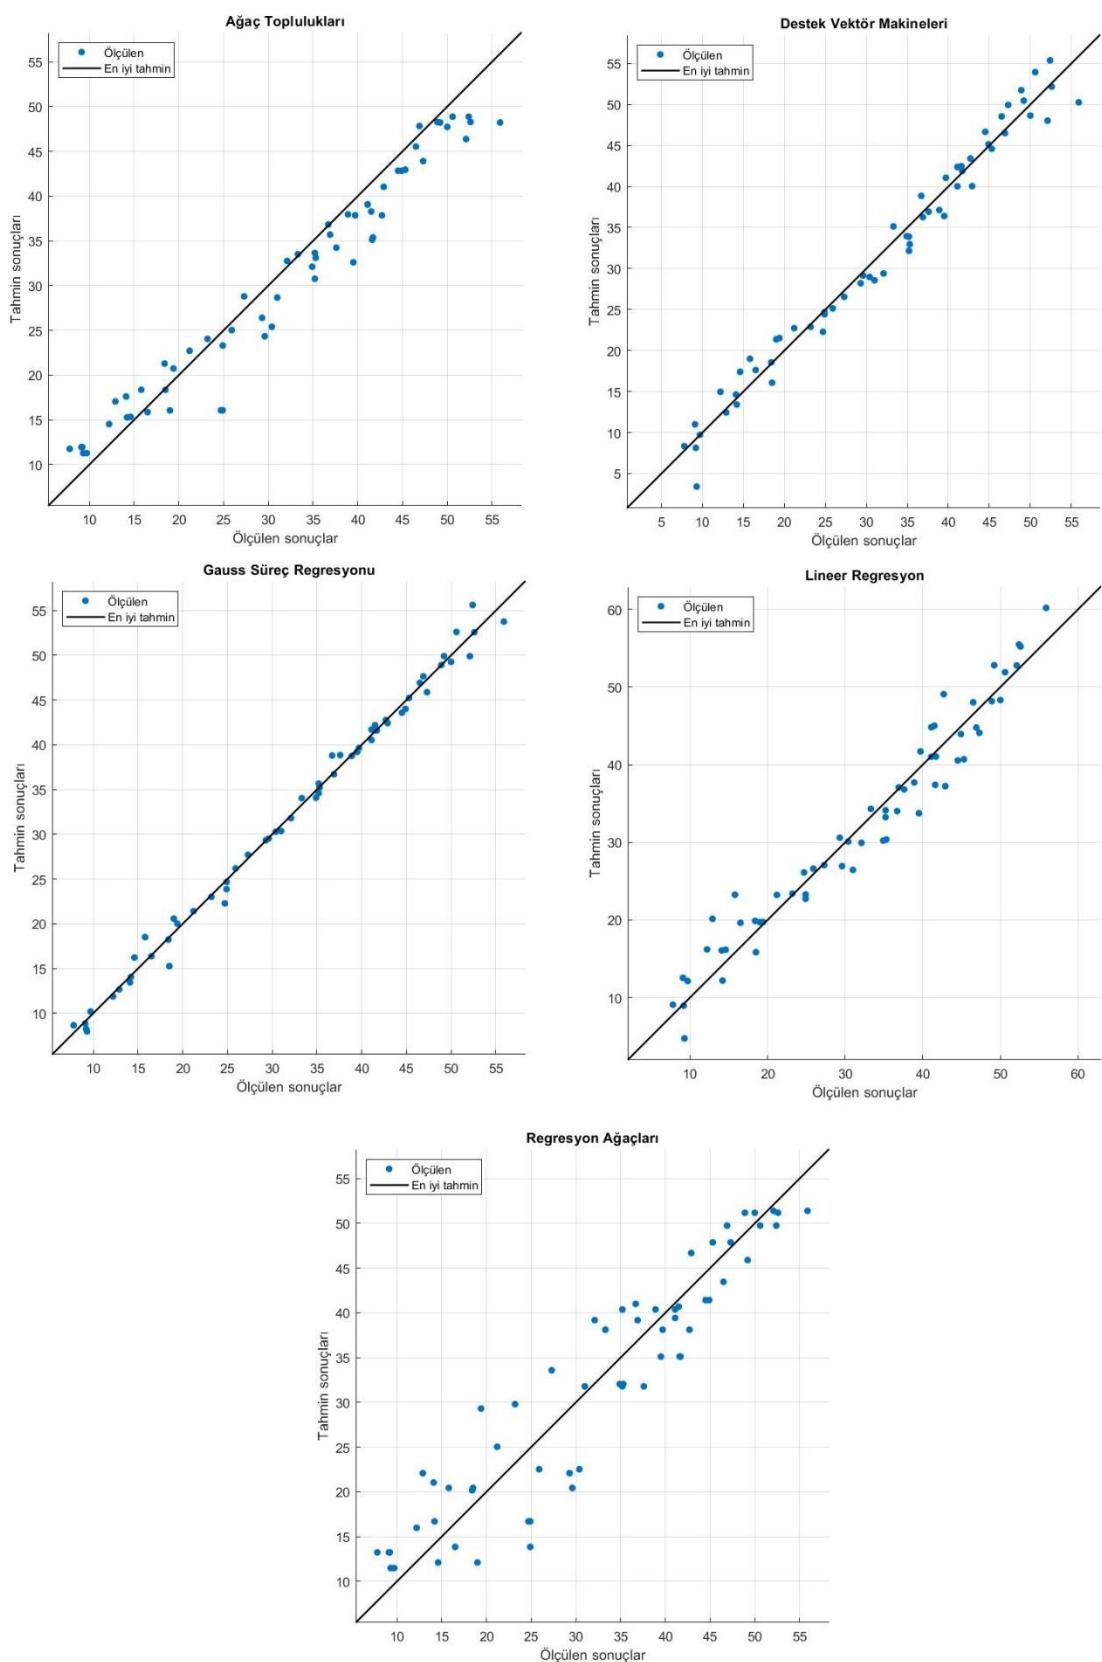
Şekil 4. Hava ve pirinç kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri



Şekil 5. Hava ve polyamid kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri



Şekil 6. Oksijen ve pirinç kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri



Şekil 7. Oksijen ve polyamid kullanılarak gerçekleştirilen makine öğrenimine ait sonuç grafikleri

4 Sonuçlar

Tüm sonuçlar birlikte değerlendirildiğinde GSR yönteminin tüm çalışmalarında en başarılı yöntem olduğu, ona en yakın sonuçların ise DVM yöntemiyle elde edilebilediği görülmektedir. Diğer makine öğrenimi yöntemleri kullanılan akışkan ve malzemeye göre farklılık gösterse de en düşük başarı RA yönteminde elde edilmiştir. Bununla birlikte tüm yöntemler tüm çalışmalarında %70'ın üzerinde başarı göstermişlerdir. Kullanılan akışkanlarla yapılan tüm çalışmalar birlikte karşılaştırıldığında GSR yöntemi haricinde oksijen kullanılarak yapılan çalışmaların başarısının hava kullanılanlardan daha yüksek olduğu söylenebilir. GSR yöntemi tüm çalışmalarında akışkana bağlı olmaksızın yüksek başarı göstermiştir. Bu çalışmada akışkan olarak hava ve oksijen kullanılmıştır. Bu akışkanlarla elde edilen sonuçlar incelendiğinde pirinç ve polyamid malzemeler için sonuçlarda belirgin bir farklılık görülmemiştir. Tüm sonuçlar bu çalışmada kullanılan makine öğrenimi metodlarının RHVT ile yapılacak deney sonuçlarını yüksek başarıyla tahmin edebileceğini ve benzer koşullarda deney yapmaya gerek kalmaksızın kullanılabileceğini göstermektedir. Makine öğrenimi kullanarak deney düzeneği kurulum maliyetlerinin azaltılabileceği, zaman tasarrufu elde edilebileceği ve araştırma çeşitliliği ile literatüre katkı sağlayabileceği görülmektedir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %16

Kaynaklar

- [1] M. Korkmaz, A. Dogan, and V. Kirmacı, Performance Analysis of Counterflow Ranque – Hilsch Vortex Tube with Linear Regression, Support Vector Machines and Gaussian Process Regression Method, *Gazi J. Eng. Sci.*, vol. 8, no. 2, pp. 361–370, 2022. <https://doi.org/10.30855/gmbd.0705015>.
- [2] X. Han et al., The influence of working gas characteristics on energy separation of vortex tube, *Appl. Therm. Eng.*, vol. 61, no. 2, pp. 171–177, 2013. <https://doi.org/10.1016/j.applthermaleng.2013.07.027>.
- [3] R. Shamsoddini and A. H. Nezhad, Numerical analysis of the effects of nozzles number on the flow and power of cooling of a vortex tube, *Int. J. Refrig.*, vol. 33, no. 4, pp. 774–782, 2010. <https://doi.org/10.1016/j.ijrefrig.2009.12.029>.
- [4] Y. Xue, M. Arjomandi, and R. Kelso, The working principle of a vortex tube, *Int. J. Refrig.*, vol. 36, no. 6, pp. 1730–1740, 2013. <https://doi.org/10.1016/j.ijrefrig.2013.04.016>.
- [5] N. Bej and K. P. Sinhamahapatra, Exergy analysis of a hot cascade type Ranque-Hilsch vortex tube using turbulence model, *Energy Econ.*, vol. 45, no. 1947, pp. 13–24, 2014. <https://doi.org/10.1016/j.ijrefrig.2014.05.020>.
- [6] H. M. Skye, G. F. Nellis, and S. A. Klein, Comparison of CFD analysis to empirical data in a commercial vortex tube, *Int. J. Refrig.*, vol. 29, no. 1, pp. 71–80, 2006. <https://doi.org/10.1016/j.ijrefrig.2005.05.004>.
- [7] U. Behera et al., CFD analysis and experimental investigations towards optimizing the parameters of Ranque-Hilsch vortex tube, *Int. J. Heat Mass Transf.*, vol. 48, no. 10, pp. 1961–1973, 2005. <https://doi.org/10.1016/j.ijheatmasstransfer.2004.12.046>.
- [8] M. A. Qyyum, A. A. Noon, F. Wei, and M. Lee, Vortex tube shape optimization for hot control valves through computational fluid dynamics, *Int. J. Refrig.*, vol. 102, pp. 151–158, 2019. <https://doi.org/10.1016/j.ijrefrig.2019.02.014>.
- [9] J. Lewins and A. Bejan, Vortex tube optimization theory, *Energy*, vol. 24, no. 11, pp. 931–943, 1999. [https://doi.org/10.1016/S0360-5442\(99\)00039-0](https://doi.org/10.1016/S0360-5442(99)00039-0).
- [10] W. Wang, C. Wang, Y. Wei, and W. Song, A study on the wake structure of the double vortex tubes in a ventilated supercavity, *J. Mech. Sci. Technol.*, vol. 32, no. 4, pp. 1601–1611, 2018. <https://doi.org/10.1007/s12206-018-0315-5>.
- [11] S. Anish, T. Setoguchi, and H. D. Kim, Computational investigation of the temperature separation in vortex chamber, *J. Mech. Sci. Technol.*, vol. 28, no. 6, pp. 2369–2376, 2014. <https://doi.org/10.1007/s12206-014-0529-0>.
- [12] F. Liang, H. Wang, and X. Wu, Study on energy separation characteristics inside the vortex tube at high operating pressure, *Therm. Sci. Eng. Prog.*, vol. 14, no. September, p. 100432, 2019. <https://doi.org/10.1016/j.tsep.2019.100432>.
- [13] D. G. Akhmetov and T. D. Akhmetov, Flow structure and mechanism of heat transfer in a Ranque–Hilsch vortex tube, *Exp. Therm. Fluid Sci.*, vol. 113, no. December 2019, p. 110024, 2020. <https://doi.org/10.1016/j.expthermflusci.2019.110024>.
- [14] F. Liang, C. Xu, G. Tang, J. Wang, Z. Wang, and N. Li, Experimental investigation on the acoustic characteristics and cooling performance of the vortex tube, *Int. J. Refrig.*, vol. 131, no. August, pp. 535–546, 2021. <https://doi.org/10.1016/j.ijrefrig.2021.08.001>.
- [15] N. Li, G. Jiang, N. Gao, and G. Chen, Simple model for flow field division and flow structure calculation in a vortex tube, *Int. J. Refrig.*, vol. 139, no. October 2021, pp. 48–59, 2022. <https://doi.org/10.1016/j.ijrefrig.2022.04.002>.
- [16] V. Kirmacı, Paralel bağlı karşıt akışlı ranque-hilsch vorteks tüp sisteminde farklı çalışma akışkanı ve nozul malzemesi kullanımının performansa etkisinin deneysel incelenmesi, *Düzce Üniversitesi Bilim ve Teknol. Derg.*, vol. 8, no. 1, pp. 1204–1215, 2020. <https://doi.org/10.29130/dubited.658242>
- [17] J. Wei et al., Machine learning in materials science, *InfoMat*, vol. 1, no. 3, pp. 338–358, 2019. <https://doi.org/10.1002/inf2.12028>
- [18] F. Zhu et al., Biomedical text mining and its applications in cancer research, *J. Biomed. Inform.*, vol. 46, no. 2, pp. 200–211, 2013. doi: <https://doi.org/10.1016/j.jbi.2013.01.001>

- .org/10.1016/j.jbi.2012.10.007.
- [19] X. Zhou et al., Comparison of different machine learning algorithms for predicting air-conditioning operating behavior in open-plan offices, Energy Build., vol. 251, p. 111347, 2021. <https://doi.org/10.1016/j.enbuild.2021.111347>.
- [20] V. A. Dev and M. R. Eden, Formation lithology classification using scalable gradient boosted decision trees, Comput. Chem. Eng., vol. 128, pp. 392–404, 2019. <https://doi.org/10.1016/j.compchemeng.2019.06.001>.
- [21] X. Chen, M. Zahiri, and S. Zhang, Understanding ridesplitting behavior of on-demand ride services: An ensemble learning approach, Transp. Res. Part C Emerg. Technol., vol. 76, pp. 51–70, 2017. <https://doi.org/10.1016/j.trc.2016.12.018>.
- [22] I. Priyadarshini, S. Sahu, R. Kumar, and D. Taniar, A machine-learning ensemble model for predicting energy consumption in smart homes, Internet of Things, vol. 20, p. 100636, 2022. <https://doi.org/10.1016/j.iot.2022.100636>.
- [23] M. Sharifzadeh, A. Sikiniti-Lock, and N. Shah, Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression, Renew. Sustain. Energy Rev., vol. 108, pp. 513–538, 2019. <https://doi.org/10.1016/j.rser.2019.03.040>.
- [24] Z.-L. Ouyang, Z.-J. Zou, and L. Zou, Adaptive hybrid-kernel function based Gaussian process regression for nonparametric modeling of ship maneuvering motion, Ocean Eng., vol. 268, p. 113373, 2023. <https://doi.org/10.1016/j.oceaneng.2022.113373>.
- [25] M. Pal and S. Deswal, Modelling pile capacity using Gaussian process regression, Comput. Geotech., vol. 37, no. 7, pp. 942–947, 2010. <https://doi.org/10.1016/j.comgeo.2010.07.012>.
- [26] Q.-H. Luu, M. F. Lau, S. P. H. Ng, and T. Y. Chen, Testing multiple linear regression systems with metamorphic testing, J. Syst. Softw., vol. 182, p. 111062, 2021. <https://doi.org/10.1016/j.jss.2021.111062>.
- [27] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M. Chica-Rivas, Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines, Ore Geol. Rev., vol. 71, pp. 804–818, 2015. <https://doi.org/10.1016/j.oregeorev.2015.01.001>.
- [28] T.-S. Lee, C.-C. Chiu, Y.-C. Chou, and C.-J. Lu, Mining the customer credit using classification and regression tree and multivariate adaptive regression splines, Comput. Stat. Data Anal., vol. 50, no. 4, pp. 1113–1130, 2006. <https://doi.org/10.1016/j.csda.2004.11.006>.

