



Prediction of specific heat of hybrid nanofluids using artificial neural networks

Abdussamet Subaşı*^{ID}, Kasım Erdem^{ID}

Department of Mechanical Engineering, Istanbul Technical University, Istanbul, 34437, Turkey

Highlights:

- Prediction of specific heat of hybrid nanofluids with ANN
- Optimization of hyperparameters with Bayesian optimization
- Development of a specific heat estimator alternative to correlations

Keywords:

- Hybrid nanofluids
- Specific heat
- Artificial neural network
- Machine learning

Article Info:

Research Article
Received: 14.02.2021
Accepted: 06.06.2021

DOI:

10.17341/gazimmfd.880340

Correspondence:

Author: Abdussamet Subaşı
e-mail: subasiab@itu.edu.tr
phone: +90 212 293 1300

Graphical/Tabular Abstract




Figure A. Schematic representation of the network structure used in the present study.

Purpose: The aim of this study is to develop an Artificial Neural Networks (ANN) based estimator that can be used to predict the specific heat of deionized water-based CuO + MWCNT, MgO + MWCNT, and SnO₂ + MWCNT hybrid nanofluids and to investigate the usability of the ANN-based estimators instead of the commonly used correlations in the literature.

Theory and Methods:

Experimentally obtained data found in the literature on the specific heat of deionized water-based CuO + MWCNT, MgO + MWCNT and SnO₂ + MWCNT hybrid nanofluids measured for various temperature T (25 – 50°C), volume ratio φ (0.25% – 1.50%), and particle diameter d_p (20 – 50 nm) were used in the present study. The training algorithm's and the network's hyperparameters such as neuron number, hidden layer number, transfer function, epoch number, and learning rate, and the best training algorithm for the problem addressed among various training algorithms were determined by employing the Bayes optimization. K -fold cross-validation was applied as a precaution against overfitting.

Results:

It has been determined as a result of the optimization that the LM training algorithm gives the best result with the hyperparameter combination where the hidden layer number is 1, the number of neurons is 24, the epoch number is 498, the learning rate is 0.15542 and the transfer function is *logsig*. The determination coefficient (R^2) of the optimized network structure for training, validation, test data, and the whole data was found to be 0.998415, 0.995497, 0.995023, and 0.997504, respectively.

Conclusion:

It was concluded that the ANN-based estimator obtained in the present study can be used to predict the specific heat of deionized water-based CuO + MWCNT, MgO + MWCNT, and SnO₂ + MWCNT hybrid nanofluids with high accuracy. It has been determined that the ANN-based estimator reveals better performance to predict the specific heat of the hybrid nanofluids than the classical correlation. Therefore, it has been concluded that more precise and realistic calculations can be made by using the ANN-based estimator in determining the specific heat of nanofluids required in experimental and numerical studies.



Hibrit nanoakışkanların özgül ısılarının yapay sinir ağları ile tahmin edilmesi

Abdussamet Subaşı*^{ID}, Kasım Erdem^{ID}

İstanbul Teknik Üniversitesi, Makina Fakültesi, Makina Mühendisliği Bölümü, 34437 Beyoğlu, İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Hibrit nanoakışkanların özgül ısılarının YSA ile tahmini
- Bayes optimizasyonu ile hiper parametrelerin optimizasyonu
- Korelasyonlara alternatif bir özgül ısı tahminleyicisi geliştirilmesi

Makale Bilgileri

Araştırma Makalesi
Geliş: 14.02.2021
Kabul: 06.06.2021

DOI:

10.17341/gazimmfd.880340

Anahtar Kelimeler:

Hibrit nanoakışkan,
özgül ısı,
yapay sinir ağları,
makina öğrenmesi

ÖZ

Nanoakışkan kullanılan mühendislik sistemlerinin deneysel ve sayısal analizinde nanoakışkanların termofiziksel ve reolojik özelliklerinin yüksek doğrulukla belirlenmesi analiz sonuçlarının hassasiyeti üzerinde kayda değer bir etkiye sahiptir. Bu çalışmada, deiyonize su bazlı CuO + ÇDKNT, MgO + ÇDKNT ve SnO₂ + ÇDKNT hibrit nanoakışkanlarının özgül ısılarının tahmin edilmesinde kullanılacak Yapay Sinir Ağları (YSA) tabanlı bir tahminleyici geliştirilmesi ve bu tahminleyicinin literatürde yaygın olarak kullanılan korelasyonların yerine kullanılabilme potansiyelinin araştırılması hedeflenmiştir. Çalışmada, literatürde bulunan deiyonize su bazlı CuO + ÇDKNT, MgO + ÇDKNT ve SnO₂ + ÇDKNT hibrit nanoakışkanların farklı sıcaklık T (25 – 50°C), hacim konsantrasyonu φ (%0,25 – %1,50) ve partikül çapı d_p (20 – 50 nm) için deneysel olarak elde edilmiş özgül ısılarına ait veriler kullanılmıştır. Nöron sayısı, gizli katman sayısı, transfer fonksiyonu, epoch sayısı ve öğrenme oranı gibi eğitim algoritması ve ağa ait hiper parametrelerin optimum değerleri ve çeşitli eğitim algoritmaları arasından ele alınan problem için en iyi sonuç veren konfigürasyon Bayes optimizasyonu ile belirlenmiştir. Aşırı öğrenmeye karşı önlem olarak k -katlı çapraz doğrulama uygulanmıştır. Çalışma sonucunda elde edilen YSA tabanlı tahminleyici ile klasik korelasyonlara nazaran doğruluk payı daha yüksek bir tahminleme yapılabileceği ve YSA'nın nanoakışkanların özgül ısılarının belirlenmesinde kullanılacak güçlü bir araç olduğu sonucuna varılmıştır.

Prediction of specific heat of hybrid nanofluids using artificial neural networks

H I G H L I G H T S

- Hibrit nanoakışkanların özgül ısılarının YSA ile tahmini
- Bayes optimizasyonu ile hiper parametrelerin optimizasyonu
- Korelasyonlara alternatif bir özgül ısı tahminleyicisi geliştirilmesi

Article Info

Research Article
Received: 14.02.2021
Accepted: 06.06.2021

DOI:

10.17341/gazimmfd.880340

Keywords:

Hybrid nanofluids,
specific heat,
artificial neural network,
machine learning

ABSTRACT

Determination of thermophysical and rheological properties of nanofluids with high accuracy to be used in the experimental and numerical analysis of nanofluid-based engineering systems has a significant effect on the accuracy of results. The aim of this study is to develop an Artificial Neural Networks (ANN) based estimator that can be used to predict the specific heat of deionized water-based CuO + MWCNT, MgO + MWCNT, and SnO₂ + MWCNT hybrid nanofluids and to investigate the usability of the ANN-based estimators instead of the commonly used correlations available in the literature. Experimentally obtained data found in the literature on the specific heat of deionized water-based CuO + MWCNT, MgO + MWCNT and SnO₂ + MWCNT hybrid nanofluids measured for various temperature T (25 – 50°C), volume concentration φ (0.25% – 1.50%), and particle diameter d_p (20 – 50 nm) were used in the present study. The training algorithm's and the network's hyperparameters such as neuron number, hidden layer number, transfer function, epoch number, and learning rate, and the best training algorithm for the problem addressed among various training algorithms were determined by employing the Bayes optimization. K -fold cross-validation was applied as a precaution against overfitting. It was concluded as a result of the study that estimation with higher accuracy can be made with the ANN-based estimator compared to classical correlations and ANN is a powerful tool that can be used in determining the specific heat of nanofluids.

1. GİRİŞ (INTRODUCTION)

Endüstriyel uygulamalarda ısı transferinin iyileştirilmesi ihtiyacı her geçen gün artmaktadır. Bu ihtiyacı karşılamak amacıyla ısı transferini iyileştirmeye yönelik çeşitli yöntemler geliştirilmiştir. Teknolojideki gelişmelere paralel olarak artan ihtiyacı karşılamak amacıyla mevcut yöntemlerin performanslarının artırılmasını ve yeni yöntemler geliştirilmesini konu edinen çalışmalar halen güncelliğini korumaktadır. Isı transferinin iyileştirilmesinde kullanılan yöntemlerden birisi de su ve etilen glikol gibi konvansiyonel iş akışkanlarına alternatif olarak, konvansiyonel iş akışkanlarına göre gelişmiş termofiziksel özelliklere sahip alternatif iş akışkanlarının kullanılmasıdır [1, 2]. 90'lı yılların ortalarında nanometre boyutundaki katı partiküllerin bir baz akışkan içerisindeki süspansiyonu Choi ve Eastman [3] tarafından nanoakışkan olarak adlandırılmıştır. 20. yüzyılın ikinci yarısından itibaren ısı transferinin iyileştirilmesinde konvansiyonel iş akışkanlarına alternatif olabileceği için nanoakışkanlar, bilim insanlarının ilgisini çekmiş ve popüler araştırma konuları arasındaki yerini almıştır [4]. Nanoakışkan kavramının ortaya atılmasından itibaren en genel halde nanoakışkanların hazırlanması, termofiziksel ve reolojik özelliklerinin belirlenmesi, çeşitli mühendislik uygulamalarında konvansiyonel iş akışkanlarına göre performanslarının kıyaslanması ve kararlılıkları konularında sayısal ve deneysel çalışmalar yapılmaktadır [5]. Nanoakışkanlar üzerine yapılan bu çalışmaları birbirinden ayrı çalışmalar olarak değerlendirmek mümkün değildir. Zira bu çalışmaların tamamı birbiriyle doğrudan alakalıdır. Örneğin; nanoakışkanların ısı değiştiricilerindeki performansını belirlemeye yönelik olarak yapılan deneysel bir çalışmada, nanoakışkanların istenilen konsantrasyonda hazırlanmasına, elde edilen nanoakışkanda topaklanma ve/veya çökme olup olmadığının belirlenmesine ve ısı taşınım katsayısı, Nusselt sayısı, Reynolds sayısı ve sürtünme faktörü gibi büyüklüklerin hesaplanmasına ihtiyaç duyulmaktadır. Dolayısıyla ısı transferi hesaplamalarının yapılabilmesi için ele alınan sistemde iş akışkanı olarak kullanılan nanoakışkanın termofiziksel ve reolojik özelliklerine ve bu özelliklerin sıcaklıkla değişimine ihtiyaç duyulmaktadır. Benzer şekilde, aynı konu üzerine yapılacak sayısal bir çalışmada da her ne kadar nanoakışkanların hazırlanmasına ve kararlılığına yönelik bir bilgiye ihtiyaç duyulmasa da incelenen nanoakışkanın termofiziksel ve reolojik özelliklerine ihtiyaç duyulmaktadır. Sayısal modellemenin yapılabilmesi için ele alınan nanoakışkanın termofiziksel özelliklerinin yanı sıra viskozite tipinin belirlenmesi de oldukça önemlidir. Dolayısıyla nanoakışkanları konu edinen gerek deneysel gerek sayısal çalışmalarda incelenen konuya bağlı olarak ısı iletim katsayısı, yoğunluk, viskozite, özgül ısı, yüzey gerilimi ve ıslatma davranışı gibi termofiziksel ve reolojik özelliklerin tamamının veya bir kısmının hassas bir şekilde belirlenmesine ihtiyaç duyulmaktadır [6, 7]. Zira yapılan hesaplamaların ve modellemenin doğruluğu, gerekli termofiziksel ve reolojik özelliklerin hassasiyetiyle

doğrudan ilişkilidir. Literatürde nanoakışkanların termofiziksel ve reolojik özelliklerinin belirlenmesine yönelik çok sayıda deneysel çalışma bulmak mümkündür. Bu çalışmalarda araştırmacılar genellikle ele aldıkları nanoakışkanların özelliklerini farklı nanopartikül konsantrasyonlarında, farklı partikül çaplarında, farklı baz akışkan ve yüzey aktif madde kullanılması gibi çeşitli durumlarda incelemekte ve elde ettikleri sonuçları grafik olarak ve/veya farklı formlarda korelasyonlar türeterek diğer araştırmacıların istifadesine sunmaktadırlar. Literatürdeki çalışmalar incelendiğinde nanoakışkanların ısı iletim katsayılarının, dinamik viskozitelerinin ve yüzey gerilimlerinin belirlenmesine yönelik çalışmalara sıklıkla rastlanırken [8, 9], nanoakışkanların yoğunluğunun ve özgül ısılarının deneysel olarak belirlenmesine yönelik az sayıda çalışma olduğu dikkat çekmektedir [10-12].

Nanoakışkanların yoğunluğunun ve özgül ısılarının deneysel olarak belirlenmediği birçok sayısal ve deneysel çalışmada, nanoparçacıkların ve baz akışkanların özelliklerini, nanoparçacık konsantrasyonu ile birlikte değerlendirerek nanoakışkanların yoğunluğunu ve özgül ısılarını veren Pak ve Cho [13] ve Xuan ve Roetzel [14] tarafından önerilen bağıntılar kullanılmaktadır. Literatürde, nanoakışkanların özgül ısılarının deneysel olarak belirlendiği ve bu ve benzeri bağıntılarla karşılaştırıldığı çalışmalar arasında, deneysel ölçümlerden elde edilen sonuçlar ile bağıntılar kullanılarak elde edilen sonuçlar arasındaki farkın kayda değer miktarda olduğunu belirten çok sayıda çalışmaya rastlamak mümkündür [15, 16]. Dolayısıyla deneysel olarak belirlenmiş değerler yerine çeşitli bağıntılar ve korelasyonlar kullanılarak belirlenen değerlerin ısı transferi hesaplamalarında ve simülasyonlarda kullanılmasıyla elde edilecek sonuçlar ile gerçek sonuçlar arasında kayda değer bir sapma olabileceği açıktır.

Son yıllarda, bilgisayar bilimi ve sayısal yöntemlerdeki gelişmelere bağlı olarak bilgisayar deneylerinin (simülasyonların) güvenilirliği artarken hesaplama maliyetleri de görece azalmıştır. Bu durum, sistem tasarımı ve analizinde Hesaplamalı Akışkanlar Dinamiğini (HAD) vazgeçilmez bir mühendislik aracı haline getirmiştir. HAD'da izlenen metodoloji, ele alınan konuda yapılmış referans bir deneysel çalışma ile doğrulandıktan sonra araştırılmak istenen spesifik hususlar HAD simülasyonları ile hızlı bir şekilde incelenebilmektedir. Bunun bir sonucu olarak; uzun süreli, maliyetli ve zahmetli deneysel çalışmalara olan ihtiyaç her ne kadar önemini ve gerekliliğini hala muhafaza etse de daha az sayıda deney yaparak araştırma yapılabilme imkânı sağlanmıştır. Nanoakışkan kullanılan mühendislik sistemlerinin tasarımı ve analizi de bu gelişmeden etkilenmiştir. Bununla birlikte, nanoakışkan kullanılan sistemlerde HAD sonuçlarının doğruluğu ve güvenilirliği HAD simülasyonlarında izlenen metodoloji ile doğrudan alakalı olduğu gibi nanoakışkanların yukarıda bahsedilen çeşitli bağıntılar kullanılarak belirlenen özgül ısı değerleri ile deneysel olarak belirlenen özgül ısı değerleri arasındaki kayda değer fark göz önünde bulundurularak,

simülasyonlarda kullanılan nanoakışkanın termofiziksel ve reolojik özelliklerinin doğruluğu ve hassasiyetiyle de yakından ilişkili olduğu anlaşılmaktadır. Bu nedenler, gerçekleştirilen çalışmanın deneysel ya da sayısal olmasından bağımsız olarak nanoakışkanların termofiziksel ve reolojik özelliklerinin hassas bir şekilde belirlenmesini elzem kılmaktadır.

Teknolojideki gelişime paralel olarak, veri bilimi, yapay zekâ ve makina öğrenmesi son zamanlarda hayatımızın çeşitli alanlarında olduğu gibi bilim ve mühendisliğin çeşitli alanlarında [17-19] da kendine geniş bir yer bulmuştur. Makina öğrenmesi ile elde edilen modeller, nanoakışkanların termofiziksel ve reolojik özelliklerinin tahmin edilmesinde de klasik yaklaşımla elde edilen korelasyonların bir alternatifi olarak düşünülmektedir. Bu konuda bir literatür taraması yapıldığında makina öğrenmesi kullanılarak çeşitli nanoakışkanların ısı iletim katsayısı ve viskozite gibi özelliklerinin belirlenmesine yönelik kayda değer sayıda çalışmaya rastlamak mümkünken, nanoakışkanların özgül ısılarının deneysel olarak belirlenmesinde olduğu gibi nanoakışkanların özgül ısılarının ve yoğunluklarının makina öğrenmesi ile tahmin edilmesine yönelik de oldukça az sayıda çalışmaya rastlanmaktadır [20, 21]. Tablo 1’de literatür araştırması sonucunda nanoakışkanların özgül ısılarının makina öğrenmesi kullanılarak tahmin edilmesine yönelik yapılan çalışmaların bir özeti verilmiştir.

Literatür taraması neticesinde, nanoakışkanların özgül ısılarının makina öğrenmesi ile tahmin edilmesine yönelik ilk çalışmanın 2019 yılına yapıldığı anlaşılmaktadır. Tablo 1’de özetlenen çalışmaların detaylarına bakıldığında çalışmaların tamamının Al_2O_3 , SiO_2 , TiO_2 ve CuO gibi yaygın olarak kullanılan nanoakışkanların [25] özgül ısılarının belirlenmesine yönelik olduğu ve içlerinden sadece birinin hibrit nanoakışkanları konu edindiği anlaşılmaktadır. Ayrıca çalışmaların büyük çoğunluğunun Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) kullanılarak gerçekleştirildiği ve çalışmalarda; makina öğrenmesi modellerinin girdi değişkenlerinin ve modellerin geliştirilmesinde kullanılan veri sayısının bazı çalışmalarda görece kısıtlı tutulduğu literatür taraması sonucunda ulaşılan önemli sonuçlar arasında yer almaktadır.

Literatür taramasından anlaşılacağı üzere nanoakışkanların özgül ısılarının deneysel olarak belirlenmesine ve makina öğrenmesi yöntemleri kullanılarak tahmin edilmesine yönelik oldukça az sayıda çalışma olduğu anlaşılmaktadır. Isı transferi hesaplamaları ve HAD simülasyonlarında nanoakışkanların diğer termofiziksel özellikleri kadar önemli olan özgül ısıyı da doğru bir şekilde belirlenmesi ihtiyacı yukarıda gerekçeleriyle izah edilmiştir. Bu çalışmanın amacı da literatürde rastlanmayan deiyonize su bazlı $CuO + \text{ÇDKNT}$, $MgO + \text{ÇDKNT}$ ve $SnO_2 + \text{ÇDKNT}$ hibrit nanoakışkanlarının özgül ısılarının tahmin edilmesinde klasik korelasyonlara alternatif olabilecek YSA tabanlı bir tahminleyici elde etmektir. Çalışmada Tiwari vd. [26] tarafından 2020 yılında yayımlanan makaledeki deneysel verilerden yararlanılmıştır. Geliştirilen kod ile

hiper parametrelerin optimum değerleri Bayes optimizasyonu vasıtasıyla belirlenerek, elde edilen ağın azami performansa ulaştırılması hedeflenmiştir. Son olarak, elde edilen YSA tabanlı tahminleyicinin performansı Tiwari vd. [26] tarafından önerilen korelasyonla karşılaştırılarak makina öğrenmesi modellerinin klasik korelasyonlara alternatif olarak kullanılıp kullanılmayacağı ve bu iki yaklaşımın birbirlerine göre avantajları ve dezavantajları üzerine derinlemesine bir değerlendirme yapılmıştır. Makalenin geri kalan kısmı şu şekilde organize edilmiştir: Bölüm 2’de çalışmada kullanılan veri setinden ve uygulanan yöntemin detaylarından bahsedilmiştir. Bölüm 3’te araştırmadan elde edilen sonuçlar karşılaştırmalı olarak verilerek detaylı bir değerlendirme yapılmıştır. Son olarak Bölüm 4’te ise çalışmanın önemli sonuçları özet olarak verilmiştir.

2. MATERYAL VE YÖNTEM (MATERIAL and METHOD)

2.1. Verilerin Elde Edilmesi (Data Acquisition)

Nanoakışkanların ve hibrit nanoakışkanların özgül ısılarının deneysel olarak belirlenmesini konu edinen oldukça az sayıda çalışma olduğu için bu konuda güvenilir verilere ulaşmak son derece zordur. Bu çalışmada kullanılan veri seti 2020 yılının son çeyreğinde Tiwari vd. [26] tarafından yayımlanan makaleden elde edilmiştir. Deneysel çalışmalarında Tiwari vd. [26] metal oksit tabanlı nanoparçacıklar olan CuO , MgO ve SnO_2 ile ÇDKNT’yi ağırlıkça 80:20 oranında ve yüzey aktif madde CTAB’ı nanoparçacık-yüzey aktif madde (CTAB) karışım oranı 3:2 olacak şekilde karıştırarak farklı hacimsel konsantrasyonlarda deiyonize su bazlı $CuO + \text{ÇDKNT}$, $MgO + \text{ÇDKNT}$ ve $SnO_2 + \text{ÇDKNT}$ hibrit nanoakışkanlarını elde etmişlerdir. Tiwari vd. [26] ÇDKNT’nin çalışmalarında yaygın kullanılan CuO , MgO ve SnO_2 ’nin termofiziksel özellikleri üzerindeki etkisini partikül çapını (d_p), hacim oranını (ϕ) ve sıcaklığı (T) değiştirerek incelemişlerdir. Elde ettikleri hibrit nanoakışkanların özgül ısılarını Diferansiyel Taramalı Kalorimetre (DTK) kullanarak ölçmüşlerdir. Ölçümlerin belirsizliğinin %2’den az olduğunu ve hata oranını düşürmek için her bir numunenin özgül ısı ölçümünü dört kere tekrarladıklarını ve çalışmalarında bu ölçümlerin ortalamasını sunduklarını belirtmişlerdir. Çalışmada inceledikleri parametreler ve aralıkları Tablo 2’de detaylı olarak verilmiştir. Bu çalışmada Tiwari vd. [26] tarafından yayımlanan makaleden elde edilen 432 deneysel veri YSA modelinin geliştirilmesinde kullanılmıştır.

2.2. Yapay Sinir Ağları (Artificial Neural Network)

YSA, doğrusal ve doğrusal olmayan girdi(ler) ve çıktı(lar) arasında insan sinir sisteminin davranışlarını taklit ederek ilişki kuran bir bilgi işleme yapısıdır. Hem sınıflandırma hem de regresyon işlemlerinde yüksek performans gösterdikleri kanıtlanmıştır [27]. YSA’nın bir türü olan Çok Katmanlı Algılayıcı (ÇKA), girdi katmanı, bir veya daha fazla gizli katman ve çıktı katmanından oluşmaktadır [28]. Her katman birbirine bağlanmış nöronlardan oluşmaktadır. Nöronlar

Tablo 1. Çeşitli makina öğrenmesi yöntemleri kullanılarak nanoakışkanların özgül ısılarının tahmin edilmesi üzerine yapılan çalışmaların özeti
(Summary of studies on the prediction of specific heat of nanofluids using various machine learning methods)

Ref.	Parçacık	Baz Akışkan	Model Girdileri ve Aralıkları			Yöntem	Veri Sayısı	
Alade vd. [21]	Al ₂ O ₃	Su	ϕ (% v/v)	3,70	9,30	DVR GA	E D	105 %80 %20
			$C_{p,np}$ (J/g·K)	0,774	0,896			
Hassan ve Anarje [20]	SiO ₂ TiO ₂ Al ₂ O ₃	Erimiş tuz KNO ₃ - NaNO ₃ (60:40 molar)	d_p (nm)	10	30	YSA	E D P	1620 %70 %15 %15
			T (°C)	250	500			
			ϕ (% m/m)	0,5	2,00			
			$C_{p,np}$ (J/g·K)	0,69	1,10			
Alade vd. [9]	Al ₂ O ₃	Etilen glikol	T (K)	296,33	336,45	YSA DVR	E P	105 %80 %20
			ϕ (% v/v)	1,00	8,10			
			$C_{p,np}$ (J/g·K)	0,77	0,90			
			$C_{p,bf}$ (J/g·K)	2,40	2,60			
Alade vd. [22]	Al ₂ O ₃ CuO	Etilen glikol	T (K)	296,31	337,43	YSA DVR	E P	189 %80 %20
			ϕ (% v/v)	0,40	8,10			
			$C_{p,np}$ (J/g·K)	0,53	0,58			
			$C_{p,bf}$ (J/g·K)	2,41	2,60			
Alade vd. [23]	CuO	Su	T (K)	298,30	337,89	YSA DVR	E D	105 %80 %20
			ϕ (% v/v)	0,40	2,00			
			$C_{p,np}$ (J/g·K)	0,533	0,597			
Çolak vd. [10]	Al ₂ O ₃ – Cu	Su Gum Arabic (Yüzey Aktif Madde)	T (°C)	20	65	YSA	E D P	1287 %70 %10 %20
			ϕ (% v/v)	0,0125	0,2			
Çolak [24]	Al ₂ O ₃	Su Gum Arabic (Yüzey Aktif Madde)	T (°C)	~20	~90	YSA	E D P	260, 210, 155, 100, 50 %70 %20 %10
			ϕ (% v/v)	0,0125	0,2			

dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirerek çıktığı üretilen ağ bağlantıları üzerinden bir sonraki katmanda yer alan nöronlara iletir. Ağa girdi katmanından iletilen veriler ara katman(lar)da işlendikten sonra çıktı katmanına gönderilirler. Ağ yapısının verilen girdilere karşılık gelen çıktıları doğru bir şekilde belirleyebilmesi için ağırlık değerlerinin doğru belirlenmesi ve uygun bir transfer fonksiyonu kullanılması gerekir. Ağın eğitilmesi,

ağırlıkların optimum değerlerinin bulunması işlemidir. Yazarlar, YSA hakkında daha detaylı bilgi almak isteyen okuyuculara [29-31] kaynaklarını tavsiye etmektedir.

Bu çalışmada, ÇKA hibrit nanoakışkanların özgül ısılarını tahmin etmede kullanılmıştır. Tablo 2’de belirtildiği gibi sıcaklık (T), hacim oranı (ϕ), partikül çapı (d_p) ve nanoparçacık türü (S) girdi değişkenleri olarak, nanoakışkanların özgül ısı değeri ($C_{p,np}$) de çıktı değişkeni

olarak ele alınmıştır. Nanoparçacık türü kategorik veri, diğer girdi ve çıktı değişkenleri ise nümerik veri olarak değerlendirilmeye alınmıştır. Veriler, ağı eğitmede kullanılmadan önce Eş. 1 vasıtasıyla 0,1 ile 0,9 aralığında normalize edilmiştir. Çalışmada kullanılan ağ yapısı şematik olarak Şekil 1'de gösterilmiştir.

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} (x_{\max}^{\text{yeni}} - x_{\min}^{\text{yeni}}) + x_{\min}^{\text{yeni}} \quad (1)$$

Ağın ve eğitim algoritmasının hiper parametreleri nihai sonucu doğrudan etkilemektedir. Bu nedenle eğitilen ağdan azami performansı elde edebilmek için ağ yapısıyla ve eğitim algoritmasıyla alakalı hiper parametrelerin optimize edilmesi hayati öneme sahiptir. Hiper parametreler çeşitli yöntemler kullanılarak optimize edilebilmektedir. En yaygın olarak kullanılan yöntemlerden biri Bayes optimizasyonudur [32]. Bu çalışmada, nöron sayısı, gizli katman sayısı, transfer fonksiyonu, epoch sayısı ve öğrenme oranı gibi hiper parametrelerin yanı sıra farklı eğitim algoritmalarının performansı da optimizasyon problemine dahil edilmiş ve Bayes optimizasyonu kullanılarak optimum ağ yapısı elde edilmiştir. Bayes optimizasyonunda ele alınan parametreler Tablo 3'te verilmiştir.

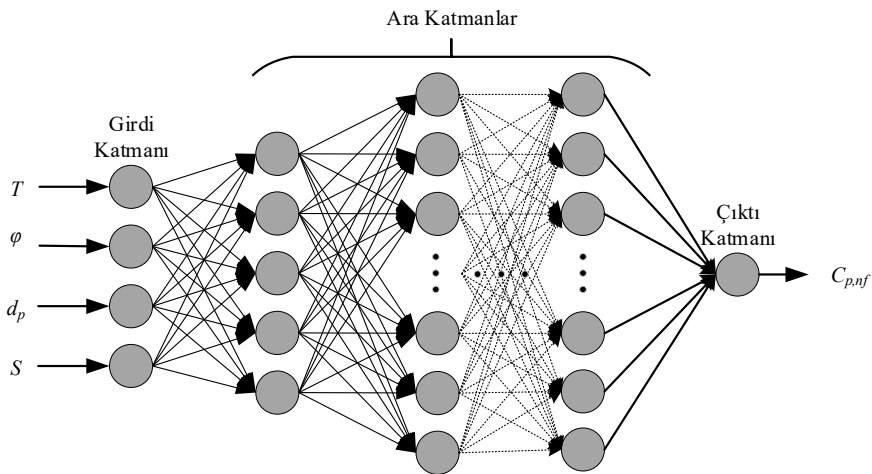
Tablo 3. Bayes optimizasyonunda ele alınan parametreler (Parameters considered in Bayesian optimization)

Parametreler	Aralık
Gizli katman sayısı	1-2
Nöron sayısı	5-70
Epoch sayısı	50-500
Öğrenme oranı	0,01-1
Eğitim algoritması	LM, BFG, RP
Transfer fonksiyonu	logsig, tansig, purelin

Hiper parametrelerin optimize edilmesi ve en uygun eğitim algoritmasının belirlenmesine ek olarak makina öğrenmesi uygulamalarında sıklıkla rastlanan aşırı öğrenme ve yetersiz öğrenme gibi istenmeyen durumlardan kaçınmak için de çeşitli tedbirler alınması elzemdir. Bu çalışmada önlem olarak 8-katlı çapraz doğrulama uygulanmıştır. Çalışmada hiper parametrelerin optimize edilmesi, en uygun öğrenme algoritmasının belirlenmesi ve k -katlı çapraz doğrulama süreçlerinde izlenen metodoloji aşağıda kaba kod olarak verilmiştir. (Tablo 4)

Tablo 2. Tiwari vd. [26] tarafından incelenen parametreler ve aralıkları (Parameters and ranges studied by Tiwari et al. [26])

Veri Sınıfı	Değişken	Minimum	Maksimum
Girdiler	Sıcaklık, T (°C)	25	50
	Hacim oranı, φ (% v/v)	0,25	1,50
	Partikül çapı, d_p (nm)	20	50
	Nanoparçacık Türü, S (-)	CuO + ÇDKNT (80:20 % m/m) MgO + ÇDKNT (80:20 % m/m) SnO ₂ + ÇDKNT (80:20 % m/m)	
Çıktı	Nanoakışkanın özgül ısısı, $C_{p,nf}$ (kJ/kg·K)	3,54867	4,09592



Şekil 1. Çalışmada kullanılan ağ yapısının şematik gösterimi (Schematic representation of the network structure used in the present study)

Tablo 4. Ağ modelinin eğitilmesi için kullanılan sözde-kod (Pseudo-code used to train the network model)

Algoritma										
1. Veriyi oku										
2. Veriyi normalize et										
3. Veriyi rastgele karıştır										
4. Eğitim, doğrulama ve test için ayrılacak veri yüzdeliklerini belirle										
5. Veriyi; eğitim, doğrulama ve test verisi olmak üzere yüzdeliklerine göre ayır										
6. Test verisinin dışında kalan verileri mümkün olduğunca eşit dağıtarak K gruba böl										
7. Bayes optimizasyonu ile hiper parametre kombinasyonlarını belirle, C										
8. (dış döngü) C 'deki her bi c_i hiper parametre kombinasyonu için <ol style="list-style-type: none"> <tr> <td>1. (iç döngü) K grup içerisindeki her bir k_i alt grubu için: <ol style="list-style-type: none"> <tr> <td>1. k_i grubunu doğrulama verisi olarak ayarla</td> </tr> <tr> <td>2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit</td> </tr> <tr> <td>3. Modelin performansını k_i grubuna göre değerlendir</td> </tr> <tr> <td>2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla</td> </tr> </td> </tr> <tr> <td>9. Bayes optimizasyonu ile en iyi ortalama performansı veren hiper parametre kombinasyonu belirle</td> </tr> <tr> <td>10. Eğitim verisini en iyi hiper parametre kombinasyonunu kullanarak ağı eğit</td> </tr> <tr> <td>11. Doğrulama verisini kullanarak eğitilen ağın performansını belirle</td> </tr> <tr> <td>12. Daha önce ağı hiç görmediği test verisini kullanarak hibrit nanoakışkanların özgül ısılarını tahmin et</td> </tr> <tr> <td>13. Sonuçları raporla</td> </tr> 	1. (iç döngü) K grup içerisindeki her bir k_i alt grubu için: <ol style="list-style-type: none"> <tr> <td>1. k_i grubunu doğrulama verisi olarak ayarla</td> </tr> <tr> <td>2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit</td> </tr> <tr> <td>3. Modelin performansını k_i grubuna göre değerlendir</td> </tr> <tr> <td>2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla</td> </tr> 	1. k_i grubunu doğrulama verisi olarak ayarla	2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit	3. Modelin performansını k_i grubuna göre değerlendir	2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla	9. Bayes optimizasyonu ile en iyi ortalama performansı veren hiper parametre kombinasyonu belirle	10. Eğitim verisini en iyi hiper parametre kombinasyonunu kullanarak ağı eğit	11. Doğrulama verisini kullanarak eğitilen ağın performansını belirle	12. Daha önce ağı hiç görmediği test verisini kullanarak hibrit nanoakışkanların özgül ısılarını tahmin et	13. Sonuçları raporla
1. (iç döngü) K grup içerisindeki her bir k_i alt grubu için: <ol style="list-style-type: none"> <tr> <td>1. k_i grubunu doğrulama verisi olarak ayarla</td> </tr> <tr> <td>2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit</td> </tr> <tr> <td>3. Modelin performansını k_i grubuna göre değerlendir</td> </tr> <tr> <td>2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla</td> </tr> 	1. k_i grubunu doğrulama verisi olarak ayarla	2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit	3. Modelin performansını k_i grubuna göre değerlendir	2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla						
1. k_i grubunu doğrulama verisi olarak ayarla										
2. K grup arasından k_i grubu çıkarılınca geriye kalan $K-1$ grup için ağı eğit										
3. Modelin performansını k_i grubuna göre değerlendir										
2. c_i hiper parametre kombinasyonu için K gruba göre ortalama performansı hesapla										
9. Bayes optimizasyonu ile en iyi ortalama performansı veren hiper parametre kombinasyonu belirle										
10. Eğitim verisini en iyi hiper parametre kombinasyonunu kullanarak ağı eğit										
11. Doğrulama verisini kullanarak eğitilen ağın performansını belirle										
12. Daha önce ağı hiç görmediği test verisini kullanarak hibrit nanoakışkanların özgül ısılarını tahmin et										
13. Sonuçları raporla										

3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Çalışmada kullanılan 432 adet verinin %70'i ağı eğitmede, %15'i eğitilen ağı doğrulanmasında ve geriye kalan %15'i de eğitilen ağı test etmek için kullanılacak şekilde organize edilmiştir. Bölüm 2.2'de detayları verilen yöntem izlenerek 100 farklı hiper parametre kombinasyonu için Bayes optimizasyonu uygulanmıştır. Optimizasyondan elde edilen sonuçlar Tablo 5'te verilmiştir. Tablo 5 incelendiğinde ele alınan çalışma için en uygun eğitim algoritmasının LM olduğu ve eğitim algoritması ve ağı hiper parametrelerinin optimum değerlerinin ise gizli katman sayısı için 1, nöron sayısı için 24, epoch sayısı için 498, öğrenme oranı için 0,15542 ve transfer fonksiyonu için de *logsig* olduğu belirlenmiştir.

Tablo 5. Bayes optimizasyonu sonucunda ele alınan parametrelerin optimum değerleri
(Optimum values of parameters obtained as the result of Bayesian optimization)

Parametreler	Optimum Değer
Gizli katman sayısı	1
Nöron sayısı	24
Epoch sayısı	498
Öğrenme oranı	0,15542
Eğitim algoritması	LM
Transfer fonksiyonu	<i>logsig</i>

LM eğitim algoritması ile hiper parametrelerin optimum değerleri kullanılarak eğitilen ağın performansı MAE, MSE, RMSE ve R^2 gibi performans ölçütleri kullanılarak değerlendirilmiştir. Performans değerlendirmesi, eğitim, doğrulama ve test verileri için ayrı ayrı yapıldığı gibi tüm veriler için de yapılmış ve elde edilen sonuçlar Tablo 6'da özetlenmiştir. Tablo 6'da verilen ve deneysel özgül ısı değerleriyle eğitilen ağ kullanılarak tahmin edilen özgül ısı değerleri kullanılarak hesaplanan MAE, MSE ve RMSE hata

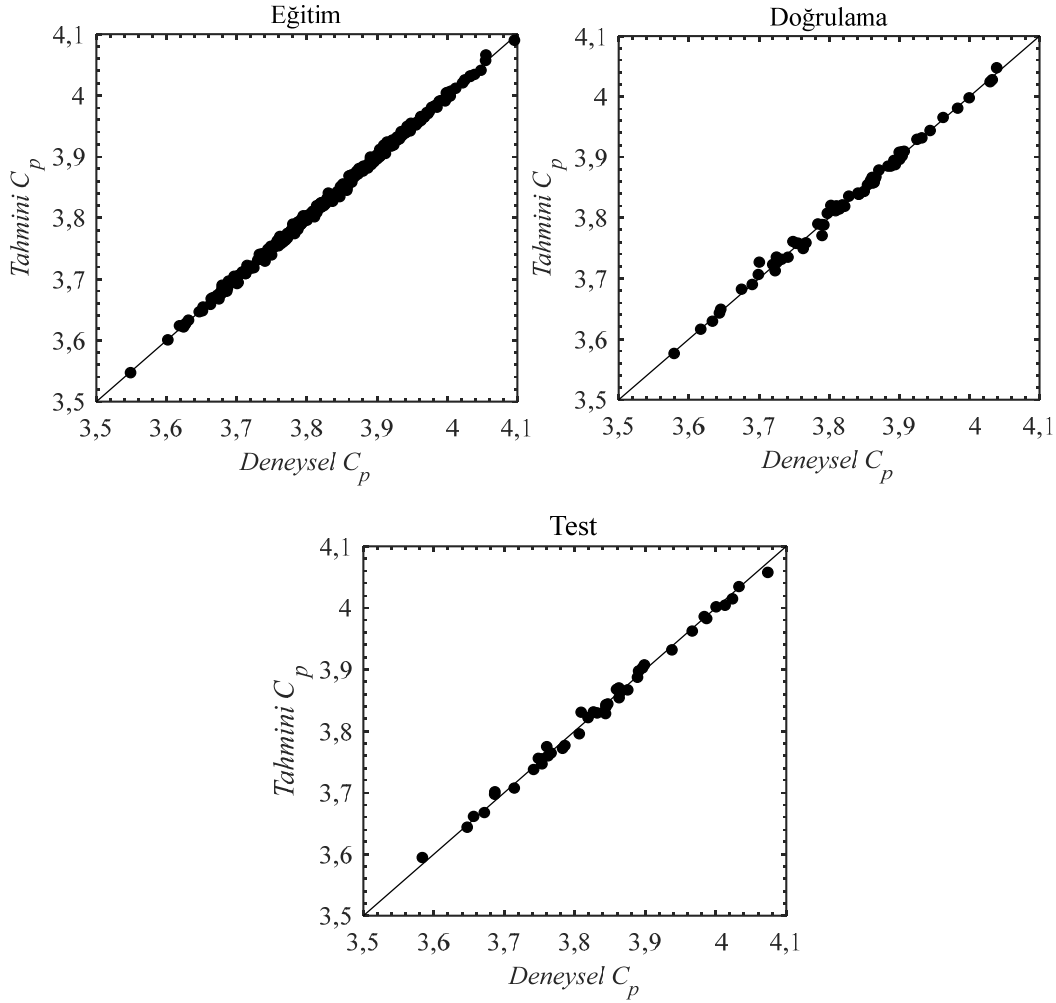
değerlerinin kabul edilebilir sınırlar içerisinde olduğu değerlendirilmiştir. Tablo 6'da farklı veri grupları için verilen ve 0 ile 1 arasında değer alabilen açıklayıcılık katsayısı R^2 'nin tüm veri grupları için 1'e oldukça yakın olduğu anlaşılmaktadır. Açıklayıcılık katsayısı R^2 'nin 1'e yakın olması çalışmada elde edilen YSA tabanlı tahminleyicinin performansının oldukça iyi olduğuna işaret etmektedir.

Tablo 6. Bayes optimizasyon neticesinde elde edilen konfigürasyon kullanılarak eğitilen ağın performans değerlendirmesi

(Performance evaluation of the trained network using the configuration obtained as the result of Bayesian optimization)

Performans Ölçütü	Eğitim	Doğrulama	Test	Tüm Veriler
MAE	0,004415	0,007222	0,009911	0,005384
MSE	0,000033	0,000102	0,000145	0,000055
RMSE	0,005767	0,010113	0,012044	0,007401
R^2	0,998415	0,995497	0,995023	0,997504

Tablo 6'da verilen performans ölçütlerine ek olarak eğitilen ağın performansı Şekil 2 incelenerek de değerlendirilebilir. Şekil 2'nin yatay ekseninde deneysel olarak belirlenmiş özgül ısı değerleri yer alırken düşey ekseninde eğitilen ağ kullanılarak tahmin edilen özgül ısı değerleri yer almaktadır. Şekil 2'de verilere ek olarak $Y=X$ şeklinde bir doğru da çizilmiştir. Verilerin $Y=X$ doğrusunun üzerinde olması ya da bu doğrudan olan sapma miktarının az olması çalışmada eğitilen ağ kullanılarak yapılan özgül ısı tahmininin deneysel olarak ölçülen değere oldukça yakın olduğu anlamını taşımaktadır. Eğitim, doğrulama ve test verileri için Şekil 2'de ayrı ayrı verilen grafikler incelendiğinde verilerin $Y=X$ doğrusundan olan sapmalarının ve saçılmalarının oldukça az olduğu anlaşılmaktadır. Bu noktada, test için ayrılan verinin, ağı eğitilmesinde kullanılmadığına yani ağı test verisiyle daha önce karşılaşmadığına dikkat çekmek gerekir. Buradan, bu çalışma kapsamında elde edilen ağa, daha önce ağı eğitilmesinde kullanılmayan bir veri girişi yapıldığında dahi



Şekil 2. Eğitim, doğrulama ve test verileri için deneysel olarak belirlenen özgül ısının bu çalışmada eğitilen ağ kullanılarak tahmin edilen özgül ısı ile değişimi (Variation of experimentally determined specific heat with specific heat predicted using the network trained in this study, for training, validation, and testing data)

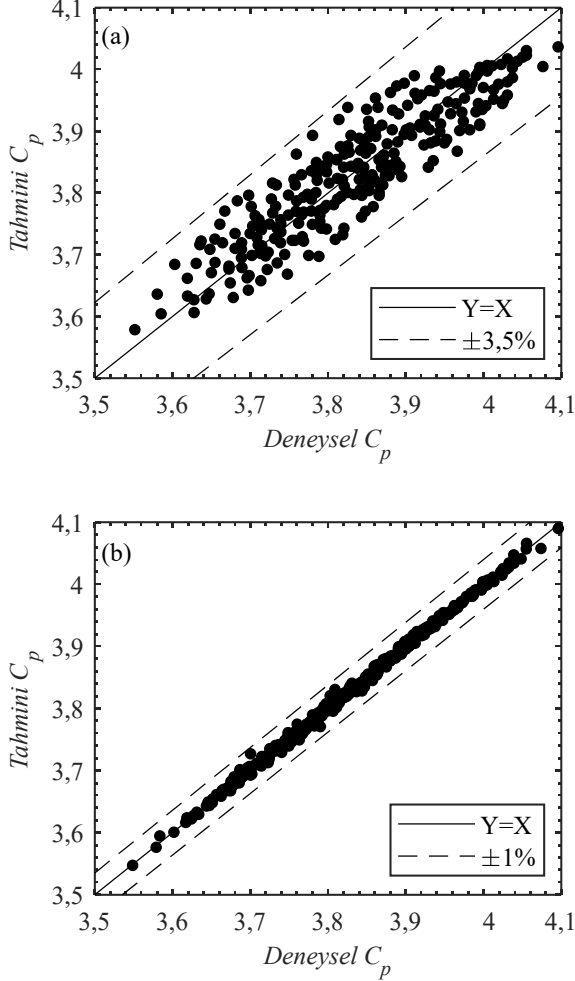
kayda değer bir performansla tahminleme gerçekleştirdiği ve dolayısıyla ağın performansının oldukça iyi olduğu sonucuna varılır.

Bu çalışmanın diğer bir amacı da nanoakışkanların termofiziksel ve reolojik özelliklerinin tahmin edilmesinde YSA tabanlı tahminleyicilerin klasik korelasyonlara alternatif olarak kullanılıp kullanılmayacağını tartışılmasıdır. Bu değerlendirmeyi yapabilmek için bu çalışmada kullanılan deneysel verilerin alındığı Tiwari vd. [26] tarafından yapılan çalışmada önerilen ve Eş. 2’de verilen korelasyon ile bu çalışma kapsamında elde edilen YSA tabanlı tahminleyicinin performansı karşılaştırılmıştır.

$$C_{p,nf} = C_{p,bf} \left(1 - 10,6364 \left(\frac{T}{T_0} \right)^{-0,771} \varphi^{0,448} \right) \times \left(\left(\frac{d_{np}}{d_0} \right)^{-0,474} \left(\frac{C_{p,np}}{C_{p,bf}} \right)^{1,027} \left(\frac{\rho_{nf}}{\rho_{bf}} \right)^{-2,742} \right) \quad (2)$$

Bu değerlendirmede 432 deneysel veri kullanılarak iki yaklaşımla yapılan tahminleme performansı karşılaştırılmış ve Şekil 3’te gösterilmiştir. Şekil 3’te tıpkı Şekil 2’de verildiği gibi deneysel özgül ısı değerleriyle tahmin edilen özgül ısı değerleri her iki yaklaşım için verilmiştir. Şekil 3(a)’da Eş. 2’de verilen korelasyona ait karşılaştırma yer alırken Şekil 3(b)’de YSA tabanlı tahminleyiciye ait karşılaştırmaya yer verilmiştir. Şekil 3(a)’dan korelasyon kullanılarak tahmin edilen değerlerin $Y=X$ şeklinde verilen karşılaştırma doğrusundan saptığını ve verilerin $\pm\%3,5$ bandında salınım yaptığı, Şekil 3(b)’den ise YSA tabanlı tahminleyici için verilerin karşılaştırma doğrusundan olan sapma miktarının $\pm\%1$ civarında olduğu anlaşılmaktadır. Bu değerlendirme ile YSA’nın korelasyona göre daha iyi bir tahminleme performansı sergilediği sonucuna varılabilir. Ayrıca korelasyonun elde edilmesinde tüm veri setinin kullanıldığı fakat YSA tabanlı tahminleyicinin eğitilmesinde test için ayrılan verilerin dışındaki verilerin kullanıldığı yani daha az sayıda veri kullanarak daha iyi bir tahminleyici elde edildiği bu çalışmanın önemli sonuçları arasında yer almaktadır. Her ne kadar klasik korelasyonları akademik

yayınlarında verip diğer bilim insanlarının istifadesine sunmanın YSA tabanlı tahminleyicilere göre daha kolay olması korelasyonların bir avantajı gibi görünse de performans bakımından daha zayıf sonuç verdiği göz ardı edilmemelidir. Bu değerlendirmelerle birlikte, YSA yaklaşımının nanoakışkanların özgül ısılarının belirlemede uygun bir yöntem olduğu sonucuna varılmıştır.



Şekil 3. Deneysel olarak belirlenen özgül ısının, a) Eş. 2'de verilen korelasyon ve b) bu çalışmada eğitilen ağ kullanılarak tahmin edilen özgül ısı ile değişimi (Variation of experimentally determined specific heat with specific heat predicted using a) the correlation in Eq. 2 and b) the network trained in this study)

4. SİMGELER (SYMBOLS)

C	: Hiper parametre kombinasyonları
c_i	: i. hiperparametre kombinasyonu
C_p	: Özgül ısı (kJ/kg·K)
d	: Çap (nm)
D	: Doğrulama verisi
E	: Eğitim verisi
K	: Veri grubu sayısı
k_i	: i. veri grubu
P	: Test verisi

S	: Nanoparçacık türü
T	: Sıcaklık ($^{\circ}\text{C}$, K)

4.1. Yunan Harfleri (Greek Letters)

ρ	: Yoğunluk (kg/m^3)
φ	: Hacim oranı (%)

4.2. Alt İndisler (Subscripts)

bf	: Baz akışkan
i	: İndeks
max	: Maksimum
min	: Minimum
nf	: Nanoakışkan
np	: Nanopartikül
0	: Referans durum

4.3. Kısaltmalar (Abbreviations)

ANN	: Artificial neural network
BFG	: BFGS quasi-Newton backpropagation algoritması
CTAB	: Setil-trimetil-amonyum bromit
ÇDKNT	: Çok duvarlı karbon nanotüp
ÇKA	: Çok katmanlı algılayıcı
DVR	: Destek vektör regresyonu
DTK	: Diferansiyel taramalı kaloliretme
GA	: Genetik algoritma
HAD	: Hesaplamalı akışkanlar dinamiği
LM	: Levenberg-Marquardt algoritması
MAE	: Ortalama mutlak hata
MSE	: Ortalama kare hata
MWCNT	: Multi-walled carbon nanotube
RMSE	: Kök ortalama karesel hata
RP	: Resilient backpropagation algoritması
YSA	: Yapay sinir ağları

5. SONUÇLAR (CONCLUSIONS)

Nanoakışkan kullanılan mühendislik sistemlerinin deneysel ve sayısal analizinde nanoakışkanların termofiziksel ve reolojik özelliklerinin yüksek doğrulukla belirlenmesi analiz sonuçlarının hassasiyetiyle doğrudan ilişkilidir. Nanoakışkanların önemli termofiziksel özelliklerinden biri özgül ısı olmasına rağmen literatürde gerek nanoakışkanların gerekse de hibrit nanoakışkanların özgül ısıları üzerine yapılan oldukça az sayıda çalışma bulunmaktadır. İlgili konuda literatürde bulunan çalışmaların bir kısmında veriler tablo ve grafikler şeklinde sunulmuş, bir kısmında korelasyonlar önerilmiş ve oldukça az sayıda çalışmada da çeşitli makina öğrenmesi yöntemleri ile elde edilen tahminleyicilere yer verilmiştir. Literatürdeki bu açığı kapatmaya katkı sağlamak amacıyla, literatürde rastlanmayan deiyonize su bazlı $\text{CuO} + \text{ÇDKNT}$, $\text{MgO} + \text{ÇDKNT}$ ve $\text{SnO}_2 + \text{ÇDKNT}$ hibrit nanoakışkanların özgül ısılarının tahmin edilmesinde klasik korelasyonlara alternatif olabilecek bir YSA tabanlı tahminleyici ortaya konmuştur. Çalışmada, Tiwari vd. [26] tarafından yayımlanan makaleden elde edilen 432 deneysel veri kullanılmıştır.

Verilerin %70'i ağı eğitimde, %15'i doğrulamada kullanılmış, geriye kalan %15'i de test verisi olarak ayrılmıştır. Aşırı öğrenmeye karşı 8-katlı çapraz doğrulama yapılarak önlem alınmıştır. ÇKA'dan azami performans elde etmek için farklı eğitim algoritmalarının performansı karşılaştırılmış ve hiper parametreleri Bayes optimizasyonu kullanılarak optimize edilmiştir. Optimizasyon sonucunda, LM eğitim algoritmasının gizli katman sayısının 1, nöron sayısının 24, epoch sayısının 498, öğrenme oranının 0,15542 ve transfer fonksiyonunun *logsig* olduğu hiper parametre kombinasyonu ile en iyi sonuç verdiği belirlenmiştir. Eğitim, doğrulama, test verileri ve tüm veriler için optimize edilen ağ yapısının açıklayıcılık katsayısı R^2 'nin sırasıyla 0,998415, 0,995497, 0,995023 ve 0,997504 olduğu bulunmuştur. Dolayısıyla çalışmada elde edilen YSA tabanlı tahminleyicinin ele alınan deiyonize su bazlı $CuO + \text{ÇDKNT}$, $MgO + \text{ÇDKNT}$ ve $SnO_2 + \text{ÇDKNT}$ hibrit nanoakışkanların özgül ısılarının yüksek doğruluk payı ile tahmin edilmesinde kullanılabileceği sonucuna varılmıştır. Bu çalışmada elde edilen YSA tabanlı tahminleyicinin ele alınan hibrit nanoakışkanların özgül ısılarını tahmin etme performansının Tiwari vd. [26] tarafından önerilen korelasyonun tahminleme performansından daha iyi olduğu tespit edilmiştir. Ayrıca YSA tabanlı tahminleyicinin elde edilmesinde korelasyonun elde edilmesine kıyasla daha az veri kullanıldığı da belirtilmelidir. Dolayısıyla deneysel ve sayısal çalışmalarda ihtiyaç duyulan nanoakışkanların özgül ısılarının belirlenmesinde YSA tabanlı tahminleyici kullanılarak daha hassas ve gerçekçi hesaplamalar yapılabileceği sonucuna varılmıştır. Çeşitli nanoakışkanların birden fazla termodinamik ve reolojik özelliğini aynı ağ üzerinden tahmin edebilen YSA tabanlı tahminleyicilerin geliştirilmesi bu konuda çalışma yapmak isteyen araştırmacılara önerilebilecek konular arasında yer almaktadır.

KAYNAKLAR (REFERENCES)

1. Zyla G., Fall J., Estellé P., The influence of ash content on thermophysical properties of ethylene glycol based graphite/diamonds mixture nanofluids, *Diamond and Related Materials*, 74, 81-89, 2017.
2. Soheli Murshed S.M., Estellé P., A state of the art review on viscosity of nanofluids, *Renewable and Sustainable Energy Reviews*, 76, 1134-1152, 2017.
3. Choi S. U., Eastman J. A., Enhancing thermal conductivity of fluids with nanoparticles, 1995 International mechanical engineering congress and exhibition, San Francisco-CA (United States), 12-17 November 1995.
4. Minea A.A., Estellé P., Numerical study on CNT nanofluids behavior in laminar pipe flow, *Journal of Molecular Liquids*, 271, 281-289, 2018.
5. Nikulin A., Moit, A.S., Moreira, A.L.N., Murshed S.M.S., Humnic A., Grosu Y., ... & Khliyeva O., Effect of Al_2O_3 nanoparticles on laminar, transient and turbulent flow of isopropyl alcohol, *International Journal of Heat and Mass Transfer*, 130, 1032-1044, 2019.
6. Shahrul I.M., Mahbubul I.M., Khaleduzzaman S.S., Saidur R., Sabri M.F.M., A comparative review on the specific heat of nanofluids for energy perspective, *Renewable and Sustainable Energy Reviews*, 38, 88-98, 2014.
7. Hemmati-Sarapardeh A., Varamesh A., Husein M.M., Karan K., On the evaluation of the viscosity of nanofluid systems: Modeling and data assessment, *Renewable and Sustainable Energy Reviews*, 81 (1), 313-329, 2018.
8. Riazi H., Murphy T., Webber G.B., Atkin R., Tehrani S.S., Taylor R.A. Specific heat control of nanofluids: A critical review, *International Journal of Thermal Sciences*, 107, 25-38, 2016.
9. Alade I.O., Abd Rahman M.A., Saleh T.A., Predicting the specific heat capacity of alumina/ethylene glycol nanofluids using support vector regression model optimized with Bayesian algorithm, *Solar Energy*, 183, 74-82, 2019.
10. Çolak A.B., Yıldız O., Bayrak M., Tezekici B.S., Experimental study for predicting the specific heat of water based $Cu-Al_2O_3$ hybrid nanofluid using artificial neural network and proposing new correlation, *International Journal of Energy Research*, 44 (9), 7198-7215, 2020.
11. Moldoveanu G.M., Minea A.A., Specific heat experimental tests of simple and hybrid oxide-water nanofluids: proposing new correlation, *Journal of Molecular Liquids*, 279, 299-305, 2019.
12. Satti J.R., Das D.K., Ray D., Specific heat measurements of five different propylene glycol based nanofluids and development of a new correlation, *International Journal of Heat and Mass Transfer*, 94, 343-353, 2016.
13. Pak B.C., Cho Y.I., Hydrodynamic and heat transfer study of dispersed fluids with submicron metallic oxide particles, *Experimental Heat Transfer an International Journal*, 11 (2), 151-170, 1998.
14. Xuan Y., Roetzel W., Conceptions for heat transfer correlation of nanofluids, *International Journal of Heat and Mass Transfer*, 43 (19), 3701-3707, 2000.
15. Vajjha R.S., Das D.K., Specific heat measurement of three nanofluids and development of new correlations, *Journal of Heat Transfer*, 131 (7), 2009.
16. Shahrul I.M., Mahbubul I.M., Khaleduzzaman S.S., Saidur R., Sabri M.F., A comparative review on the specific heat of nanofluids for energy perspective, *Renewable and Sustainable Energy Reviews*, 38, 88-98, 2014.
17. Sabuncuoğlu B., Demirtaş O., Development of an artificial neural network using parametric correlation technique for the determination of machined torsional spring stiffness, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 36 (1), 105-118, 2020.
18. Molla B., Çağıl G., Uyaroğlu Y., Chaotic analysis of BIST 100 return time series and short-term predictability with ANFIS, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 36 (2), 577-592, 2021.
19. Sayılğan E., Yüce Y., İşler Y., Evaluation of wavelet features selected via statistical evidence from steady-state visually-evoked potentials predict to predict the

- stimulating frequency, Journal of The Faculty of Engineering and Architecture of Gazi University, 36 (2), 593-606, 2021.
20. Hassan M.A., Banerjee D., A soft computing approach for estimating the specific heat capacity of molten salt-based nanofluids, Journal of Molecular Liquids, 281, 365-375, 2019.
 21. Alade I.O., Abd Rahman M.A., Saleh T.A., Modeling and prediction of the specific heat capacity of Al₂O₃/water nanofluids using hybrid genetic algorithm/support vector regression model, Nano-Structures & Nano-Objects, 17, 103-111, 2019.
 22. Alade, I.O., Abd Rahman M.A., Bagudu A., Abbas Z., Yaakob Y., Saleh T.A., Development of a predictive model for estimating the specific heat capacity of metallic oxides/ethylene glycol-based nanofluids using support vector regression, Heliyon, 5 (6), 2019.
 23. Alade I.O., Abd Rahman M.A., Abbas Z., Yaakob Y., Saleh T.A., Application of support vector regression and artificial neural network for prediction of specific heat capacity of aqueous nanofluids of copper oxide, Solar Energy, 197, 485-490, 2020.
 24. Çolak A.B., An experimental study on the comparative analysis of the effect of the number of data on the error rates of artificial neural networks, International Journal of Energy Research, 45 (1), 478-500, 2021.
 25. Wciślik, S., A simple economic and heat transfer analysis of the nanoparticles use, Chemical Papers, 71, 2395–2401, 2017.
 26. Tiwari A.K., Pandya N.S., Shah H., Said Z., Experimental comparison of specific heat capacity of three different metal oxides with MWCNT/water-based hybrid nanofluids: proposing a new correlation, Applied Nanoscience, 1-11, 2020.
 27. Zendejboudi A., Saidur R., A reliable model to estimate the effective thermal conductivity of nanofluids, Heat and Mass Transfer, 55 (2), 397-411, 2019.
 28. Ramchoun H., Idrissi M.A., Ghanou Y., Ettaouil M., New modeling of multilayer perceptron architecture optimization with regularization: an application to pattern classification, IAENG International Journal of Computer Science, 44 (3), 261-269, 2017.
 29. Öztemel E., Yapay sinir ağları, Papatya Yayıncılık, İstanbul, Türkiye, 2003.
 30. Alpaydin E., Introduction to machine learning. MIT press, 2020.
 31. Bengio Y., Goodfellow I., Courville A., Deep learning, MIT press, Massachusetts, U.S.A, 2017.
 32. Wu J., Chen X.Y., Zhang H., Xiong L.D., Lei H., Deng S.H., Hyperparameter optimization for machine learning models based on Bayesian optimization, Journal of Electronic Science and Technology, 17 (1), 26-40, 2019.

