

GAZİ

JOURNAL OF ENGINEERING SCIENCES

Performance Analysis of Counterflow Ranque – Hilsch Vortex Tube with Linear Regression, Support Vector Machines and Gaussian Process Regression Method

Murat Korkmaz^a, Ayhan Dogan^b, Volkan Kirmaci^c

Submitted: 30.04.2022 Revised: 18.05.2022 Accepted: 07.06.2022 doi:10.30855/gmbd.0705015

ABSTRACT

Keywords: Vortex tube, Linear regression, Support vector machines, Gaussian process regression, Machine learning

^a, Hacettepe University, Başkent OSB Vocational Higher School of Technical Sciences, Department of Electrical and Energy, 06909, Ankara, Türkiye
Orcid: 0000-0002-3721-2854

^b, Hacettepe University, Başkent OSB Vocational Higher School of Technical Sciences, Department of Computer Technologies, 06909 - Ankara, Türkiye
Orcid: 0000-0002-9872-8889

^c Bartın University
Faculty of Engineering,
Architecture and Design,
Department of Mechanical Engineering,
74110-Bartın, Türkiye
Orcid: 0000-0001-7076-1911
e mail: volkankirmaci@bartin.edu.tr

*Corresponding author:
volkankirmaci@bartin.edu.tr

Ranque-Hilsch Vortex Tube (RHVT) is a system that consists of a simple pipe with no moving parts except for the control valve, working with pressurized fluid and performing both heating and cooling processes at the same time. In the study, air with an inlet pressure of 150 to 700 kPa at 50 kPa intervals was used in RHVT with an internal diameter of 7 mm and a body length of 100 mm. In RHVT, nozzles with two, three, four, five and six orifices made of aluminum, steel, brass and polyamide were used. During the experimental study, the control valve on the hot fluid outlet side was left in the fully open position and the performance of the RHVT was calculated by calculating the difference (ΔT) between the outlet hot flow temperature (T_h) and the leaving cold flow temperature (T_c). The data obtained from the experimental setup were used separately with the machine learning methods Linear Regression (LR), Support Vector Machines (SVM) and Gaussian Process Regression (GPR) methods, and the performance of RHVT was optimized and it was aimed to fill the gap in the literature. During the machine learning methods in the study, 80% of all data was used as training and 20% as test data. Tests were made with the models obtained at the end of the study and the results were compared.

Karşıt Akışlı Ranque – Hilsch Vorteks Tüpünün Lineer Regresyon, Destek Vektör Makineleri ve Gauss Süreç Regresyonu Yöntemi ile Performans Analizi


ÖZ

Ranque-Hilsch Vorteks Tüp (RHVT) kontrol valfi haricinde hareketli parçası olmayan, basit bir borudan oluşan, basınçlı akışkan ile çalışarak ısıtma soğutma işlemini aynı anda yapan bir sistemdir. Çalışmada iç çapı 7 mm, gövde uzunluğu 100 mm olan RHVT’de giriş basıncı 50 kPa aralıklarla 150 ile 700 kPa basınç değerinde hava kullanılmıştır. RHVT’de alüminyum, çelik, pirinç ve polyamid malzemeden üretilmiş iki, üç, dört, beş ve altı orifslü nozzullar kullanılmıştır. Deneysel çalışma esnasında sıcak akışkan çıkışı tarafındaki kontrol valfi tam açık konumda bırakılarak, RHVT’ünün performansı çıkan sıcak akış sıcaklığı (T_{sck}) ile çıkan soğuk akışın sıcaklığı (T_{sgk}) arasındaki fark (ΔT) hesaplanarak veriler alınmıştır. Deneysel çalışmadan elde edilen veriler makine öğrenimi yöntemlerinden Lineer Regresyon (LR), Destek Vektör Makineleri (DVM) ve Gauss Süreç Regresyonu (GSR) yöntemleri ile ayrı ayrı kullanılarak RHVT’nin performansının optimizasyonu yapılmış ve literatürdeki eksikliğin tamamlanması amaçlanmıştır. Çalışmada makine öğrenme yöntemleri esnasında tüm verinin %80’i eğitim, %20’si test verisi olarak kullanılmıştır. Çalışma sonunda elde edilen modeller ile testler yapılmış ve ortaya çıkan sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler: Vorteks tüp, Lineer regresyon, Destek vektör makineleri, Gauss süreç regresyonu, Makine öğrenimi


1. Giriş (Introduction)

Kontrol valfi hariç hiçbir hareketli bir parçası olmayan, soğutma ve ısıtma işlemini aynı anda yapan ebatları küçük ama hızlı rejime giren vorteks tüpler ilk kez 1931 yılında Ranque tarafından ilk kez icat edilmiş ve daha sonra 1947 yılında Hilsch tarafından geliştirilmiştir [1, 2]. Vorteks tüp, Ranque-Hilsch Vorteks Tüp (RHVT) olarak adlandırılmasının nedeni kendisini bulan ve geliştiren kişilerin adlarını almasından kaynaklanmaktadır [3]. RHVT, boyutlarının küçük oluşu, ağırlıklarının hafif oluşu, çok hızlı bir şekilde rejime ulaşması, kloroflorokarbon kullanılmadığından çevresel açıdan zararlı olmaması sebebi ile birçok soğutma ve ısıtma işlemlerinde kullanılabilir. Ayrıca RHVT'ler elektriksel ve kimyasal güç ile bakım gerektirmezler [4, 5]. Çalışmada kullanılan karşıt akışlı RHVT şekil 1'de verilmiştir.



Şekil 1. Karşıt akışlı RHVT (Counterflow RHVT)

RHVT'lerde sıcak ve soğuk akışkanların oluşturulmasının temeli Şekil 2'de verilmiştir. RHVT çalışma prensibi, giriş kısmında bulunan nozula uygulanan basınçlı akışkan, tüpe teğet olacak şekilde giriş yapar. Girişinde nozul ile basınçlı akışkan basıncı düşürülür ve buna bağlı olarak akışkan hızı artar. Yüksek hızlarda dönen akışkanın tüp cidarındaki sürtünmeden dolayı, tüp cidarı ile merkezindeki akışkan arasında basınç farkı meydana gelir. Tüp cidarındaki akışın hızı sürtünmenin etkisi ile tüp merkezindeki akışın hızına göre daha düşüktür. Merkezdeki akış cidarındaki akışa ivmelendirmeye çalışır ve merkezdeki akışkan cidarındaki akışa enerji transfer eder. Sistemde çalışma esnasında kontrol vanası sayesinde oluşan bir durgunluk noktası ile sıcak akışkanın bir kısmı geri döner. Bunun sonucunda, RHVT'de eş zamanlı olarak bir tarafından soğuk akış, diğer tarafından ise sıcak akış elde edilir (Şekil 2) [6,7].



Şekil 2. (a) RHVT içerisindeki sıcak ve soğuk akışın hareketi (b) RHVT içerisindeki akış ((a) The movement of hot and cold flow in the RHVT (b) The flow in the RHVT)

Bovand v.d. (2014) 7-11 mm orifis çapı aralığında değiştirerek farklı soğuk akış debisinde deneyler yapmışlardır. Sıcaklık, debi ve basınç değerlerinin ölçüldüğü deneysel sonuçlar ANOVA yöntemi ile istatistiksel analiz yapılarak optimizasyon çalışması yapmışlardır [8]. Thakare ve Parekh (2014) ANSYS Fluent programı ile yaptıkları nümerik hesaplamalarla sekiz değişik gaz ile ayrı ayrı çalışarak ısı iletkenlik, ısı yayılım, prandtl sayısı ve gaz sabiti parametrelerinin vorteks tüpü enerji ayrıştırma etkilerini incelemişlerdir [9]. Gökçe v.d. (2019), giriş basıncı 300, 400 ve 500 kPa basınç değerinde hava kullanılarak karşıt akışlı RHVT'de çıkan sıcak akış ile soğuk akışın sıcaklıkları arasındaki fark cinsinden RHVT'nin performansının optimizasyonu yapmışlardır. Optimizasyon için Taguchi L9 dikey dizini kullanarak testler yapılmıştır. Testler sonucunda elde edilen RHVT performansı için kalite karakteristiği, çıkan sıcak ile soğuk akışın sıcaklığı arasındaki fark (ΔT) olarak belirlemişler ve önem seviyelerini belirlemek için varyans analizi (ANOVA) uygulanmıştır. Yaptıkları ANOVA analizine göre, ΔT için en önemli kontrol faktörleri sırasıyla giriş basıncı, nozul orifis sayısı ve nozul malzemesi olduğu belirlemişlerdir [10]. Kaya ve Gökçe (2019), giriş basıncı 150 ile 650 kPa basınç değerinde 100 kPa aralıklarla oksijen gazı kullanarak RHVT'den çıkan sıcak ile soğuk akışın sıcaklığı arasındaki fark cinsinden RHVT'nin performanslarının optimizasyonu yapmışlardır. Bu bağlamda, Taguchi L18 dikey dizini kullanarak testler yapılmıştır. Testler sonucunda elde edilen RHVT performansı ΔT olarak

belirlenmişlerdir. Bu amaçla, önem seviyelerini belirlemek için varyans analizi (ANOVA) uygulanmıştır. Sinyal/Gürültü oranları kullanılarak elde edilen kontrol faktörlerinin optimum değerleri ΔT için farklı seviyelerde bulunmuştur. ANOVA analizine göre, ΔT için en önemli kontrol faktörleri sırasıyla giriş basıncı, nozul malzemesi ve nozul sayısı olduğu belirlenmiştir [11].

Bir deney düzeneğinin asıl performansını iyi tespit edebilmek için o düzeneğin kurularak test edilmesiyle doğru sonuçlar verilebilir. Fakat günümüzde laboratuvar kurulum maliyetlerinin yüksek olabilmemesinden dolayı tasarım ve test edilmesi her zaman mümkün olamamaktadır. Ayrıca, bu düzeneklerin yeterli sayıda test edilmesi de önemli bir zaman gerektirebilmektedir. Bu zorlukların üstesinden gelebilmek ve gerçek saha testlerini en aza indirgeyebilmek için günümüzde yapay zekânın bir alt dalı olan makine öğrenimi yöntemleri giderek artan bir şekilde kullanılmaya başlanmıştır. Bu ve benzeri zorlukları aşabilmek ve gerçek laboratuvar testlerini en aza indirgeyebilmek için günümüzde çeşitli makine öğrenimi yöntemleri yaygın olarak kullanılmaya başlanmıştır.

Bu çalışmada, RHVT deney sisteminde alüminyum, çelik, pirinç ve polyamid malzemeden üretilmiş iki, üç, dört, beş ve altı orfislilik nozullarda, giriş basıncı 50 kPa aralıklarıyla 150 ile 700 kPa basınç değerinde hava kullanılarak, RHVT'de çıkan T_{sck} ile T_{sgk} arasındaki fark ΔT cinsinden RHVT'nin performansının optimum olarak gerçekleşmesi ve çıkışlarını en doğru şekilde tahmin edebilmek amacıyla makine öğrenimi yöntemlerinden Lineer Regresyon (LR), Destek Vektör Makineleri (DVM) ve Gauss Süreç Regresyonu (GSR) kullanılmıştır.

2. Materyal ve Metot (Material and method)

2.1. Deneysel sistem (Experimental system)

Çalışmada, gövde uzunluğu 100 mm, iç çapı 7 mm olan karşıt akışlı RHVT yüksekliği 330 mm, genişliği 550 mm, kalınlığı 2 mm olan metal levha üzerine şekil 3'teki gibi yerleştirilmiştir. RHVT giren havanın basıncını ölçmek için PAKKENS tipi %5 hassasiyetindeki manometre, hacimsel debileri okunak için %3 hassasiyetinde TSI marka debimetreler karşıt akışlı RHVT'ün çıkışlarına sabitlenmiştir. RHVT çıkan soğuk ve sıcak akış sıcaklıklarını ölçmek üzere $\pm 1^\circ\text{C}$ hassasiyetindeki dijital termometre problemleri kullanılmıştır. Deneylerde RHVT'de alüminyum, çelik, pirinç ve polyamid malzemeden üretilmiş iki, üç, dört, beş ve altı nozul kullanılmıştır (Şekil 3). Hava kompresörü ve RHVT akışkan girişindeki vana kullanılarak deneylerde başlangıç basıncı olan 150 kPa basınç sağlanmış ve RHVT'nün soğuk ve sıcak akış çıkışında bulunan ölçüm cihazlarında ölçülen sıcaklık değerleri sabitleninceye kadar 150 kPa basınçta hava gönderilerek RHVT girişteki basınç, çıkan sıcak ve soğuk akışkanın sıcaklık değerleriyle ve hacimsel debileri kayıt altına alınmıştır. Deneysel çalışmada belirlenen diğer basınç değerleri için 150 kPa basınçta yapılan işlemler tekrarlanarak farklı malzemelerden imal edilen tüm nozullar kullanılmıştır. Tüm deneyler ortam sıcaklığı 21°C 'lik ortamda yapılmıştır. Deney sonuçlarının doğruluğu için yapılan deneylerin her biri üçer kez tekrarlanmış olup ortalamaları alınarak çalışmada kullanılmıştır.

RHVT'ler, bir girişe ve iki farklı akışa sahip açık sistemler olarak kabul edilirler. Tüp içerisinde giriş akışının ne kadarının soğuk akışa dönüştüğünü ifade eden ξ değeri denklem 1 verilmiştir.

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

RHVT'lerde girişteki akış sıcaklığı (T_{gir}) ile çıkan soğuk akış sıcaklık (T_{sgk}) farkı, soğuk akış sıcaklık farkı (ΔT_{sgk}) olarak tanımlanır ve denklem 2 de ifade edilmiştir.


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

RHVT'lerde girişteki akış sıcaklığı (T_{gir}) ile çıkan sıcak akış sıcaklık (T_{sck}) fark, sıcak akış sıcaklık farkı (ΔT_{sck}) olarak tanımlanır ve denklem 3 de verilmiştir.

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

Denklem 2 ve 3 birleştirilip sadeleştirildiğinde, RHVT performansı (ΔT) denklem 4 de verilmiştir [1, 3, 4, 12].

$$\Delta T = T_{sck} - T_{sgk} \quad (4)$$



Şekil 3. Deneysel çalışmada kullanılan Karşıt akışlı RHVT ve kullanılan nozullar (Counterflow RHVT and nozzles used in the experimental study)

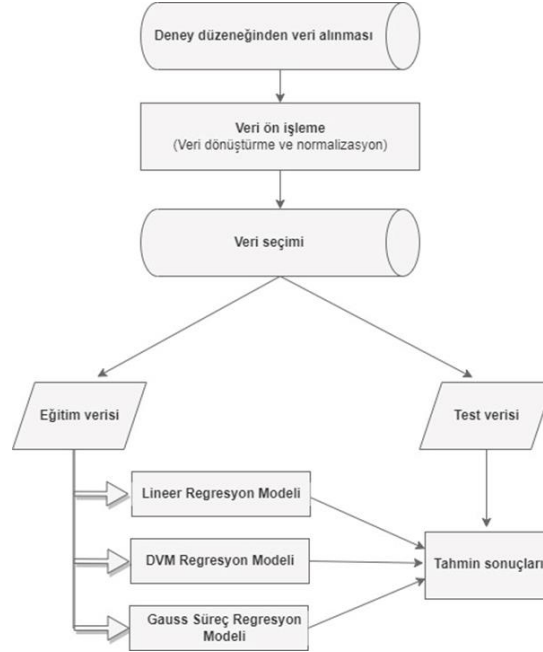
2.2. Makine öğrenme yöntemleri (Machine learning techniques)

Yapay zekânın bir dalı olan makine öğrenimi, sorunların çözümünde konuya ilişkin verileri eğitim, test ve doğrulama amaçlı kullanarak çözüme yönelik tahminler üreten algoritmalarıdır. Bunun için eğitim modelleri oluşturulur. Farklı makine öğrenimi yöntemleri farklı oranda veriye ihtiyaç duysa da genellikle modelleri sürekli olarak optimize etmek ve algoritmaları kullanarak en iyi tahminleri yapmak için büyük miktarda veri kullanılır [13]. Makine öğrenimi için çok sayıda farklı algoritma ve yöntem geliştirilmiştir. Bunlardan bazıları; lineer regresyon, gauss süreç regresyonu, karar ağaçları, destek vektör makineleri, rastgele orman ve yapay sinir ağları olarak sayılabilir. Makine öğrenimi yöntemleri kümeleme, sınıflandırma, tahmin, örüntü tanıma, bilgi çıkarımı gibi çeşitli amaçlarla kullanılabilir [14].

Bu çalışmada kurulu deney düzeneği ile elde edilen sonuçlardan RHVT'nin ΔT değerlerini tahmin etmek için makine öğrenme yöntemleri kullanılmıştır. Şekil 4'te makine öğrenimi işlem süreçlerinin akış şeması verilmektedir. İşlemler ilk olarak deney düzeneğinin oluşturulması ve bu düzenden gerekli verilerin toplanmasıyla başlar. Toplanan verilerdeki ölçüm ve diğer hatalar giderilir. Hatalardan arındırılmış veriler makine öğreniminde kullanılacak şekilde düzenlenir. Bu düzenleme esnasında gerekli olan bazı veriler makine öğreniminde kullanılan matematiksel modellere de uygun olacak şekilde sayısal değerlere dönüştürülür. Yine bu değerlerin makine öğrenimi yöntemlerinde doğru bir şekilde kullanılabilmesi için veriler üzerinde standartlaştırma işlemi yapılır. Veriler eğitim verisi ve test verisi olarak iki grup halinde kullanılır. Bu çalışmada eğitim verisi için tüm verinin %80'ni, test verisi için %20'si kullanılmıştır. İlk olarak makine öğrenimi yöntemlerinden üç farklı regresyon yöntemi olan DVM, LR ve GSR yöntemleriyle eğitim süreci gerçekleştirilmiştir. Bu yöntemlerle elde edilen eğitim modelleri kullanılarak test verisi ile tahminler üretilmiştir.

Yapılan regresyon analizlerinden elde edilen tahminlerin doğruluğunun bir ölçüsü determinasyon katsayısı R^2 'dir. Bu katsayı ölçülen verilerle tahmin edilen verilerin birbiri ile ne kadar uyumlu

olduğunun bir ölçütüdür. $R^2=1$ olması tam uyumlu olduğunu gösterir. Veri sayısı arttıkça R^2 'nin güvenilirliği de artmaktadır.



Şekil 4. Makine öğrenimi işlem akış şeması (Machine learning operations flowchart)

2.2.1. Lineer regresyon (Linear regression)

Lineer regresyon (LR) bağımlı bir değişken ile bir veya daha çok bağımsız değişken arasındaki neden-sonuç ilişkisini ortaya koyabilmek amacıyla kullanılan temelde istatistik bilimine dayalı bir yöntemdir. Regresyon modeli, bir fonksiyon aracılığıyla bağımlı değişkeni bağımsız değişken veya değişkenlerle ilişkilendirir [15]. LR yönteminde tek bir bağımsız değişken kullanılabilir gibi birden çok bağımsız değişken de kullanılabilir. Birden çok bağımsız değişken kullanıldığında çoklu lineer regresyon (ÇLR) adını alır [16, 17]. LR yöntemi denklem 5 ile ifade edilebilir.

$$y = a_0 + a_1X + \varepsilon \quad (5)$$

Denklem 5'te, y bağımlı değişken, X bağımsız değişken ve ε hata terimidir. a_0 sabit terim olup, regresyon doğrusunun düşey eksendeki kesişimini, a_1 ise regresyon doğrusunun eğimini veren regresyon katsayısıdır. Burada a_1 bir sabit olup değişimin yönünü ve miktarını verir. a_1 'in değerinin pozitif olması değişimin arttığını, değerinin negatif olması ise değişimin azaldığını gösterir [18]. ÇLR yöntemine ait eşitlik denklem 6 da verilmektedir.

$$y = a_0 + a_1X_1 + a_2X_2 + \dots + a_nX_n + \varepsilon \quad (6)$$

Denklem 6 da birden çok regresyon katsayısı (a_1, a_2, \dots, a_n) ve birden çok bağımsız değişken (X_1, X_2, \dots, X_n) bulunmaktadır. Genellikle en küçük kareler yaklaşımı kullanılarak tahmindeki olası hata sıfıra yaklaştırılmaya çalışılır [19].

2.2.2. Destek vektör makineleri (Support vector machines)

Destek Vektör Makineleri (DVM), Vapnik tarafından 1990'lı yıllarda ortaya konuldu [20]. DVM algoritması, veriyle ilgili birleşik dağılım fonksiyonu bilgisine ihtiyaç duymadığından dağılımdan bağımsız çalışabilen bir öğrenme algoritmasıdır [21]. DVM'nin amacı sınıfların birbirinden ayrılması için optimum ayırma hiper düzleminin bulunmasıdır. Yani farklı sınıfların destek vektörleri arasındaki uzaklığı en büyükmektir [22]. Bir destek vektör makinesi, verileri optimum bir şekilde iki gruba ayıran n -boyutlu bir hiperdüzlem oluşturur. DVM'ler istatistik ve makine öğrenimi yöntemlerinden sinir ağlarının çeşitli tekniklerini birlikte kullanırlar [23, 24]. DVM, yüksek genelleme yeteneğine

sahiptir ve yüz tanıma, ses tanıma, el yazısı tanıma metin sınıflandırma gibi bir çok farklı alanda kullanılmaktadır [25, 26].

DVM yöntemi ilk önceleri doğrusal verilerin iki sınıfa ayrılması için tasarlanmış olsa da günümüzde doğrusal olmayan ve çok sınıflı veriler üzerinde tahminler üretmek için de kullanılmaktadır. Doğrusal ayrılabilen veriler için genellikle iki sınıfa ayrılabilen örnek veriler kullanılarak yapılan eğitimler sonucu elde edilen karar fonksiyonu sayesinde verilerin birbirinden ayrılması amaçlanır [27]. Optimum hiperdüzleme ait denklem 7 ve 8 de verilmektedir.

$$w \cdot x_i + b \geq +1, y = +1 \quad (7)$$

$$w \cdot x_i + b \leq -1, y = -1 \quad (8)$$

Bu denklemlerde $x \in \mathbb{R}^N$ N-boyutlu uzayı, $y \in \{-1, +1\}$ sınıf etiketlerini, b eğilim değerini, w ağırlık vektörünü gösterir [28, 29].

Bazı durumlarda verileri doğrusal olarak ayırmak mümkün olmayabilir. Bu durumda doğrusal ayıramayan verilerin yanlış sınıflandırılmaması için düzenleme parametresi ve yapay değişken kullanılarak optimizasyon problemi çözülmeye çalışılır [27].

2.2.3. Gauss süreç regresyonu (Gaussian process regression)

Gauss süreç regresyonu (GSR), genellikle doğrusal olmayan regresyon problemlerini çözmek için olasılıklı, parametrik olmayan problemlerde daha çok tercih edilen başarılı bir makine öğrenme yöntemidir [30, 31]. GSR, küçük verilerde bile başarılı sonuçlar üretebilir ve tahminlerde belirsizlik ölçümleri yapılabilecek özelliklere sahiptir [32]. GSR ile en doğru seçeneğin belirlenebilmesine imkân verebilecek farklı kovaryans fonksiyonları kullanılabilir [33]. Gauss süreç fonksiyonu $f(x)$ denklem 9 da verilmektedir [34].

$$f(x) = GP(m(x), k(x, x')) \quad (9)$$

Burada $m(x)$ ortalama fonksiyonu, $k(x, x')$ kovaryans fonksiyonudur. Ortalama fonksiyonu denklem 10 da, kovaryans fonksiyonu ise denklem 11 de verilmektedir.


$$m(x) = E[f(x)] \quad (10)$$

$$k(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (11)$$

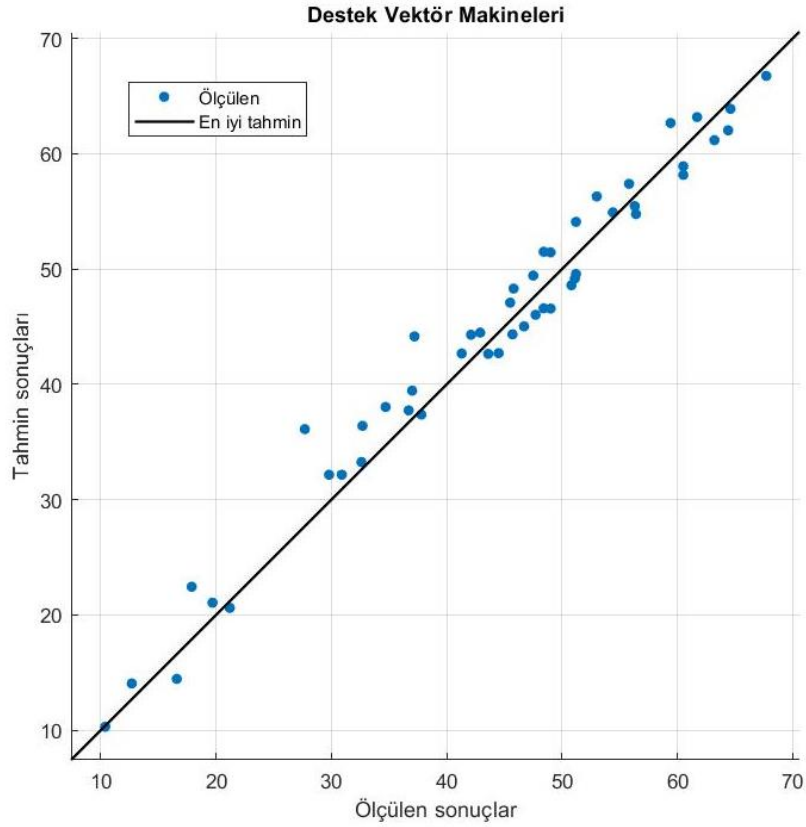
Gauss sürecinin hiper-parametreleri ortalama fonksiyonu ve kovaryans fonksiyonudur. Ortalama fonksiyonu, x girdisine sahip $\mathbb{R}(\mathbb{R})$ fonksiyonunun beklenen değerini gösterir ve genelde basitleştirme amacıyla sıfır olarak alınmaktadır. Ortalama fonksiyonu için güven düzeyinin bir ölçüsü kovaryans fonksiyonudur [35].

3. Sonuçlar ve Tartışma (Results and Discussion)

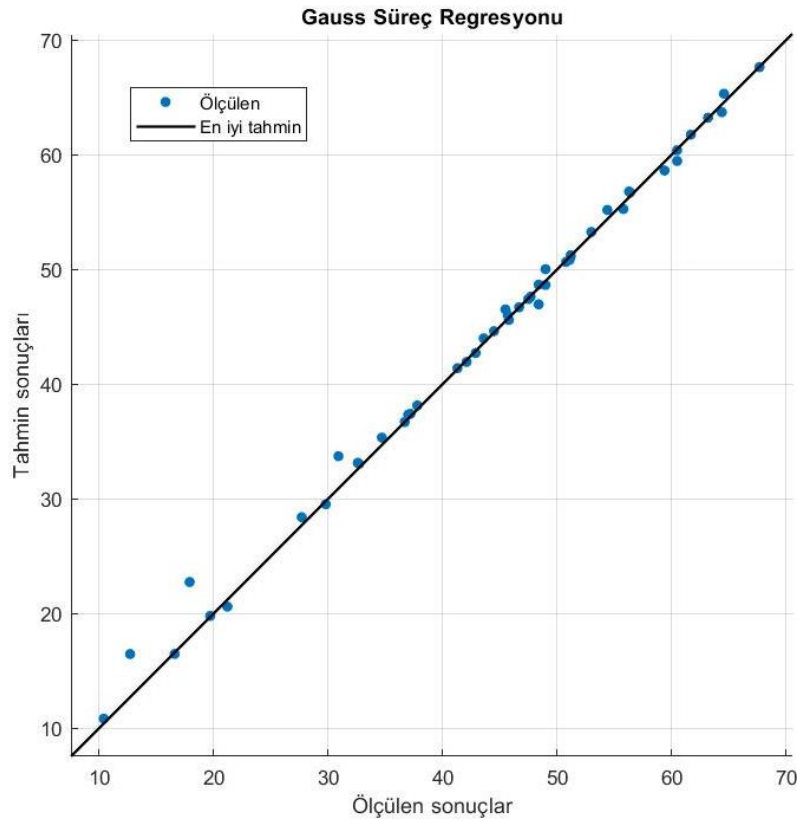
Kurulan RHVT deney düzenekleri ile elde edilen verilerle makine öğrenimi eğitim ve test işlemleri gerçekleştirilmiştir. Makine öğrenimi yöntemlerinden LR, DVM ve GSR yöntemleriyle yapılan çalışmalardan elde edilen testlere ait sonuç grafikleri sırasıyla Şekil 5-7 de verilmiştir. Şekil 5'te görüldüğü gibi LR yönteminde düşük ΔT değerlerinde ölçülen ve tahmin edilen değerler arasındaki farklılık daha fazlayken daha yüksek değer aralığında birbirine daha yakın çıkmıştır. Benzer durum Şekil 6 ve Şekil 7'deki DVM ve GSR yöntemlerinde de görülmekle birlikte onlardaki farklılık çok daha azdır. Tüm sonuçlar birlikte değerlendirildiğinde LR yönteminin başarısının diğer yöntemlere göre daha düşük olduğu, ancak bununla birlikte yine de kullanılabilir düzeyde sonuçlar üretebildiği değerlendirilmektedir. DVM ve GSR yöntemleriyle elde edilen tahmin sonuçlarının çok iyi olduğu Şekil 6 ve Şekil 7'de görülmektedir. Uygulanan makine öğrenimi yöntemleri içerisinde en yüksek doğruluğa sahip yöntemin GSR yöntemi olduğu şekillerden, doğruluk ve uyumluluk ölçütlerinden (R^2 , RMSE, MSE, MAE) anlaşılmaktadır. Yöntemlerin ürettiği tahmin sonuçlarına ait doğrulukların farklı seviyelerde olması, kullanılan yöntemlerin algoritmasından, veri sayılarından ve uygulanan alandan kaynaklandığı düşünülmektedir.



Şekil 5. LR yöntemi ile ölçülen ve tahmin edilen sıcaklık farkları (ΔT) grafiği (Graph of temperature differences (ΔT) measured and estimated by the LR method)



Şekil 6. DVM yöntemi ile ölçülen ve tahmin edilen sıcaklık farkları (ΔT) grafiği (Graph of temperature differences (ΔT) measured and estimated by the SVM method)



Şekil 7. GSR yöntemi ile ölçülen ve tahmin edilen sıcaklık farkları (ΔT) grafiği (Graph of temperature differences (ΔT) measured and estimated by the GPR method)

Kullanılan makine öğrenimi yöntemleriyle yapılan test tahmin sonuçlarına ait doğruluk değerleri Tablo 1'de verilmektedir.

Tablo 1. Makine öğrenimi yöntemleri kullanılarak elde edilen test tahmin sonuçlarının doğruluk değerleri (Accuracy values of test prediction results obtained using machine learning methods)

	LR	DVM	GSR
Determinasyon Katsayısı (R^2)	0.87	0.97	0.99
Kök Ortalama Kare Hata (RMSE)	5.30	2.56	1.09
Ortalama Kare Hata (MSE)	28.11	6.56	1.18
Ortalama Mutlak Hata (MAE)	4.32	2.09	0.59

Yapılan çalışmada, RHVT deneylerinden elde edilen verilerle öncelikle makine öğrenimi yöntemleri kullanılarak eğitimler gerçekleştirilmiştir. Eğitimlerden elde edilen modeller kullanılarak yapılan makine öğrenimi testlerinde RHVT sıcaklık farkına (ΔT) ait R^2 değerleri; LR yönteminde 0.87, DVM yönteminde 0.97, GSR yönteminde ise 0.99 olarak bulunmuştur. Bu çalışmalar makine öğrenimi yöntemi ile yapılan çalışmaların gerçek deney düzeneklerinde ölçülen sıcaklık farkı değerlerine çok yakın sonuçlar verdiğini ortaya koymuştur. Kullanılan üç farklı makine öğrenimi yönteminden GSR yönteminin RHVT performansına ait sıcaklık farkının (ΔT) R^2 değeri, LR ve DVM yöntemlerine ait sıcaklık farklarının (ΔT) R^2 değerlerinden daha yüksek doğruluk değeri vermiştir (Tablo 1). Makine öğrenimi yöntemlerinin karşıt akışlı RHVT sistemlerinin deney düzeneklerinin oluşturulmasında zaman ve maliyet kaybını azaltmak için önemli bir yöntem olduğu ortaya konulmuştur. Makine öğrenimi yöntemleri ile karşıt akışlı RHVT performans analizlerinin bu çalışmadaki değer aralıklarında çalışıldığında, istenilen gerçek değerlere ulaşılmasının tahmin edilebilmesi için doğrulayıcı bir yaklaşım olduğu görülmüştür.

Yapılan çalışma ile makine öğrenimi yöntemlerinden Lineer Regresyon (LR), Destek Vektör Makineleri (DVM) ve Gauss Süreç Regresyonu (GSR) yöntemleri kullanılarak yapılan makine öğrenme yöntemlerinden oldukça yüksek doğrulukta sonuçlar elde edilebileceği ve yöntemin tüm deneysel çalışmalara uyarlanabileceği önerilmektedir.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] A. Pinar, O. Uluer, and V. Kirmaci, "Optimization of counter flow ranque-hilsch vortex tube performance using taguchi method," *International Journal of Refrigeration*, vol. 32, no. 6, pp. 1487-1494, 2009. doi:10.1016/j.ijrefrig.2009.02.018
- [2] F. Günver, "Paralel bağlı karşıt akışlı ranque-hilsch vorteks tüpün enerji-ekserji analizlerinin deneysel olarak incelenmesi," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bartın Üniversitesi, 2018
- [3] A. Pinar, O. Uluer, and V. Kirmaci, "Statistical assessment of counter-flow vortex tube performance for different nozzle numbers, cold mass fractions, and inlet pressures via taguchi method," *Experimental Heat Transfer*, vol. 22 no. 4, pp. 271-282, 2009. doi:10.1080/08916150903099058
- [4] H. Kaya, O. Uluer, E. Kocaoğlu, and V. Kirmaci, "Experimental analysis of cooling and heating performance of serial and parallel connected counter-flow Ranquee-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
- [5] H. Gökçe, "Optimization of ranque-hilsch vortex tube performances via taguchi method," *J. Brazilian Soc. Mech. Sci. Eng.*, vol. 42, no. 11, 2020. doi:10.1007/s40430-020-02649-z
- [6] 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
- [7] K. Dincer, S. Baskaya, B. Z. Uysal, and I. Ucgul, "Experimental investigation of the performance of a ranque-hilsch vortex tube with regard to a plug located at the hot outlet," *Int. J. Refrig.*, vol. 32, no. 1, pp. 87-94, 2009. doi:10.1016/j.ijrefrig.2008.06.002
- [8] M. Bovand, M. S. Valipour, S. Eiamsa-Ard, and A. Tamayol, "Numerical analysis for curved vortex tube optimization," *Int. Commun. Heat Mass Transf.*, vol. 50, pp. 98-107, 2014. doi:10.1016/j.icheatmasstransfer.2013.11.012
- [9] H. R. Thakare and A. D. Parekh, "CFD analysis of energy separation of vortex tube employing different gases, turbulence models and discretisation schemes," *Int. J. Heat Mass Transf.*, vol. 78, pp. 360-370, 2014. doi:10.1016/j.ijheatmasstransfer.2014.06.083
- [10] H. Gökçe, H. Kaya, and V. Kirmaci, "Karşıt akışlı ranque-hilsch vorteks tüpün performansının taguchi metodu ile analizi," *2nd International Turkish World Engineering and Science Congress 2019*, pp. 414-421, 2019.
- [11] Kaya. H and Gökçe. H, "oksijen kullanılan karşıt akışlı vorteks tüpünün taguchi yöntemi ile analizi," *2nd International Turkish World Engineering and Science Congress*, pp. 588-595, 2019.
- [12] H. Kaya, H. Gökçe, and V. Kirmaci, "Effect of cold outlet diameter on thermal performance and exergy analysis of ranque-hilsch vortex tube with copper nozzles," *Heat Transf. Res.*, vol. 53, no. 2, pp. 59-70, 2022. doi:10.1615/HeatTransRes.2021039907
- [13] J. Wei, X.Chu, X. Sun, K. Xu, H. Deng, J. Chen, Z. Wei and M. Lei "Machine learning in materials science," *InfoMat*, vol. 1, no. 3, pp. 338-358, 2019.
- [14] T. E. Kalaycı, "Kimlik hırsız web sitelerinin sınıflandırılması için makine öğrenmesi yöntemlerinin karşılaştırılması," *Pamukkale Üniversitesi Mühendislik Bilim. Derg.*, vol. 24, no. 5, pp. 870-878, 2018.
- [15] Q.-H. Luu, M. F. Lau, S. P. H. Ng, and T. Y. Chen, "Testing multiple linear regression systems with metamorphic testing," *Journal of Systems and Software*, vol. 182, p. 111062, 2021.
- [16] D. S. Memnun ve Ş. Kalaycı, "SPSS uygulamalı çok değişkenli istatistik teknikleri," Ankara: *Asil Yayın Dağıtım*, İlköğretim Online, cilt 12, sayı 1, 2006.
- [17] S. Rong and Z. Bao-Wen, "The research of regression model in machine learning field," in *MATEC Web of Conferences*, vol. 176, pp. 1033, 2018.
- [18] M. Bayazit and B. Oğuz, *Mühendisler için istatistik*, Birsen Yayınevi, İstanbul, s. 197, 1994.
- [19] Y. Aslan, S. Yavasca, and C. Yasar, "Long term electric peak load forecasting of Kutahya using different approaches," *Int. J. Tech. Phys. Probl. Eng.*, vol. 3, no. 2, pp. 87-91, 2011.
- [20] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273-297, 1995.
- [21] K. P. Soman, R. Loganathan, and V. Ajay, *Machine learning with SVM and other kernel methods*, PHI Learning Pvt. Ltd., New Delhi, 2009.
- [22] S. Ayhan and Ş. Erdoğmuş, "Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi," *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilim. Derg.*, cilt 9, sayı 1, ss. 175-201, 2014.

- [23] S. Haykin, *Neural Networks, a comprehensive foundation*, Prentice-Hall Inc, New Jersey, pp. 161–175, 1999.
- [24] S. Tolun, “Destek vektör makineleri: Banka başarısızlığının tahmini üzerine bir uygulama,” Doktora Tezi, Sosyal Bilimler Enstitüsü, İstanbul Üniversitesi, İstanbul, 2008.
- [25] B. Schölkopf, J. C. B. Christopher, and J. A. Smola, *Advances in kernel methods*, England: The MIT Press, vol. 53., Cambridge, 1999.
- [26] N. Cristianini and J. Shawe-Taylor, *An introduction to support vector machines and other kernel-based learning methods*, Cambridge university press, Cambridge, 2000.
- [27] T. Kavzoğlu ve İ. Çölkesen, “Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi,” *Harit. Derg.*, cilt 144, sayı 7, ss. 73–82, 2010.
- [28] E. E. Osuna, “Support vector machines: Training and applications,” Ph.D. dissertation, Massachusetts Institute of Technology, USA, 1998.
- [29] 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.
- [30] K. Liu, X. Hu, Z. Wei, Y. Li, and Y. Jiang, “Modified Gaussian process regression models for cyclic capacity prediction of lithium-ion batteries,” *IEEE Trans. Transp. Electrification*, vol. 5, no. 4, pp. 1225–1236, 2019.
- [31] M. Acı ve A. G. Doğanşoy, “Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini,” *Gazi Üniversitesi Mühendislik Mimar. Fakültesi Derg.*, vol. 37, no. 3, pp. 1325–1340, 2022.
- [32] B. Ateş, “Gemi yapılarında gerilme yığılması öngörülerinin kaba ağ yapısı ve makine öğrenmesi ile gerçekleştirilmesi,” Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2020.
- [33] Y. Heo and V. M. Zavala, “Gaussian process modeling for measurement and verification of building energy savings,” *Energy Build.*, vol. 53, pp. 7–18, 2012.
- [34] C. E. Rasmussen and C. K. I. Williams, “Gaussian processes formachine learning,” USA: MIT Press, Cambridge, 2006.
- [35] K. Yazıcı, “Makine öğrenmesi yöntemleri kullanılarak kısa dönem rüzgar gücü tahmini,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Sakarya Üniversitesi, Sakarya, 2021.

This is an open access article under the CC-BY license

