






Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Karşıt Akışlı Ranque– Hilsch Vorteks Tüpünün Makine Öğrenmesi Metotları ile Performans Analizi

 Murat KORKMAZ^{a,*},  Ayhan DOĞAN^a,  Volkan KIRMACI^b

^aBaşkent OSB Teknik Bilimler Meslek Yüksekokulu, Hacettepe Üniversitesi, Ankara, TÜRKİYE
Makine Mühendisliği Bölümü, Mühendislik-Mimarlık-Tasarım Fakültesi, Bartın Üniversitesi, Bartın, TÜRKİYE

* Sorumlu yazarın e-posta adresi: mkorkmaz@hacettepe.edu.tr

DOI: <https://doi.org/10.29130/dubited.1267774>

ÖZ

Bu çalışmada, basınçlı oksijen gazı kullanarak aynı anda hem soğutma hem de ısıtma yapabilen ve kontrol vanası dışında hareketli parçası bulunmayan basit borudan meydana gelen Karşıt Akışlı Ranque-Hilsch Vorteks Tüp (KARHVT) kullanılmıştır. KARHVT'nün tasarımında boru 7 mm iç çapında ve 100 mm gövde uzunluğunda imal edilmiştir. Aynı zamanda, nozul olarak pirinç, çelik, alüminyum ve polyamid malzemelerden üretilen 2, 3, 4, 5 ve 6 orfisler kullanılmıştır. Yapılan deneylerde sıcak akışkan tarafında bulunan kontrol vanası tam açık konumda bırakılmış olup, giriş basıncı ilk 150 kPa olarak ayarlanmıştır. Daha sonra 50 kPa aralıklarla 700 kPa kadar veriler alınmıştır. KARHVT'de çıkan soğuk akışın sıcaklığı ($T_{soğ}$) ve çıkan sıcak akış sıcaklığı (T_{sic}) ile arasındaki fark (ΔT) cinsinden bulunarak sistemin performans optimizasyonu yapılmıştır. Sistemin performansının optimizasyonunu, makine öğrenimi metotlarından Lineer Regresyon (LR), Regresyon Ağaçları (RA), Ağaç Toplulukları (AT) ve Destek Vektör Makineleri (DVM) yöntemleri kullanılarak literatürdeki eksikliğin tamamlanması amaçlanmıştır. Çalışmada makine öğrenimi metotlarının her birinin analizi için, tüm verinin %80'i eğitim verisi, tüm verinin %20'si ise test verisi olarak kullanılmıştır. Analizler sonucunda en iyi tahmin sonucu R^2 değeri makine öğrenme metotlarından 0,97 ile DVM ile elde edilmiştir. Ayrıca çalışmanın sonunda eğitilen modeller sonunda gerçekleşen tahmin sonuçları ile gerçek deney sonuçları karşılaştırılmıştır.

Anahtar Kelimeler: Vorteks Tüp, Makine Öğrenme, Lineer Regresyon, Regresyon Ağaçları, Ağaç Toplulukları, Destek Vektör Makineleri


Performance Analysis of Counterflow Ranque– Hilsch Vortex Tube by Machine Learning Methods

ABSTRACT

In this study, the Counter-Flow Ranque-Hilsch Vortex Tube (KARHVT) consists of a simple pipe with no moving parts other than the control valve, which can cool and heat at the same time using pressurized oxygen gas, was used. In KARHVT's design, the pipe is manufactured with an inner diameter of 7 mm and a body length of 100 mm. At the same time, 2, 3, 4, 5 and 6 orchids made of brass, steel, aluminium and polyamide materials were used as nozzles. In the experiments, the control valve on the hot fluid side was left fully open, and the inlet pressure was set as the first 150 kPa. Then, data up to 700 kPa were taken at 50 kPa intervals. The system's performance was optimized by finding the difference (ΔT) between the temperature of the cold flow (T_c) leaving the KARHVT and the temperature of the leaving hot flow (T_h). The optimization of the system's performance is aimed at filling the gap in the literature by using the machine learning methods Linear Regression (LR), Regression Trees (RT), Tree Ensembles (RE) and Support Vector Machines (SVM). For the analysis of each of the machine learning methods in the study, 80% of all data was used as training data and 20% of all data was used as test data. As a result of the analysis, the best estimation results R^2 value was obtained with SVM with 0.97 from machine learning methods. In addition, the estimation results realized at the end of the models trained at the end of the study were compared with the actual experimental results.


I. GİRİŞ

1931 yılında vorteks tüpler Ranque tarafından icat edilmiş olup, daha sonra Hilsch tarafından 1947 yılında geliştirilmiştir. Vorteks tüplerini icat eden ve geliştiren kişilerin adlarından dolayı Ranque-Hilsch Vorteks Tüp (RHVT) olarak isimlendirirler [1]. Kontrol valfi dışında hiçbir hareketli parçası bulunmayan RHVT'ler, ısıtma ve soğutma işlemini aynı anda gerçekleştirildikleri için günümüzde birçok soğutma ve ısıtma işlemlerinde kullanılabilmektedirler [2]. Ağırlıklarının hafif, boyutlarının küçük oluşu, çevresel açıdan zararlı olmaması, kimyasal güç ile bakım gerektirmemeleri ve hızlı bir şekilde rejime ulaşması RHVT'lerin kullanım avantajları arasındadır [3]. Çalışmada da kullanılan KARHVT Şekil 1'de verilmiştir.



Şekil 1. KARHVT.

KARHVT'ünün giriş kısmında bulunan nozul ile kullanılan basınçlı akışkan, teğet olarak giriş yapar. Nozul basınçlı akışkanın basıncını azaltıp, hızını artırır. Hızı artan akış merkezkaç kuvvetinden dolayı tüp cidarına yönünde genişlemeye başlar. Genişleme sonucunda, cidardaki akışkan ile tüp merkezindeki akışkan arasında basınç farkı oluşmaktadır. Daha sonra oluşan basınç farkı nedeni ile akış radyal yönde merkeze doğru genişlemeye başlamaktadır. KARHVT'de merkezdeki akışın açısız hızı tüp cidarındaki akışının açısız hızından yüksek olmasının nedeni, açısız momentumun korunumu ilkesine dayanmaktadır. Bundan dolayı merkezdeki akışkan yüksek hıza sahip olduğunda merkezdeki akışkan KARHVT yüzeyindeki akışkana mekanik enerji transferi yapmaktadır (Şekil 2). Mekanik enerjisi transferi sayesinde merkezdeki akışkan soğuk akışı, tüp cidarındaki akış sıcak akışı meydana getirir ve Şekil 1'de gösterildiği gibi KARHVT'de nozulların bulunduğu kısımdan soğuk akış, kontrol vanasının bulunduğu kısımdan ise sıcak akış olarak sistemi terk eder [4].



Şekil 2. (a) KARHVT içindeki soğuk ve sıcak akış hareketi (b) KARHVT içindeki akış.


Vorteks tüpleri ile ilgili farklı alanlarda literatürde çalışmalar bulunmaktadır. Bu çalışmalarda, Gutak, deneylerde akışkan olarak doğal gaz kullanarak, endüstriyel vorteks tüpünün termal performansını araştırmışlardır [5]. Bej and Sinhamahapatra, yaptıkları deneysel çalışmada ikinci vorteks tüpünün çalışmasını başlatmak için ilk vorteks tüpünden çıkan sıcak havayı kullanarak k-ε türbülans yöntemini

uygulayarak ekserji kapasitesi analizi yapmışlardır [6]. Dutta et al, Vorteks tüplerinde sıcak ve soğuk akışkanın ayırma sürecinin bazı üç boyutlu simülasyonlarını birkaç yeni yolla yapmışlardır. Aynı zamanda NIST' e (Ulusal Standartlar ve Teknoloji Enstitüsü) göre gerçek ve mükemmel gaz modellerini ilk kez karşılaştırmalı biçimde kullanmışlardır [7]. Aynı zamanda Yapay sinir ağları, Taguchi ve Kural tabanlı Mamdani-Tipi Bulanık yöntemler (kod tabanlı yöntemler olarak), geometrik faktörlere (L/D ve soğuk kütle oranı, valf açısı, sıvı tipi ve meme) dayalı VT performansını tahmin etmek için uygulamalar yapılmıştır. Berber v.d, farklı soğuk fraksiyonlar için RHVT'nin ikinci aşamasında ekserji analizine odaklanan standart k-ε türbülans modeli kullanılarak gerçekleştirilen bir dizi sayısal simülasyonun sonuçlarını araştırmışlardır [8]. Pouraria ve Zangoee, vortex tüp kullanmanın etkisini incelemek ve optimum ayrılma açısını bulmak için sayısal bir araştırma yapmışlardır. Tüp içindeki enerji ayırma etkisi için, standart k-ε modelini kullanılarak tüp içinde ısı ve iş transferini araştırmışlardır. Araştırmalarının sonucunda girdap tüp açısındaki bir artışın vorteks tüpünün soğutma performansında bir artışa neden olduğunu bulmuşlardır. Çalışmalarında kritik bir sapma açısı değerinden fazla artış olduğunda soğutma performansının düşebileceğini vurgulamışlardır [9]. Han et al, farklı tipte giriş gazlarının (R32, R728, R134a, R744, R161, R22, O₂, N₂, CO₂, NO₂ ve hava) bir vorteks tüpü üzerinde ısıtma ve soğutma performansının etkilerini incelemişlerdir [10]. Sadi and Gord, (RHVT) performansını artırmak için, yeni bir Anular Vortex Tube (AVT) olarak adlandırılan deneysel tasarımı test ederek, benzer bir tasarım RHVT ile karşılaştırmışlardır. Yapılan karşılaştırmalar sonucunda AVT'nin RHVT'ye kıyasla daha yüksek termal ayırma performansına sahip olduğunu bulmuşlardır. Ayrıca optimum soğuk kütle fraksiyonu için AVT, RHVT'ye kıyasla soğutma verimliliğini yaklaşık %24 artırdığına ulaşmışlardır [11]. Khait et al, RHVT girdaplı sıkıştırılabilir akışın üç boyutlu bir sayısal modelini araştırmışlardır. Araştırmanın sonucunda, RHVT'lerde ampirik katsayıların kalibrasyonundan sonra önerilen enerji korunumu denklemine dayalı yeni sayısal modelin uygulanabilirliğinin gösterilmesini amaçlamışlardır [12]. Eiamsa-ard, RHVT'nde enerji, sıcaklık ayırma olayını ve soğutma verimliliği özellikleri deneysel olarak incelemişlerdir. Deneysel çalışmalar sonucunda, salyangoz girişli RHVT'nün aynı soğuk kütle fraksiyonu ve besleme giriş basıncı altında, nozül sayısındaki artışın, geleneksel teğetsel giriş nozüllü RHVT'nün performansından daha fazla soğuk hava sıcaklığı düşüşü ve soğutma verimliliği sağladığını ortaya koymuşlardır. Ayrıca besleme basıncının, girdap yoğunluğunun artmasına ve dolayısıyla tüpte enerji ayrılmasına yol açtığını vurgulamışlardır [13].

Bu çalışmada, KARHVT'ünde iki, üç, dört, beş ve altı orfisli pirinç, alüminyum, çelik ve polyamid malzemeden üretilmiş nozullar kullanılarak deneyler yapılmıştır. Deneyler 150 ile 700 kPa giriş basıncında 50 kPa basınç aralıklarıyla oksijen gazı kullanılarak her bir farklı malzemeden yapılan nozullar için tekrarlanmıştır. Deneyler sonunda KARHVT'de çıkan T_{sck} ile T_{sgk} arasındaki fark alınarak sıcaklık farkı ΔT hesaplanmıştır. KARHVT' de ΔT performansının analizleri makine öğrenimi metotlarından LR, RA ve AT kullanılarak yapılmıştır. Analizlerde makine öğrenme metotlarında tüm verinin %80'ni eğitim verisi, tüm verinin %20'si de test verisi olarak kullanılmıştır. Ortaya sonuçları determinasyon katsayısı R^2 ortalaması alınarak KARHVT'nin performansları karşılaştırılmıştır.

II. MATERİYAL VE METOT

Çalışmada, iç çapı 0.7 cm, gövde uzunluğu 10 cm olan KARHVT ve deneylerde kullanılan iki, üç, dört, beş ve altı orfisli pirinç, çelik, alüminyum ve polyamid malzemeler Şekil 3 de verilmiştir. KARHVT çıkan sıcak ve soğuk akış sıcaklığını ± 1 °C hassasiyette ölçmek için dijital termometreler kullanılmıştır. KARHVT deneylerde başlangıç basıncını 150 kPa ayarlanması için akışkan girişine vana bağlanmıştır. KARHVT'nün sıcak ve soğuk akış çıkışında bağlı dijital termometrelerden okunan sıcaklık değerleri sabit olana kadar basınç değeri olan 150 kPa oksijen gazı gönderilerek tüm çıktı sonuçları kayıt altına alınmıştır. Deneylerde ortam sıcaklığı 21°C ayarlanmış olup, farklı malzemelerden imal edilen tüm nozullar için diğer basınç aralıklarında da 150 kPa basınçta yapılan işlemler tekrarlanmıştır. Aynı zamanda deneylerin her biri üçer kez tekrarlanarak ortalamaları alınmış ve deney sonuçlarının doğruluğu belirlenerek analizlerde kullanılmıştır.



Şekil 3. Deneysel çalışmada kullanılan KARHVT ve nozullar.

RHVT'ne giren giriş akışkanının ne kadarının vorteks tüpünün çıkışında oluşan soğuk akışa dönüştüğünü gösteren soğuk kütle oranı (μ_c) eşitlik 1'de verilmiştir.

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

RHVT'lerde, eşitlik 4 de gösterildiği gibi RHVT'nin performansı, soğuk akış sıcaklık farkı ($\Delta T_{soğ}$) ve sıcak akış sıcaklık farkı ($\Delta T_{sıc}$) eşitlik 2-3 de gösterilen denklemler çıkarılarak hesaplanmaktadır [1],[14]. Çalışmada kullanılan giriş ve çıkış parametreleri Tablo 1'de gösterilmiştir.

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

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

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

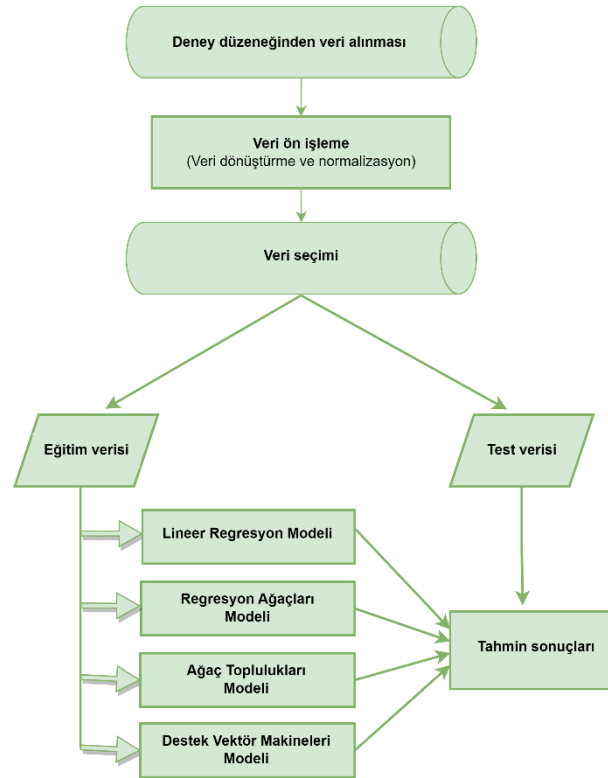
Tablo 1. RHVT'de kullanılan giriş ve çıkış parametreleri

Giriş parametreleri					Çıkış parametreleri
Akışkan	Malzeme	Nozul sayısı	Giriş Basıncı (kPa)	Isı iletim katsayısı (W/mK)	Sıcaklık farkı (K)
Oxygen (1)	Alüminyum (1)	2,3,4,5,6	150 – 700 kPa	226	ΔT
	Çelik (2)	2,3,4,5,6	150 – 700 kPa	23.43	
	Polyamid (3)	2,3,4,5,6	150 – 700 kPa	0.257	
	Pirinç (4)	2,3,4,5,6	150 – 700 kPa	117	

A. MAKİNE ÖĞRENME METOTLARI

Problem çözerken konuyla ilgili verileri eğitim, test ve doğrulama için kullanarak, makine öğrenme metotları ile çözüme ulaşmak amacıyla tahminler yapılmaktadır. Makine öğrenme metotları farklı sayıda verileri kendi içerisinde kullanarak eğitim modelleri oluşturmaktadırlar. Daha sonra modelleri en iyi şekilde optimize edebilmek ve uygun algoritmaları kullanarak olası en iyi tahminleri yapabilmek amacıyla büyük miktarda veriye ihtiyaç duymaktadırlar [15]. Makine öğreniminde birbirinden farklı çok sayıda algoritma mevcuttur. Bu algoritmalarından bazıları; destek vektör makineleri, lineer regresyon, ağaç toplulukları, karar ağaçları, gauss süreç regresyonu, yapay sinir ağları ve rastgele orman'dır. Makine öğrenimi metotları genellikle tahmin, sınıflandırma ve kümeleme gibi farklı amaçlar için değerlendirilebilir [16].

Bu çalışmada hazırlanan deney düzeneğinden elde edilen sonuçlarla RHVT'nin ΔT değerleri makine öğrenimi yöntemleriyle tahmin edilmiştir. Şekil 4'te bu çalışma için kullanılan makine öğrenimi işlemlerine ait akış şeması verilmiştir. Önce deney düzeneği oluşturulmuş ve veriler alınmıştır. Elde edilen verilerde olabilecek hatalar kontrol edilir ve giderilir. Hatadan arındırılan veriler kullanıma uygun hale getirilir. Bu işlem gerçekleştirilirken gerekli görülen bazı veriler, makine öğrenimi matematik modellerine uygun hale getirebilmek amacıyla sayılara dönüştürülür. Bu verilerde standartlaştırma işlemi gerçekleştirilir. Verilerle ilgili bu işlemlerden sonra veri eğitim ve test verisi olarak iki gruba ayrılır. Çalışmamızda tüm verilerin %80'ni eğitim, %20'si de test alınarak, LR, RA, AT ve DVM makine öğrenimi metotları kullanılarak eğitimler yapılmıştır. Eğitimlerden elde edilen modellerle testler gerçekleştirilmiş ve tahminler yapılmıştır.



Şekil 4. Makine öğrenimi işlem akış şeması

A. 1. LİNEER REGRESYON

LR metodu genellikle analizler sonucu elde edilen bağımlı bir değişkenin neden-sonuç ilişkisini bir ya da birden fazla bağımsız değişken arasında bulmaya çalışan bir makine öğrenme modelidir. Bu model, bağımsız değişken veya değişkenlerin, bağımlı değişken ile bir fonksiyon kullanarak ilişkilendirir [17]. LR yönteminde bağımsız değişken bir yada birden çok olabilir. Bağımsız değişken birden çok olduğunda işlem çoklu lineer regresyon (ÇLR) adını alır [18].

A. 2. REGRESYON AĞAÇLARI

Regresyon ağaçları (RA), bağımsız ve bağımlı değişkenlerin arasındaki ilişkiyi ortaya koymaya çalışır. Bunun için topluluğun üyeleri homojen alt sınıflara ayrılır. RA, parametrik bir yöntem değildir. Yöntemde ilk olarak kök düğüm, ardından da dallara ayırma işlemleri gerçekleştirilir. RA metodunda ayırma işlemi düğümdeki bireylerle ilgili belirlenmiş olan bağımsız değişkenler aynı değere ulaştığında durdurulmaktadır. Bu yöntemde, benzer bireyler aynı ağaç düğümünde toplanır.

RA yöntemi kullanılarak gerçekleştirilen tahminlerin ait olduğu özniteliklere ait değerler sürekli gerçek sayılardan oluşur. Tahmin değerlerine ait kare ortalama hata en aza indirgenecek şekilde ağacın büyütülmesi ve dallarına ayrılması sağlanır. Yapraklardaki tahminler düğümde hesaplanan ağırlıklı ortalamalara bağlıdır [19].

RA'da üç ayırma kuralı kullanılır. Bunlar; Least Absolute Deviaton (LAD), Least Squares (LS), Clark&Pregibon (CP). Asıl amaç, olabildiğince homojen düğümler oluşturmaktır [20].

Bu yöntemde, bağımsız değişkenler aralıklarla ayırıldığından kesiklidir. Bu nedenle istenen aralıklardaki tahmin sonuçları benzer çıkabilir.

A. 3. AĞAÇ TOPLULUKLARI

Ağaç toplulukları (AT), bir çok ağaca ait bilgileri aşamalı olarak toplayarak büyütür. Her ağaç kendinden önceki ağaçlardan aldığı bilgilerle büyür. İşleyiş, önce bir regresyon ağacı ile başlar ve daha önce üretilen model artıkları üzerinde yeni regresyon ağaçlarıyla güncellenir. Model, sonuç değişkeni yerine modelin kalıntılarına ağaç yerleştirerek ilerler. Yeni ağaç, artıkları güncellemek amacıyla fonksiyona eklenir. Her ağaç, yetmişmiş ağaçlara büyük oranda bağlıdır[21].

Topluluk sınıflandırıcı sistemi olarak AT modeli kullanılabilir. Makine öğreniminde yaygın olarak araştırılan ve kullanılan yaklaşımlardan biri çoklu sınıflandırıcılardır. Literatürde yapılan çalışmaların çoğunda, tek bir kararsız sınıflandırıcı yapılan çalışmaların, birçok kararsız sınıflandırıcının tek bir toplu sınıflandırıcıda birleştirilmesinin göre performansının azaldığı anlaşılmaktadır [21],[22],[23],[24]. Kararsız sınıflandırıcılara örnek olarak, karar ağaçları ve sinir ağları verilebilir [25]. Özellikle eğitim setindeki küçük bir bozulma bile kararsız sınıflandırıcıların tahmin yeteneğini olumsuz şekilde etkileyebilir. Bundan dolayı karar ağaçları ve sinir ağları topluluklarının çeşitli stratejilere sahip olmasından dolayı benzer çalışmalar için önerilmektedir [21],[27]. Makine öğrenme metodları içerisinde rastgele orman bu tür topluluklara gösterilebilecek güzel bir yöntemdir [28]. Karar ağaçları sınıflandırma ve regresyon görevlerinde yüksek performans meydana getiren, torbalama ve rastgele alt uzay yöntemleri kullanılarak oluşan bir komitedir [29].

AT'nda, gradyan artırma ve rastgele orman gibi çeşitli topluluk yöntemlerini, sınıflandırma performansını iyileştirmek için daha sık kullanılmaktadır. Karar ağaçları, çok daha az parametreye ihtiyaç duymasının nedeni sinir ağı tabanlı sınıflandırıcılar ile karşılaştırıldığında eğitim ve sınıflandırmada çok daha hızlı olmasından kaynaklanmaktadır. Bu yöntem paralelleştirilebilmesi ve gürültüyü etiketlemesi nedeniyle kullanılan güçlü bir yöntemdir [30].

A.4. DESTEK VEKTÖR MAKİNELERİ

Destek vektör makineleri (DVM), ilk defa 1990'lı yıllarda ortaya çıkmıştır [31]. DVM algoritması, veri hakkında bütünlük dağılım fonksiyonuna gereksinimi olmadığından dağılımdan bağımsız çalışabilir [32]. Burada amaç, sınıfların ayrıştırılabilmesi için en uygun ayırma hiperdüzleminin tespit edilebilmesidir. Birbirinden farklı olan sınıflar için destek vektörleri arasındaki uzaklığın en büyük olması sağlanmaya çalışılır [33]. DVM, verileri gruplara ayıran n-boyutlu bir hiperdüzlemi en uygun şekilde oluşturur. Bu yöntem yapay sinir ağlarındaki çeşitli yöntemleri beraber kullanabilirler [34],[35]. DVM, iyi bir genelleme yeteneğine sahiptir ve bu sayede ses ve yüz tanıma, sınıflandırma gibi bir çok alanda kullanılabilir [36].

Bu yöntem önceleri doğrusal verilerin sınıflandırılması için kullanılmışsa da bugün doğrusal olmayan ve çok sınıflı veriler üzerinde de kullanılmaktadır [37]. En iyi hiperdüzleme ait eşitlikler 5 ve 6'da verilmektedir.

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

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

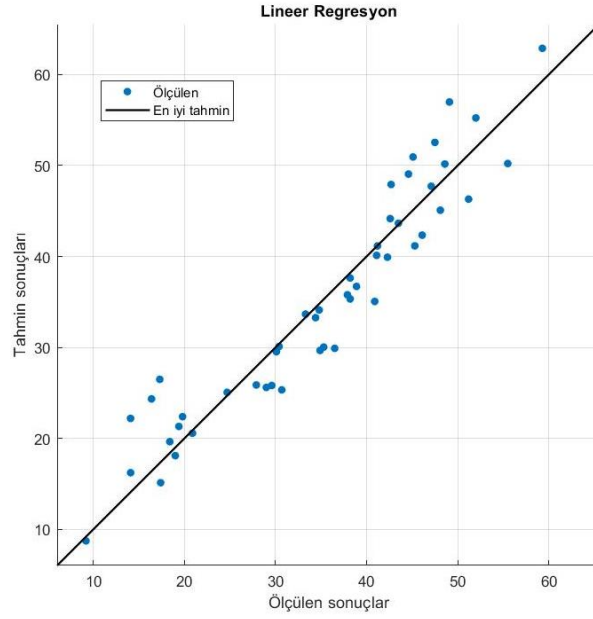
Burada $x \in R^N$ N-boyutlu uzayı, $y \in \{-1, +1\}$ sınıf etiketlerini, w ağırlık vektörünü, b eğilim değerini göstermektedir [38].

Bazen veriler doğrusal ayrılamayabilir. Böyle durumlarda verilerin hatalı sınıflandırılmaması amacıyla düzenleme parametresi ve yapay değişken kullanılır. Bu şekilde en iyi durumu bulmak için problemin çözümü gerçekleştirilmeye çalışılır [37].

Çalışmada KARHVT'ünde giriş ve çıkışlar arasındaki ilişkinin ortaya konulabilmesi için LR, RA, AT ve DVM makine öğrenimi tüm verinin %80'i eğitim, %20'si ise test amacıyla kullanılmıştır.

III. BULGULAR VE TARTIŞMA


RHVT ile gerçekleştirilen deney sonuçları kullanılarak makine öğrenimi için eğitim ve testler yapılmıştır. Çalışma sonunda LR, RA, AT ve DVM metodlarıyla gerçekleştirilen testlerin sonuç grafikleri Şekil 5, Şekil 6, Şekil 7 ve Şekil 8'de verilmiştir. Aynı zamanda test tahmin sonuçlarından elde edilen doğruluk/uyumluluk değerleri Tablo 2' de gösterilmiştir.



Şekil 5. Makine Öğrenimi Metodu “LR” Tahmin Sonuçları Grafiği (ΔT)


Ayrıca makine öğrenme yöntemleri içerisinde Lineer regresyon yönteminden elde edilen sonuçları Şekil 5’de incelediğimizde ölçülen gerçek deney verileri ile tahmin edilen sonuçların en iyi tahmin eğrisi üzerinde birbirlerine yaklaşık değerler verdiği görülmektedir. Lineer regresyon yöntemi ile yapılan KARHVT’nün sıcaklık farkını R^2 değerinin %90, RMSE değerinin 3,94, MSE değerinin 15,49 ve MAE değerinin ise 3,11 olduğu görülmektedir.

Makine öğrenme yöntemleriyle yapılan tüm sonuçlar birlikte değerlendirildiğinde Şekil 6’da RA yöntemindeki başarı diğer metotlarla karşılaştırıldığında R^2 değeri %75 olarak bulunmuştur. Regresyon ağaçları yöntemi yapılan deneysel çalışma verileri ile kullanılabilir ölçekte sonuçlar üretmiştir.




Şekil 6. Makine Öğrenimi Metodu “RA” Tahmin Sonuçları Grafiği (ΔT)

Ağaç toplulukları metodu ile yapılan analiz sonuçları incelendiğinde hem deney sonuçlarının hem de tahmin sonuçlarının en iyi tahmin eğrisi üzerinde olduğu Şekil 7’ de görülmektedir. Bununla birlikte ağaç toplulukları metodunun KARHVT’nün sıcaklık farkını R^2 değeri ise %92 olarak bulunmuştur.



Şekil 7. Makine Öğrenimi Metodu “AT” Tahmin Sonuçları Grafiği (AT)

Çalışmada kullanılan makine öğrenimi metodlarından en yüksek doğruluk değerleri performans metrikleri (R^2 , RMSE, MSE, MAE) incelenerek bulunmuştur. Buna göre en iyi metod Şekil 8’de görüldüğü gibi DVM metodudur. Metodların ürettiği tahmin sonuçlarına ait metriklerdeki farklılıklar, kullanılan metodlarından algoritmasından, veri sayısından ve metodların uygulandığı alandan kaynaklanabileceği düşünülmektedir.



Şekil 8. Makine Öğrenimi Metodu “DVM” Tahmin Sonuçları Grafiği (AT)

Tablo 2. Makine Öğrenimi Performans Ölçüm Metrikleri

	LR	RA	AT	DVM
Determinasyon Katsayısı (R^2)	0,90	0,75	0,92	0,97
Kök Ortalama Kare Hata (RMSE)	3,94	6,20	3,57	2,59
Ortalama Kare Hata (MSE)	15,49	38,48	12,76	6,2
Ortalama Mutlak Hata (MAE)	3,11	5,27	2,82	1,97

IV. SONUÇ VE ÖNERİLER

Çalışmada, makine öğrenme yöntemlerinden üç farklı yöntem kullanılarak karşıt akışlı RHVT'ünden alınan sonuçlar ile eğitimler yapılmıştır. Eğitimler sonucunda RHVT'nün sıcaklık farkının (ΔT) R^2 değerleri sırasıyla, Lineer Regresyon yönteminde 0,90, Regresyon Ağaçları yönteminde 0,75, Ağaç Toplulukları yönteminde 0,92 ve Destek Vektör Makineleri yönteminde 0,97 bulunmuştur. Modellemelerde test sonuçlarının gerçek deney sonuçlarına yakın değerler verdiğinin göstergesi elde edilen R^2 değerleridir. Aynı zamanda eğitim modellerinin RMSE değerleri kıyaslandığında en iyi ΔT değerini DVM yöntemi ile ulaşıldığı görülmektedir. Ayrıca RA yöntemi ile elde edilen RMSE değerlerinin diğer iki yöntem ile kıyaslandığında daha düşük tahmin sonuçları verdiği Tablo 1.'de anlaşılmaktadır.

Bu sonuçlar değerlendirildiğinde;

Kullanılan makine öğrenme yöntemleri içerisinde en iyi sonucu DVM yönteminin verdiği anlaşılmaktadır. Bu deney şartlarına uygun verilerle çalışıldığında, makine öğrenme yöntemleri içerisinde DVM yöntemi ile kullanıldığında daha doğru sıcaklık farkı (ΔT) değerlerine ulaşılabileceği görülmektedir. Aynı zamanda regresyon ağaçları yönteminin R^2 değerinin doğruluğunun kabul edilebilir fakat diğer iki yöntemin R^2 değerinden düşük olduğu bulunmuştur. Makine öğrenme yöntemi hem RHVT sistemlerinin hem de diğer deneysel sistemlerin kurulmasında maliyet ve zaman kaybının en aza indirilmesini sağlaması amacıyla kullanılabilir. Makine öğrenme yöntemlerinin karşıt akışlı RHVT' lerinde performans analizlerini önceden görebilmek için rahatlıkla kullanılabileceği anlaşılmaktadır.

V. KAYNAKLAR

- [1] M. Korkmaz, A. Dogan, and V. Kırmacı, "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, doi: doi:10.30855/gmbd.0705015.
- [2] Kırmacı, V, Kaya, H and Cebeci, i, "An experimental and exergy analysis of a thermal performance of a counter flow ranque–hilsch vortex tube with different nozzle materials," *Int. J. Refrig.*, vol. 85, no. 2018, pp. 240–254, 2018.
- [3] H. Kaya, O. Uluer, E. Kocaoğlu, and V. Kırmacı, "Experimental analysis of cooling and heating performance of serial and parallel connected counterflow Ranque–Hilsch vortex tube systems using carbon dioxide as a working fluid," *Int. J. Refrig.*, vol. 106, pp. 297–307, 2019, doi: 10.1016/j.ijrefrig.2019.07.004.

- [4] W. Fröhlingsdorf and H. Unger, "Numerical investigations of the compressible flow and the energy separation in the Ranque-Hilsch vortex tube," *Int. J. Heat Mass Transf.*, vol. 42, no. 3, pp. 415–422, 1998, doi: 10.1016/S0017-9310(98)00191-4.
- [5] A. D. Gutak, "Experimental investigation and industrial application of Ranque-Hilsch vortex tube," *Int. J. Refrig.*, vol. 49, no. 0, pp. 93–98, 2015, doi: 10.1016/j.ijrefrig.2014.09.021.
- [6] 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, doi: 10.1016/j.ijrefrig.2014.05.020.
- [7] T. Dutta, K. P. Sinhamahapatra, and S. S. Bandyopadhyay, "Numerical investigation of gas species and energy separation in the Ranque-Hilsch vortex tube using real gas model," *Int. J. Refrig.*, vol. 34, no. 8, pp. 2118–2128, 2011, doi: 10.1016/j.ijrefrig.2011.06.004.
- [8] A. Berber, K. Dincer, Y. Yilmaz, and D. N. Ozen, "Rule-based Mamdani-type fuzzy modeling of heating and cooling performances of counterflow Ranque-Hilsch vortex tubes with different geometric construction for steel," *Energy*, vol. 51, pp. 297–304, 2013, doi: 10.1016/j.energy.2013.01.005.
- [9] H. Pouraria and M. R. Zangoee, "Numerical investigation of vortex tube refrigerator with a divergent hot tube," *Energy Procedia*, vol. 14, no. 2011, pp. 1554–1559, 2012, doi: 10.1016/j.egypro.2011.12.1132.
- [10] 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, doi: 10.1016/j.applthermaleng.2013.07.027.
- [11] M. Sadi and M. Farzaneh-Gord, "Introduction of Annular Vortex Tube and experimental comparison with Ranque-Hilsch Vortex Tube," *Int. J. Refrig.*, vol. 46, pp. 142–151, 2014, doi: 10.1016/j.ijrefrig.2014.07.004.
- [12] A. V. Khait, A. S. Noskov, A. V. Lovtsov, and V. N. Alekhin, "Semi-empirical turbulence model for numerical simulation of swirled compressible flows observed in Ranque-Hilsch vortex tube," *Int. J. Refrig.*, vol. 48, pp. 132–141, 2014, doi: 10.1016/j.ijrefrig.2014.09.006.
- [13] S. Eiamsa-ard, "Experimental investigation of energy separation in a counterflow Ranque-Hilsch vortex tube with multiple inlet snail entries," *Int. Commun. Heat Mass Transf.*, vol. 37, no. 6, pp. 637–643, 2010, doi: 10.1016/j.icheatmasstransfer.2010.02.007.
- [14] V. Kırmacı, "Paralel bağlı karşıt akışlı ranque-hilsch vorteks tüp sisteminde farklı çalışma akışkanı ve nozul malzemesi kullanımının performans etkisinin deneysel incelenmesi," *Düzce Üniversitesi Bilim ve Teknol. Derg.*, vol. 8, no. 1, pp. 1204–1215, 2020.
- [15] J. Wei *et al.*, "Machine learning in materials science," *InfoMat*, vol. 1, no. 3, pp. 338–358, 2019.
- [16] T. E. Kalaycı, "Kimlik hırsızı web sitelerinin sınıflandırılması için makine öğrenmesi yöntemlerinin karşılaştırılması," *Pamukkale Üniversitesi Mühendislik Bilim. Derg.*, vol. 24, no. 5, pp. 870–878, 2018.
- [17] 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.
- [18] S. Rong and Z. Bao-Wen, "The research of regression model in machine learning field," in *MATEC Web of Conferences*, 2018, vol. 176, p. 1033.
- [19] L. Rokach and O. Z. Maimon, *Data mining with decision trees: theory and applications*, vol. 81. World scientific, 2014.
- [20] G. Temel Orekici, "Sınıflama ve regresyon ağaçları," Mersin Üniversitesi Sağlık Bilimleri Enstitüsü, Mersin, 2004.
- [21] F. Schiltz, C. Masci, T. Agasisti, and D. Horn, "Using regression tree ensembles to model interaction effects: a graphical approach," *Appl. Econ.*, vol. 50, no. 58, pp. 6341–6354, 2018.
- [22] D. Opitz and R. Maclin, "Popular ensemble methods: An empirical study," *J. Artif. Intell. Res.*, vol. 11, pp. 169–198, 1999.
- [23] T. G. Dietterich, "Ensemble methods in machine learning," in *International workshop on multiple classifier systems*, 2000, pp. 1–15.
- [24] G. Valentini and F. Masulli, "Ensembles of learning machines," in *Italian workshop on neural nets*, 2002, pp. 3–20.
- [25] L. Rokach, "Ensemble-based classifiers," *Artif. Intell. Rev.*, vol. 33, no. 1, pp. 1–39, 2010, doi:

- 10.1007/s10462-009-9124-7.
- [26] L. Breiman, "Bias, variance, and arcing classifiers," Tech. Rep. 460, Statistics Department, University of California, Berkeley ..., 1996.
- [27] Z.-H. Zhou, J. Wu, and W. Tang, "Ensembling neural networks: Many could be better than all," *Artif. Intell.*, vol. 137, no. 1, pp. 239–263, 2002, doi: [https://doi.org/10.1016/S0004-3702\(02\)00190-X](https://doi.org/10.1016/S0004-3702(02)00190-X).
- [28] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [29] R. Katuwal, P. N. Suganthan, and L. Zhang, "An ensemble of decision trees with random vector functional link networks for multi-class classification," *Appl. Soft Comput.*, vol. 70, pp. 1146–1153, 2018.
- [30] M. Shoaran, B. A. Haghi, M. Taghavi, M. Farivar, and A. Emami-Neyestanak, "Energy-efficient classification for resource-constrained biomedical applications," *IEEE J. Emerg. Sel. Top. Circuits Syst.*, vol. 8, no. 4, pp. 693–707, 2018.
- [31] V. Vapnik, "The nature of statistical learning theory," *NY Springer-Verlag*, 1995.
- [32] K. P. Soman, R. Loganathan, and V. Ajay, *Machine learning with SVM and other kernel methods*. PHI Learning Pvt. Ltd., 2009.
- [33] S. Ayhan and Ş. Erdoğmuş, "Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi," *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilim. Derg.*, vol. 9, no. 1, pp. 175–201, 2014.
- [34] S. Tolun, "Destek vektör makineleri: Banka başarısızlığının tahmini üzerine bir uygulama," İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2008.
- [35] S. Haykin, "Neural Networks, a comprehensive foundation, Prentice-Hall Inc," *Up. Saddle River, New Jersey*, vol. 7458, pp. 161–175, 1999.
- [36] N. Cristianini and J. Shawe-Taylor, *An introduction to support vector machines and other kernel-based learning methods*. Cambridge university press, 2000.
- [37] T. Kavzoğlu and İ. Çölkesen, "Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi," *Harit. Derg.*, vol. 144, no. 7, pp. 73–82, 2010.
- [38] S. Huang, N. Cai, P. P. Pacheco, S. Narrandes, Y. Wang, and W. Xu, "Applications of support vector machine (SVM) learning in cancer genomics," *Cancer Genomics Proteomics*, vol. 15, no. 1, pp. 41–51, 2018.