

KANATLI BORULU ISI DEĞİŞTİRİCİLERİN PERFORMANS ANALİZİNDE TEST, YAZILIM VE YAPAY ZEKA ÇIKTILARININ KARŞILAŞTIRILMASI

Comparison of Test, Software and Artificial Intelligence Outputs in Performance Analysis of Finned Tube Heat Exchangers

Hasan ACÜL
Altay ARBAK
Abdurrahim TÜRK
Murat ÖZCAN

ÖZET

Bu çalışma, kanatlı borulu ısı değiştiricilerin performans analizinde kullanılan üç farklı yaklaşımı—test, yazılım simülasyonları ve yapay zekâ modelleri—karşılaştırmayı amaçlamaktadır. Geleneksel test yöntemleri, uzun zamandır ısı değiştiricilerin performans hesaplarının yapılmasında güvenilir bir yöntem olarak kullanılmaktadır. Ancak, son yıllarda geliştirilen yazılım simülasyonları ve yapay zekâ tabanlı analiz yöntemleri, daha hızlı ve maliyet etkin çözümler sunarak bu süreci dönüştürmektedir. Bu çalışmada, her üç yöntemin sonuçları belirli bir dizi performans kriteri üzerinden karşılaştırılacak ve doğruluk açısından değerlendirilecektir. Elde edilen sonuçlar, ısı değiştirici performans analizlerinde hangi yöntemin hangi koşullar altında daha uygun olduğunu belirlemeye katkı sağlayacaktır.

Anahtar Kelimeler: Kanatlı borulu ısı değiştiricileri, yapay zeka, makine öğrenmesi

ABSTRACT

This study aims to compare three different approaches used in the performance analysis of finned tube heat exchangers: experimental testing, software simulations, and artificial intelligence (AI) models. Traditional testing methods have long been considered a reliable approach for evaluating heat exchanger performance. However, in recent years, software simulations and AI-based analysis methods have emerged as transformative solutions, offering faster and more cost-effective alternatives. In this study, the results of these three methods will be compared based on a set of performance criteria and evaluated in terms of accuracy. The findings will contribute to determining which method is more suitable under specific conditions for heat exchanger performance analysis.

Key Words: Finned tube heat exchangers, artificial intelligence, machine learning

1. GİRİŞ

Enerji verimliliği, sanayiden konut sistemlerine kadar birçok alanda büyük önem taşımaktadır. Isı değiştiricilerin kapasite ve basınç kayıplarının doğru hesaplanması enerji verimliliği açısından çok önemlidir. Buna ek olarak, Eurovent sertifikası gibi programların ısı değiştirici üreticilerine belirli bir doğrulukta hesap yapma zorunluluğu getirdiği bilinmektedir. Ayrıca yetersiz kapasite veya istenilenden fazla basınç kaybı gibi sonuçlar endüstriyel projeler için sorun teşkil etmektedir. Isı değiştiricileri, farklı sıcaklıklara sahip akışkanlar arasında ısı transferini sağlayan temel ekipmanlardan biridir. Bu cihazlar, iklimlendirme, soğutma, güç santralleri, petrol rafinerileri, petrokimya tesisleri ve atık ısı geri kazanımı gibi birçok endüstriyel uygulamada yaygın olarak kullanılmaktadır [1]. Isı değiştiricilerinin performans hesaplamaları, tasarım optimizasyonları, kontrol analizleri ve geçici rejim simülasyonları, geleneksel analitik ve deneysel yöntemlerle gerçekleştirilmektedir. Bu bağlamda, ısı değiştiricilerinin termal tasarımı, performans değerlendirmesi ve mühendislik hesaplamaları açısından önemli kaynaklar

bulunmaktadır. Literatürde, bu konulara yönelik geniş kapsamlı çalışmalar yapılmış olup, geleneksel ve ileri modelleme yaklaşımlarını içeren referanslar mühendislik uygulamalarında yaygın olarak kullanılmaktadır [2]. Bununla birlikte, bu geleneksel yaklaşımlar çoğu zaman yüksek hesaplama maliyetlerine rağmen yeterli hassasiyet ve doğruluk sunamamaktadır [3].

Geleneksel modelleme yaklaşımlarının bir diğer büyük kısıtlaması, yeni geliştirilen akışkanların termofiziksel özelliklerinin hesaplanmasındaki zorluklardır. Yeni nesil çalışmalarda, alternatif soğutucu akışkanlar, nanoakışkanlar ve faz değiştiren malzemeler (PCM) gibi kompleks akışkanlar kullanılmaktadır. Bu akışkanların yoğunluk, viskozite, ısı kapasitesi ve termal iletkenlik gibi temel parametrelerinin doğru bir şekilde tahmin edilmesi, geleneksel yaklaşımlar için büyük bir zorluk oluşturmaktadır [1].

Farklı geometrik parametrelerin modelleme üzerindeki etkisi, hesaplamaların karmaşıklığını artıran bir diğer faktördür. Plaka tipi, mikro kanal ve borulu değiştiriciler gibi farklı tasarımların akış yapıları ve ısı transfer mekanizmaları üzerindeki etkisini doğru bir şekilde modellemek geleneksel modeller için oldukça zordur [4]. Özellikle çift fazlı akış gibi karmaşık akış olaylarının doğru modellenmesi geleneksel korelasyonlarla daha karmaşık ve zordur.

Son yıllarda, makine öğrenimi (ML) tekniklerinin ısı değiştirici modellemesinde kullanımı artmıştır. Makine öğrenimi modelleri, deneysel ve sayısal veriler ile eğitilerek, geleneksel yöntemlere kıyasla daha hızlı ve daha doğru tahminler sağlayabilmektedir [1]. Özellikle ısı taşınım katsayısı, sürtünme faktörü, basıncı düşüşü hesaplamalarında büyük bir hassasiyet ve esneklik sağlamaktadır [4]. Geleneksel modeller sabit çerçevelere sahipken, makine öğrenimi teknikleri farklı tasarımlar, malzemeler ve akış rejimleri için kolayca uyarlanabilir. Bu sayede yeni geliştirilen geometrik yapılar ve akışkanlarla ilgili hassas tahminler yapmak mümkün hale gelmektedir [5]

Bu çalışma, kanatlı borulu ısı değiştiricilerin performans analizinde kullanılan geleneksel ve modern hesaplama yöntemlerini karşılaştırmaktadır. Geleneksel yöntemler, testler ve test verilerinden oluşturulan korelasyonları kullanan yazılımlar, uzun zamandır ısı değiştiricilerin performans hesaplamaları ve doğrulamalarında güvenilir yöntemler olarak tercih edilmektedir. Bununla birlikte son yıllarda geliştirilen yapay zekâ tabanlı analiz yöntemleri, doğru, hızlı ve maliyet etkin çözümler sunarak bu süreci önemli ölçüde dönüştürebileceğinin ipuçlarını vermektedir. Bu çalışma, havanın ısıtılması için kullanılan kanatlı borulu tip ısı değiştiricilerin kapasite hesabına odaklanmaktadır. Buna ek olarak, Li ve arkadaşları tarafından yapılan çalışmada olduğu gibi, yapay sinir ağları ve yanıt yüzey metodolojisi (RSM) kullanılarak yüksek doğruluklu ısı değiştirici modelleme yöntemleri incelenmektedir [6]. Benzer şekilde, Pacheco-Vega ve arkadaşlarının çalışması da sınırlı deneysel verilerle yapay sinir ağlarını kullanarak ısı değiştirici performans modellemesi üzerine önemli katkılar sunmuştur [7]. Buna ek olarak, Mohanraj ve arkadaşlarının çalışması, makine öğrenimi algoritmalarının soğutma ve iklimlendirme sistemlerinde uygulanabilirliği üzerine geniş bir inceleme sunmaktadır [8]. Çalışmada yöntem olarak makine öğrenmesi yöntemi kullanılmaktadır. Farklı makine öğrenmesi algoritmalarına çalışmada yer verilmiştir. Buna ek olarak, makine öğrenimi tabanlı ısı değiştiricisi modelleme yöntemlerini kapsamlı bir şekilde ele alarak, yüksek doğrulukta hesap yapmanın gerek modelleme yaklaşımındaki kısıtlar gerekse de deneysel verilerin azlığından dolayı her zaman mümkün olmadığını vurgulamaktadır.

Kanatlı Borulu Isı Değiştiricilerin Performans Analizinde Test, Yazılım ve Yapay Zekâ Çıktılarının Karşılaştırılması başlıklı bu çalışmada, farklı modelleme yaklaşımlarının doğruluk, işlem süresi ve maliyet açısından etkinliği değerlendirilerek, mühendislik uygulamalarında en uygun yöntemin belirlenmesi hedeflenmektedir.

2. YÖNTEM

Bu çalışmada, Gradient Boosting, Neural Network, Random Forest ve K-Nearest Neighbors algoritmaları kullanılmıştır. Bu modeller, farklı veri yapılarına ve problem türlerine uygun olarak tasarlanmış olup, her biri belirli avantajlar ve kullanım alanlarına sahiptir.

Gradient Boosting, zayıf öğrencilerin ardışık olarak eğitildiği bir topluluk (ensemble) öğrenme yöntemidir. Her yeni model, önceki modellerin hatalarını düzelterek modelin genel doğruluğunu artırmayı amaçlar [9]. Bu yöntem, genellikle karar ağaçlarıyla uygulanır ve özellikle büyük veri setlerinde güçlü genelleştirme yeteneği sunar. Isı değiştirici modelleme çalışmalarında, Gradient Boosting'in doğruluk oranını artırmada etkili olduğu gösterilmiştir [10].

Yapay Sinir Ağları (Neural Networks), biyolojik sinir sistemlerinden esinlenen bir makine öğrenimi tekniğidir. Katmanlar halinde düzenlenmiş yapay nöronlar aracılığıyla öğrenme gerçekleştirilir [11]. Derin sinir ağları, karmaşık ısı transfer fenomenlerini modelleme konusunda büyük bir potansiyele sahiptir. Isı değiştiricilerde sıcaklık dağılımı ve akışkan dinamikleri gibi konuların modellenmesi için kullanılmaktadır [12].

Random Forest, birçok karar ağacının topluluk (ensemble) öğrenme yöntemi ile bir araya getirilerek tahminleme yapılan bir makine öğrenimi algoritmasıdır [11]. Rastgele örnekleme ve öznelite seçimi ile her ağacın farklı veri alt kümeleri üzerinde eğitilmesi, modelin genelleme kabiliyetini artırmaktadır. Bu yöntem, aşırı öğrenmeyi (overfitting) önlemesi ve yüksek doğruluk sağlaması nedeniyle özellikle büyük veri setleri için uygundur. Isı değiştiricilerde farklı tasarım değişkenlerinin performansa etkisini analiz etmek ve en uygun tasarım parametrelerini belirlemek için yaygın olarak kullanılmaktadır.

En Yakın Komşu (K-Nearest Neighbors, KNN) algoritması, bir veri noktasını, en yakın komşularının sınıflarına veya değerlerine dayalı olarak tahmin eden örüntü tanıma tekniğidir [12]. Özellikle düşük boyutlu veri setlerinde etkili olup, ısı değiştirici modellemelerinde deneysel verilerle hızlı tahminler yapmak için kullanılmıştır [13].

2.1 Veri Toplama

Havanın ısıtılması amacıyla kullanılan kanatlı borulu tip ısı değiştiricilerinin kapasitesinin makine öğrenmesi algoritmalarıyla hesaplanabilmesi için öncelikle uygun girdilerin belirlenmesi gerekmektedir. Modelleme sürecinde, problemi fiziksel olarak doğru temsil eden ve gereksiz değişkenlerden arındırılmış bir yaklaşım benimsenmiştir. Bu doğrultuda, modelin gereğinden fazla karmaşık hale gelmesini önlemek amacıyla borular arası mesafe (ST: 32 mm), sıralar arası mesafe (SL: 28 mm) ve boru çapı (Do: 13,25 mm) gibi bazı geometrik parametreler sabit tutulmuş; yalnızca iki farklı hatve değeri (fP: 1,8 mm ve fP: 3,2 mm) kullanılarak modelleme gerçekleştirilmiştir.

Farklı hatveye sahip ısı değiştiricilerin kıyaslanabilirliğini sağlamak için kapasite modellemesi, birim yüzey alanı başına düşen kapasite olarak değerlendirilmiştir. Çalışmada, modelin öğrenme sürecini desteklemek amacıyla hatve, hava giriş hızı ve sıcaklığı, akışkan hızı ve giriş sıcaklığı olmak üzere beş temel giriş parametresi seçilmiştir. Veri seti oluşturulurken, geniş bir çalışma aralığını temsil edecek şekilde 600 veri noktası üretilmiş, ek olarak Eurovent standart testlerinde ölçüm yapılan noktaların çevresinde 108 adet veri noktası oluşturularak modelin genel doğruluk seviyesi artırılmıştır. Böylece, toplam 708 adet veri içeren kapsamlı bir veri seti oluşturulmuştur. Veri setinin tamamının oluşturulması ve kapasite hesaplamalarının gerçekleştirilmesi için "Coil Designer" yazılımı kullanılmıştır [14].


Model eğitimi ve test süreci, tüm algoritmalar için aynı veri seti üzerinden gerçekleştirilmiş ve sonuçların tutarlılığı sağlanmıştır. Bu yapı, farklı makine öğrenimi algoritmalarının kıyaslanmasını ve modelleme sürecinde kullanılan parametrelerin doğruluk üzerindeki etkisinin detaylı olarak analiz edilmesini mümkün kılmıştır. Tablo 1' de modellemede kullanılan veri seti gösterilmiştir.

Tablo 1. Model eğitiminde kullanılan veri seti.

Girdiler							Çıktı
		Hatve (mm)	Hava hızı (m/s)	Hava giriş sıcaklığı (°C)	Akışkan hızı (m/s)	Akışkan giriş sıcaklığı (°C)	Kapasite, birim alan başına (W/m ²)
Isıtma bataryası, farklı kombinasyonlar	1						
	2						
	3						
							
	559						
	600						
Standart şart kombinasyonları	601						
	602						
	603						
							
	707						
	708						


2.1 Model Eğitim

Şekil 1' de korelasyon matrisi gösterilmektedir ve değişkenler arasındaki ilişkileri anlamak amacıyla kullanılmıştır. Bu matris, modelde kullanılan bağımsız değişkenlerin birbiriyle nasıl etkileşime girdiğini göstererek, modelde hangi değişkenlerin önemli olabileceğini belirlemeye yardımcı olmuştur. Korelasyon katsayıları, değişkenlerin birbirleriyle olan doğrusal bağıntıyı gösterirken, modelin hangi girdilerden en fazla etkilendiğini anlamak açısından önemlidir. Matris incelendiğinde, hava hızı ile kapasite arasında güçlü bir pozitif korelasyon olduğu görülmektedir. Bu durum, hava hızının artmasıyla birlikte ısı değiştirici performansının arttığını göstermektedir. Hatve ile kapasite arasındaki korelasyonun da pozitif olması, ısı transfer yüzey alanının tasarımdaki önemini vurgulamaktadır. Buna karşın, hava giriş sıcaklığı ile kapasite arasında negatif bir korelasyon gözlenmiştir. Bu, hava giriş sıcaklığının artmasının ısı değiştirici kapasitesini sınırlayabileceğini göstermektedir. Akışkan giriş sıcaklığı ise kapasite ile orta derecede pozitif bir ilişkiye sahiptir; bu da akışkan giriş sıcaklığının ısı transferi sürecinde belirleyici bir faktör olduğunu işaret etmektedir. Korelasyon matrisinin analizi, modelleme sürecinde hangi değişkenlerin daha fazla etkili olacağını anlamak ve gereksiz değişkenleri elemek açısından kritik bir öneme sahiptir.



Şekil 1. Korelasyon matrisi.

Algoritmaların değişkenlere verdiği ağırlıkları anlamak amacıyla Şekil2' de özellik önem skorları gösterilmektedir ve algoritmaların değişkenlere verdiği ağırlıkları anlamak amacıyla hesaplanmıştır. Önem skoru hava hızı, akışkan hızı, akışkan giriş sıcaklığı, hava giriş sıcaklığı ve hatve değerlerinin kapasite üzerinde yüzdesel olarak etkisini temsil etmektedir. Gradient Boosting ve Random Forest modelleri kullanılarak, önem skorlarında hangi değişkenlerin model için daha kritik olduğu hesaplanmıştır. Şekil 2a' da Random Forest algoritması kullanılarak elde edilen özellik önem skorları gösterilmektedir. Buna göre hava hızının, ısı değiştiricinin kapasitesini en fazla etkileyen parametre olduğu anlaşılmaktadır. Akışkan hızı ve akışkan giriş sıcaklığı da modelin kararlarında önemli roller üstlenmektedir. Bu değişkenler, toplam ısı geçiş katsayısı ve dolayısıyla ısı değiştirici kapasitesini doğrudan etkilemektedir. Hava giriş sıcaklığı ve hatve değişkenleri, modele etkisi daha düşük olan ancak yine de kapasiteyi belirleyen faktörler arasında yer almaktadır.




Şekil 2. Özellik önem skorları

Şekil 2b 'de benzer şekilde Gradient Boosting algoritması ile elde edilen özellik önem skorları verilmiştir. Bu modelde de hava hızı en yüksek önem skoruna sahip değişken olarak öne çıkmaktadır. Ancak, Random Forest modelinden farklı olarak, akışkan giriş sıcaklığı, ikinci en önemli değişken olarak belirlenmiştir.

Şekil 3' te gösterilen ortalama karesel hata (MSE) grafiği, farklı makine öğrenimi algoritmalarının eğitim (train) ve test aşamalarındaki hata oranlarını karşılaştırmaktadır. Eşitlik 1' de ortalama karesel hatanın tanımı verilmiştir.

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

Bu formül, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkın karesinin ortalamasını alarak modelin hata seviyesini belirler. Daha düşük bir MSE değeri, modelin daha iyi tahminler yaptığını gösterir.



Şekil 3. Modellerin ortalama karesel hataları (MSE)

Random Forest ve Gradient Boosting modellerinin eğitim ve test hataları düşük seviyede olup, genelleme yeteneklerinin güçlü olduğunu göstermektedir. Bu iki algoritma, modelleme sürecinde daha az hata üreterek ısı değiştirici kapasitesinin tahmin edilmesinde başarılı bir performans sergilemiştir.

Buna karşılık, K-Nearest Neighbors (KNN) algoritması, en yüksek test hatasına sahip olup aşırı öğrenme (overfitting) eğilimi göstermektedir. KNN modelinin eğitim hatası nispeten düşük olsa da, test hatasının oldukça yüksek olması, modelin yeni veriler karşısında zayıf genelleştirme yaptığını göstermektedir. Bu durum, KNN algoritmasının, veri setindeki gürültüye duyarlı olduğunu ve düşük boyutlu veri kümelerinde daha iyi performans gösterebileceğini işaret etmektedir.

Neural Network (Yapay Sinir Ağları) modeli ise dengeli bir performans sunmuş olup, eğitim ve test hataları arasında büyük bir fark bulunmamaktadır. Bu durum, modelin aşırı öğrenme probleminden kaçındığını ancak doğruluk açısından Random Forest ve Gradient Boosting kadar etkili olmadığını göstermektedir.


Genel olarak, Random Forest ve Gradient Boosting algoritmaları, en düşük hata oranları ile en iyi performansı sergileyerek ısı değiştirici kapasite modellemesinde daha güvenilir tahminler sunmaktadır. KNN modeli, genelleme yeteneğinin zayıf olması nedeniyle bu tür mühendislik hesaplamalarında daha az tercih edilmelidir. Neural Network modeli ise makul bir doğruluk sunmasına rağmen, daha büyük veri setleri ve optimizasyon teknikleri ile performansının artırılması gerekmektedir.

3. SONUÇ

Eurovent test sonuçlarının yalnızca altı veri noktasından oluşması nedeniyle, sınırlı bir bölgede karşılaştırma yapılabilmektedir. Şekil 4'te sunulan grafik, Eurovent test sonuçları, Coil Designer yazılımı ve dört farklı makine öğrenimi algoritmasının (Random Forest, Gradient Boosting, Neural Network, K-Nearest Neighbors) hesapladığı kapasite değerlerini karşılaştırmaktadır. Grafik incelendiğinde, Random Forest ve Gradient Boosting algoritmalarının tahminlerinin Eurovent test sonuçlarına en yakın olduğu gözlemlenmiştir. Neural Network modeli ise genellikle makul sonuçlar üretmiş ancak belirli veri

noktalarında hata oranı artmıştır. K-Nearest Neighbors (KNN) modeli, diğer modellere kıyasla daha fazla değişkenlik göstermiş ve bazı noktalarda önemli hata oranlarına sahip olmuştur.

Makine öğrenimi modellerinin performansı, Eurovent test sonuçlarına olan yakınlıkları ile değerlendirildiğinde, Random Forest ve Gradient Boosting algoritmalarının ısı değiştirici kapasite hesaplamalarında en güvenilir tahminleri sunduğu söylenebilir. Özellikle, 6. veri noktası gibi yüksek kapasite değerlerine sahip durumlarda, Random Forest ve Gradient Boosting algoritmaları, test sonuçlarına oldukça yakın tahminler yapmıştır. Bununla birlikte, Neural Network modeli, bazı noktalarda daha yüksek hata oranına sahip olsa da genel eğilimde doğruluk göstermiştir. KNN modeli ise yüksek hata oranları nedeniyle genelleme yeteneği açısından zayıf bir performans sergilemiştir.



Şekil 4. Kapasite karşılaştırması

Yapılan analizler, makine öğrenimi tabanlı modellerin, geleneksel yazılım tabanlı yöntemlerle karşılaştırıldığında yüksek doğruluk sağladığını göstermektedir. Bununla birlikte, modellerin hassasiyetleri kullanılan veri setinin genişliği ve kalitesine bağlıdır. Tablo 2' de, hesaplanan kapasiteler ile test sonuçları arasındaki hata oranları verilmiştir. Bu sonuçlar, model eğitimi sürecinde hesaplanan hata oranlarından farklı olup, Eurovent test noktaları üzerinden yapılan bağımsız bir değerlendirmedir. Model eğitimi sırasında verilen hatalar, veri setinden rastgele seçilen %20'lik bir test grubu için hesaplanmış olup, yine yazılım sonuçları ile testi ifade etmektedir. Bu nedenle, modelin genel doğruluk seviyesinin belirlenmesi açısından Eurovent test verileri ile yapılan değerlendirmeler daha doğru bir karşılaştırma imkanı sunmaktadır. Tablo incelendiğinde, Random Forest ve Gradient Boosting algoritmalarının genel olarak düşük hata oranlarına sahip olduğu görülmektedir. Random Forest modeli, Eurovent test verileri ile kıyaslandığında en düşük hata oranına sahip model olarak öne çıkmaktadır. Gradient Boosting ise belirli noktalarda yüksek hata gösterse de genel hata dağılımı dengeli bir yapı sergilemektedir.

Tablo 2. Yüzde hata değerleri.

Eurovent Test No	Coil Designer	Random Forest	Gradient Boosting	Neural Network	K-Nearest Neighbors
1	%1.97	%-3.77	%-1.99	%-0.01	%-13.44
2	%1.20	%-8.88	%-12.93	%2.52	%-11.61
3	%2.17	%-3.85	%-4.27	%-6.64	%-2.07
4	%4.93	%-0.02	%1.11	%7.96	%13.29
5	%5.47	%5.71	%-2.36	%1.66	%8.30
6	%4.75	%7.36	%4.91	%0.94	%8.56

Neural Network modeli, bazı test noktalarında yüksek doğruluk gösterirken, belirli noktalarda hata oranı yükselmektedir. Bu durum, modelin bazı veri noktalarında genelleme yapmada zorlandığını göstermektedir. K-Nearest Neighbors algoritması ise en yüksek hata oranlarına sahip olup, bazı noktalarda Eurovent test sonuçlarından önemli ölçüde sapmalar göstermektedir. Özellikle KNN modelinin 1. veri noktasında -13.44% hata oranı ile en yüksek sapmayı gösterdiği, bununla birlikte Neural Network modelinin 4. veri noktasında 7.96% hata oranına ulaştığı gözlemlenmiştir. Random Forest ve Gradient Boosting modelleri ise genel olarak düşük hata oranları ile en iyi performansı sunmuştur. Bu durum, ısı değiştirici kapasite tahminlerinde makine öğrenimi yöntemlerinin geleneksel yöntemlere kıyasla başarılı tahminler yapabileceğini, ancak model seçiminde doğruluk ve genelleme yeteneğinin dikkate alınması gerektiğini ortaya koymaktadır.

Sonuç olarak, makine öğrenimi tabanlı modellerin ısı değiştirici kapasitesinin hesaplanmasında güvenilir ve hızlı çözümler sunduğu, ancak en iyi sonuçların algoritma seçimi ve uygun veri ön işleme süreçleri ile elde edilebileceği sonucuna varılmıştır. Bununla birlikte, sistematik ve güvenilir deneysel verilerin varlığı, modellerin doğruluğunu ve genelleme yeteneğini artırmak için büyük önem taşımaktadır.

KAYNAKLAR

- [1] J. Zou, T. Hirokawa, J. An, L. Huang, J. Camm, Recent advances in the applications of machine learning methods for heat exchanger modeling—a review, *Front. Energy Res.* 11 (2023) 1294531. <https://doi.org/10.3389/fenrg.2023.1294531>
- [2] S. Kakaç, H. Liu, A. Pramuanjaroenkij, *Heat Exchangers*, 0 ed., CRC Press, 2002. <https://www.taylorfrancis.com/books/9781420053746>
- [3] R. Du, J. Zou, J. An, L. Huang, A regression-based approach for the explicit modeling of simultaneous heat and mass transfer of air-to-refrigerant microchannel heat exchangers, *Appl. Therm. Eng.* 235 (2023) 121366. <https://doi.org/10.1016/j.applthermaleng.2023.121366>
- [4] R.L. Amalfi, J. Kim, Machine learning-based prediction methods for flow boiling in plate heat exchangers, in: 2021 20th IEEE Intersoc. Conf. Therm. Thermomechanical Phenom. Electron. Syst. ITherm, IEEE, San Diego, CA, USA, 2021: pp. 1131–1139. <https://doi.org/10.1109/ITherm51669.2021.9503302>
- [5] J. Li, C. Kharangate, Physics-Assisted Machine Learning Models for Predicting Pool Boiling Critical Heat Flux for Cryogenic Fluids, *ASME J. Heat Mass Transf.* (2024) 1–52. <https://doi.org/10.1115/1.4067339>
- [6] Z.-Y. Li, L.-L. Shao, C.-L. Zhang, Modeling of Finned-Tube Evaporator Using Neural Network and Response Surface Methodology, *J. Heat Transf.* 138 (2016) 051502. <https://doi.org/10.1115/1.4032358>
- [7] A. Pacheco-Vega, M. Sen, K.T. Yang, R.L. McClain, Neural network analysis of fin-tube refrigerating heat exchanger with limited experimental data, *Int. J. Heat Mass Transf.* 44 (2001) 763–770. [https://doi.org/10.1016/S0017-9310\(00\)00139-3](https://doi.org/10.1016/S0017-9310(00)00139-3)

- [8] M. Mohanraj, S. Jayaraj, C. Muraleedharan, Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems—A review, *Renew. Sustain. Energy Rev.* 16 (2012) 1340–1358. <https://doi.org/10.1016/j.rser.2011.10.015>
- [9] J.H. Friedman, Greedy function approximation: A gradient boosting machine., *Ann. Stat.* 29 (2001). <https://doi.org/10.1214/aos/1013203451>
- [10] T. Chen, C. Guestrin, XGBoost: A Scalable Tree Boosting System, (2016). <https://doi.org/10.48550/ARXIV.1603.02754>
- [11] L. Breiman, J.H. Friedman, R.A. Olshen, C.J. Stone, *Classification And Regression Trees*, 1st ed., Routledge, 2017. <https://doi.org/10.1201/9781315139470>
- [12] T. Cover, P. Hart, Nearest neighbor pattern classification, *IEEE Trans. Inf. Theory* 13 (1967) 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- [13] N.S. Altman, An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression, *Am. Stat.* 46 (1992) 175–185. <https://doi.org/10.1080/00031305.1992.10475879>
- [14] Kanatlı borulu ısı değıştirgeçleri tasarım yazılımı (Coil Designer), <https://www.iklimsoft.com/tr/urunler/coil-designer>

ÖZGEÇMİŞ

Hasan ACÜL

Hasan ACÜL, Yıldız Teknik Üniversitesi Makine Mühendisliği mezunu olup, Gebze Teknik Üniversitesi'nde Bilim ve Teknoloji Stratejileri alanında yüksek lisans yapmıştır. Yeni ürün geliştirme, soğutma, iklimlendirme ve sektörel yazılım konularında uzmanlaşmış, PDMA tarafından verilen NPDP sertifikasına sahiptir. Yönetici olarak yer aldığı CO₂ soğutucu akışkanlı soğutma sistemi projesi İstanbul Sanayi Odası'ndan birincilik ödülü almış, Chiller Performans ve Enerji Verimliliği Simülasyon Yazılımı geliştirme projesiyle de İSİB tarafından ödüllendirilmiştir. İKLİMSOFT firmasının kurucusu olup, mühendislik ve yöneticilik görevlerini sürdürmektedir. Ayrıca TSSF CMAS 1 Yıldız Dalış Eğitmenidir.

Altay ARBAK

1989 İstanbul doğumludur. Lisans eğitimini 2012 yılında İstanbul Üniversitesi Makine Mühendisliği bölümünde, yüksek lisans eğitimini 2014 yılında İstanbul Teknik Üniversitesi Isı ve Akışkan Programı'nda tamamlamıştır. Doktorasını 2021 yılında İstanbul Teknik Üniversitesi'nde tamamlamış olup, 2014-2018 yılları arasında İTÜ Makina Fakültesi Isı Tekniği Anabilim Dalında araştırma görevlisi olarak çalışmıştır. Halen İstanbul Medeniyet Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Makine Mühendisliği Bölümünde Doktor Öğretim Üyesi olarak çalışmalarına devam etmektedir.

Abdurrahim TÜRK

2000 Bursa doğumludur. Lisans eğitimini 2022 yılında Marmara Üniversitesi Makine Mühendisliği bölümünde tamamlamıştır. Mezuniyetinin ardından İklimsoft İklimlendirme ve Soğutma Endüstrisi Yazılımları Limited Şirketi'nde Ürün Geliştirme Mühendisi olarak çalışmaya başlamış olup, halen endüstriyel yazılım çözümleri ve mühendislik ürünlerinin geliştirilmesi üzerine çalışmalarını sürdürmektedir.

Murat ÖZCAN

2000 Bursa doğumludur. Lisans eğitimini 2024 yılında Yıldız Teknik Üniversitesi Matematik Mühendisliği bölümünde tamamlamıştır. Eğitim süresince matematiksel modelleme, algoritma geliştirme, yapay zeka ve yazılım mühendisliği konularında bilgi ve beceriler edinmiştir. İş hayatına İklimsoft İklimlendirme ve Soğutma Endüstrisi Yazılımları Limited Şirketi'nde başlamış olup, burada matematik mühendisi ve full stack developer olarak çalışmaktadır.