



Yapay zekâ destekli nanoakışkan modellemesi: Termal iletkenlik ve viskozite için stabiliteye bağlı korelasyon geliştirilmesi

Artificial intelligence-assisted nanofluid modeling: Developing stability-based correlation for thermal conductivity and viscosity

Fevzi Şahin^{1,*} 

¹ Ondokuz Mayıs Üniversitesi, Makine Mühendisliği Bölümü, 55139, Samsun, Türkiye

Öz

Nanoakışkan çalışmalarında sonuçların deneysel çalışmalara bağlı olması, son yıllarda yapay zeka tabanlı modelleme çalışmaları ile aşılmaya çalışılmaktadır. Yapılan modelleme çalışmalarında nanoakışkanların temel termal özellikleri olan ısı iletkenlik ve viskozite üzerine yoğunlaşmış ve nanoakışkanlar için gerekli olan en önemli özelliklerden olan stabilitenin çoğu zaman ihmal edildiği görülmektedir. Bu çalışmada TiO₂ nanoakışkanı için deneysel olarak ortaya konmuş veriler kullanılarak ısı iletkenlik ve viskozite değerleri YSA ile modellenmiştir. YSA modelinin performans ölçütleri olan MSE, R değerleri sırasıyla 4,2484E-06 ve 0,99982'dir. Ağ sonuçlarında sıcaklık, kütle oran ve stabiliteyi doğrudan etkileyen pH değerine bağlı olarak bir model geliştirilmiştir. Model sonuçları kullanılarak ısı iletkenlik ve viskozite özellikleri için sıcaklık, kütle oran ve pH değişkenlerine bağlı olarak korelasyonlar geliştirilmiştir. Ortaya konulan korelasyonların ısı iletkenlik için deneysel değerlerden sapma oranları \pm % 3,5 aralığında iken viskozite için bu oran \pm % 9 aralığında elde edilmiştir.

Anahtar kelimeler: Nanoakışkan, Isıl iletkenlik, Viskozite, Stabilite, Yapay sinir ağları

1 Giriş

Enerji tüketimi günümüzde hızla artmaktadır ve bu durum, sınırlı kaynakların daha verimli bir şekilde kullanılmasını gerekli kılmaktadır. Teknolojik ilerlemelerin yaşandığı bu dönemde, enerji sistemlerinde önemli gelişmeler gözlemlenmektedir. Bu gelişmeler arasında dikkat çeken konulardan biri de nanoakışkanlar olarak adlandırılan yeni nesil ısı transfer akışkanlarıdır. Nanoakışkanlar, metal, metal oksit ve karbon tabanlı tozların nano boyutlarda üretilerek, geleneksel ısı transfer akışkanlarına eklenmesiyle elde edilmektedir. Nanoakışkanların genel kabul gören tanımına göre, kullanılacak nanopartikül boyutlarının yaklaşık olarak 100 nm'den küçük olması beklenmektedir [1].

Nanoakışkanlar ile yapılan çalışmalarda ısı transferindeki artışları raporlayan birçok çalışma literatürde bulunmaktadır [2-5].

Isı transferinde elde edilen bu iyileştirmeler birçok parametreye bağlıdır. Literatürdeki çalışılan en önemli

Abstract

In recent years, artificial intelligence-based modeling studies have been attempted to overcome the reliance on experimental results in nanofluid research. These modeling studies have mainly focused on the fundamental thermal properties of nanofluids, namely thermal conductivity and viscosity, while stability, which is one of the most important properties for nanofluids, has often been neglected. In this study, experimental data for TiO₂ nanofluid has been utilized to model thermal conductivity and viscosity values using Artificial Neural Networks (ANNs). The performance metrics of the ANN model, MSE (Mean Squared Error), and R (Correlation Coefficient), are 4,2484E-06 and 0,99982, respectively. Using the model results, correlations have been established temperature, mass ratio, and pH variables for the thermal conductivity and viscosity properties of nanofluids. The deviation rates of the proposed correlations from the experimental values are within the range of \pm 3,5% for thermal conductivity and \pm 9% for viscosity.

Keywords: Nanofluid, Thermal conductivity, Viscosity, Stability, Artificial neural networks

parametreler nanopartiküllerin temel akışkan içerisindeki hacimsel oranı, nanopartikül malzemesi, nanopartikül şekli, nanopartikül boyutu, temel akışkanın türü, sıcaklık ve stabilitesidir [6]. Nanoakışkanların ısı özelliklerinin birçok parametreye bağlı olması konuyu karmaşık hale getirmektedir [7].

Isı transfer çalışmalarında ısı transfer performansı analiz edilirken dikkate alınan temel parametreler termal iletkenlik ve viskozitedir. Nanoakışkanların ısı iletkenliğindeki artış aynı zamanda viskozite değerinde bir artışa neden olmaktadır. Isı transfer prosesinde artan viskozite, pompalama güç ihtiyacını artırmaktadır. Nanoakışkanların artan ısı iletkenliğinin yanında viskozite değişimini incelemek, nanoakışkanların alternatif bir ısı transfer akışkanı olarak kullanılabilmesi kritik öneme sahiptir. Diğer taraftan deneysel olarak incelenen nanoakışkanların içerisindeki nanopartiküllerin zamanla çökmesi, nanoakışkanların kullanılabilirliğini kısıtlamaktadır. Literatürde nanoakışkanların termal özelliklerini

* Sorumlu yazar / Corresponding author, e-posta / e-mail: fevzi.sahin@omu.edu.tr (F. Şahin)

Geliş / Received: 20.03.2024 Kabul / Accepted: 23.05.2024 Yayımlanma / Published: 15.07.2024

doi: 10.28948/ngumuh.1455986

iyileştirmeye yönelik çalışmaların çoğunda stabilitenin ihmal edildiği görülmektedir [7]. Bu çalışmalarda ısı transfer özelliklerinde iyileştirmeler elde edilmesine rağmen stabilite ölçülemediğinden elde edilen iyileştirmelerin sınırlı süreler için geçerli olduğu düşünülmektedir. Bu nedenle nanoakışkanların termal özelliklerinin iyileştirilmesine yönelik çalışmaların stabilite çalışmaları ile birlikte ele alınması gerekmektedir [8].

Nanoakışkanların termofiziksel özelliklerinin nasıl değiştiğinin anlaşılması için geliştirilen birçok matematiksel model araştırmacılar tarafından sunulmuştur. Bu modellerin birçoğu ısı iletim katsayısı, viskozite, özgül ısı değerlerinin değişen nanopartikül oranları ile değişimlerini açıklamaktadır [9]. Nanoakışkanların özelliklerini etkileyen diğer parametreler çoğu zaman ihmal edilmiştir. Bunun sonucu olarak tutarlı modellerin oluşturulması karmaşık ve zordur. Nanoakışkanların ısı iletim katsayısı ve viskozitesinin deneysel olarak belirlenmesi, karmaşık ve zaman alıcı bir süreçtir. Bu zorluklar, nanoakışkanların homojenliğinin sağlanması, stabilitesinin korunması ve hassas ölçüm cihazlarının gerekliliği gibi faktörlerden kaynaklanmaktadır. Ayrıca, deneysel çalışmalar genellikle maliyetli olup, geniş bir parametre aralığını kapsamak zor olabilir. Bu nedenle, yapay zeka tabanlı modelleme çalışmalarının önemi artmaktadır. Yapay sinir ağları (YSA) gibi modeller, deneysel verileri kullanarak hızlı ve doğru tahminler yapabilmekte ve böylece deneysel yöntemlerin sınırlamalarını aşmaya yardımcı olmaktadır [2].

Araştırmacılar, nanoakışkanlar gibi deneysel çalışmalara önemli ölçüde bağlı bir mühendislik konusu için sistem teorik modelleme yöntemlerine yönelmiştir. Günümüzde en sık kullanılan yöntemlerden biri yapay sinir ağları yöntemidir. Yapay sinir ağları, diğer yöntemlere göre daha üstün bir alternatif sunar çünkü verileri hızlı ve doğru bir şekilde işleyebilir, çoklu değişken analizi yapabilir ve adaptif öğrenme yetenekleriyle yeni koşullara uyum sağlayabilir. YSA, birçok farklı model ve öğrenme algoritmasına sahip olması sayesinde, farklı sistemlere uygulanabilir olmasını sağlamaktadır. YSA, deneysel parametrelerin fiziksel süreçleri içine alan girdi ve çıktı değişkenleri arasındaki ilişkiyi, altta yatan fiziksel süreci dikkate almadan öğrenmeye çalışan bir modelleme yöntemidir [6]. Nanoakışkanların YSA ile modellenebilirliğini gösteren birçok çalışma bulunmaktadır [10-16].

Hemmat Esfe ve Saedodin [17] ZnO-etilen glikol nanoakışkanları üzerinde sıcaklığın ve nanopartikül oranının dinamik viskozitesi üzerindeki etkisini araştırmak için deneysel bir araştırma yürüttüler. Nanopartiküllerin hacimsel oranın artmasıyla yükselen viskozite sıcaklığın artmasıyla beklenildiği gibi düşmektedir. Deneysel verilere dayanarak viskozite için korelasyon geliştirmişlerdir. Önerilen modeller ve deneylerin sonuçları uyum içindedir. Murshed ve diğerleri [18], TiO₂/Diyonize su nanoakışkanlarını % 0.5-5 aralığında hacimsel oranlarda sentezlemişlerdir. Nanoakışkanların ısı iletim katsayılarının hacimsel orana bağlı değişimini incelemişlerdir. Sonuçlar hacimsel oran ile ısı iletim katsayısı arasında lineer bir ilişki olduğunu ortaya koymuşlardır. Hojjat ve diğerleri [19]

tarafından Al₂O₃, TiO₂ ve CuO nanopartikülleri ile su tabanlı nanoakışkanlar sentezlenmiş ve ısı iletim katsayılarını modellemek için YSA yöntemi kullanmışlardır. Isı iletim katsayısını nanopartikül oranı ve nanoakışkan sıcaklığın bir fonksiyonu olarak modellenmiştir. Deneysel veriler ile öngörülen veriler arasındaki ortalama ve maksimum hatalar sırasıyla % 1,6 ve % 5,8 olarak elde edilmiştir. Başka bir çalışmada, YSA modellemesi kullanılarak, nanoparçacık tipinin ve konsantrasyonun (EG)-su bazlı sıvının termal iletkenliği üzerindeki etkisi Yashawantha ve Vinod tarafından incelenmiştir [20].

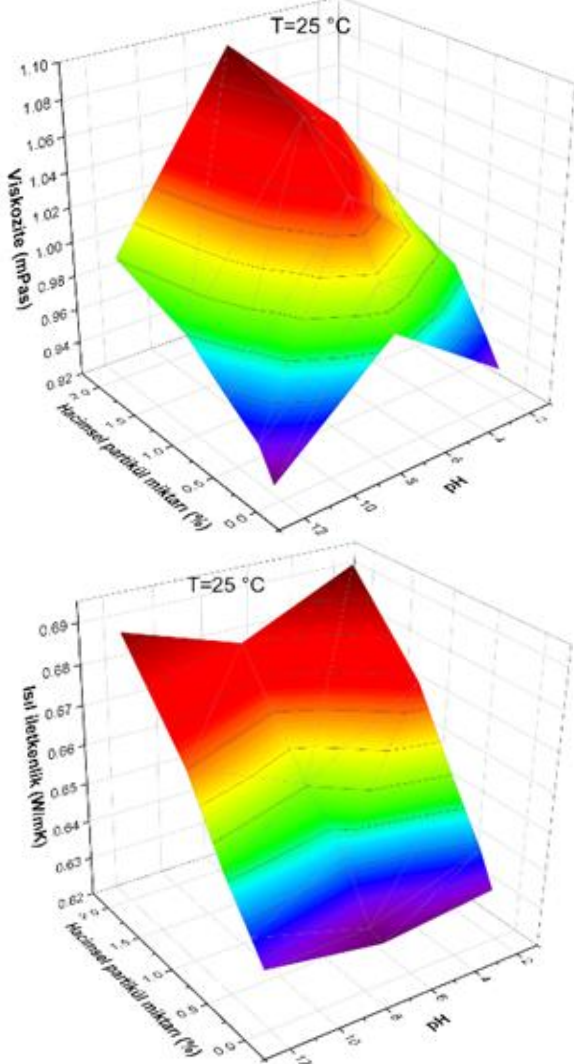
He ve diğerleri [21] yaptığı bir çalışmada, su bazlı ZnO - Ag nanoakışkanların ısı iletkenliğini tahmin etmek için bir YSA geliştirdi. Elde edilen maksimum mutlak hata değerinin 1.6684E-05 ve R²'nin 0.0095 olarak elde edilmiştir. Ahmadloo ve Azizi [22] YSA kullanarak MnFe₂O₄ nanoakışkanın termal iletkenliğini ve viskozitesini modellemişlerdir. YSA'nın nanoakışkanların özelliklerini tahmin etmek için çok iyi bir araç olduğunu göstermişlerdir. Kamalesh ve diğerleri [23] TiO₂ içeren nanoakışkanların termal iletkenliğini Su, Etilen Glikol ve Motor Yağı nanoakışkanları gibi farklı baz sıvılar için tahmin etmiştir. YSA verilerinin deneysel sonuçlarla iyi bir uyum içinde olduğunu gözlemlemişlerdir. Tahani ve diğerleri [24] grafen oksit nanoplatelet/deiyonize su nanoakışkanın termal iletkenlik değerlerinin ölçümlerini kullanarak geliştirdikleri YSA'dan sıcaklık ve konsantrasyona göre değişen simülasyon verileri elde ettiler. % 0,001, % 0,005, % 0,015 ve % 0,045 konsantrasyonlarında düzenlenen nanoakışkanın ısı iletkenliği 25°C ile 50°C arasındaki sıcaklıklarda ölçülmüştür. YSA'nın tahmin performansını değerlendirmek amacıyla MSE, MAPE ve R² değerleri analiz edilmiştir. Sonuçlar, YSA tarafından amaçlanan modelin, grafen oksit nanoplateletlerin/deiyonize su nanoakışkanının termal iletkenliğini doğru bir şekilde tahmin edebildiğini göstermiştir. Çolak [25], beş farklı hacimsel konsantrasyonda Y₂O₃ nanopartikülleri ile üretilen itriyum oksit-su nanoakışkanının özgül ısılarını deneysel olarak test etmek için Diferansiyel Termal Analiz tekniğini kullanılmıştır. Deneylerden elde edilen veriler, 15 nöronlu, çok katmanlı bir algılayıcı, ileri beslemeli, geri yayımlı yapay sinir ağı modeli kurmuştur. Toplamda 60 deneysel veri kullanılmıştır; 42'si eğitim için, 12'si doğrulama için ve 6'sı test için kullanıldı. YO-HF'nin özgül ısı değerlerini belirlemek için yeni bir matematiksel korelasyon da geliştirilmiştir. Nanoakışkanların özgül ısı değerleri bir YSA tarafından çok düşük bir ortalama yanlışlıkla tahmin edilmiştir.

Nanoakışkanların termal özelliklerinin Yapay Sinir Ağları (YSA) ile modellenmesine dair yapılan çalışmalarda, ısı iletkenlik, viskozite ve özgül ısı gibi temel özellikler üzerine odaklanılmaktadır. Ancak, genellikle modelleme çalışmalarında nanoakışkanların stabilitesi, kritik bir öneme sahip olmasına rağmen ihmal edilmektedir. Bu çalışma, nanoakışkanların viskozite ve ısı iletkenliğini, stabilite durumlarını da dikkate alarak Yapay Sinir Ağları ile başarılı bir şekilde modellemiştir. MSE (Ortalama Kare Hata) ve R² değerleri üzerinden yapılan değerlendirmelerle çok katmanlı bir yapay sinir ağı kullanılarak en uygun nöron sayısı

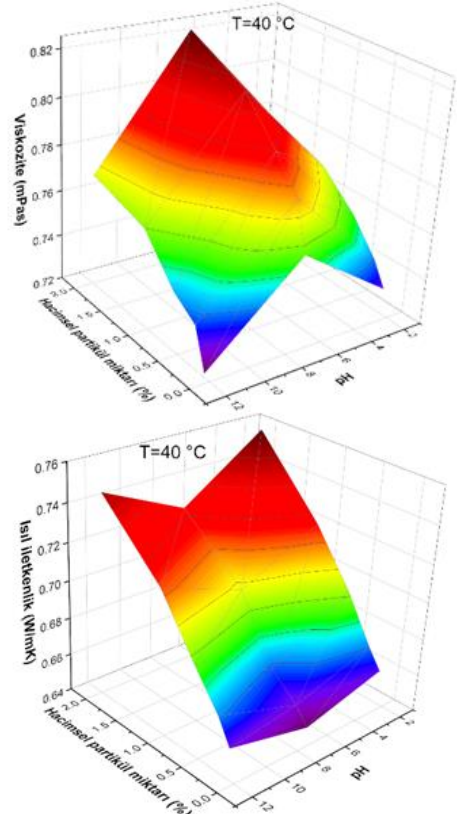
belirlenmiştir. Nanoakışkanların viskozite ve ısı iletkenlik değerleri sıcaklığa bağlı olarak değişimlerini ifade eden korelasyonlar önerilmiştir. Nanoakışkan stabilitesi dikkate alınarak elde edilen yüksek uyumlulukta korelasyonlar nanoakışkanların viskozite ve ısı iletkenliği için daha geçerli sonuçlar sunmaktadır. Çalışmanın temel amacı ve motivasyonu literatürdeki bu boşluğu kapatmayı amaçlamaktadır.

2 Verilerin toplanması

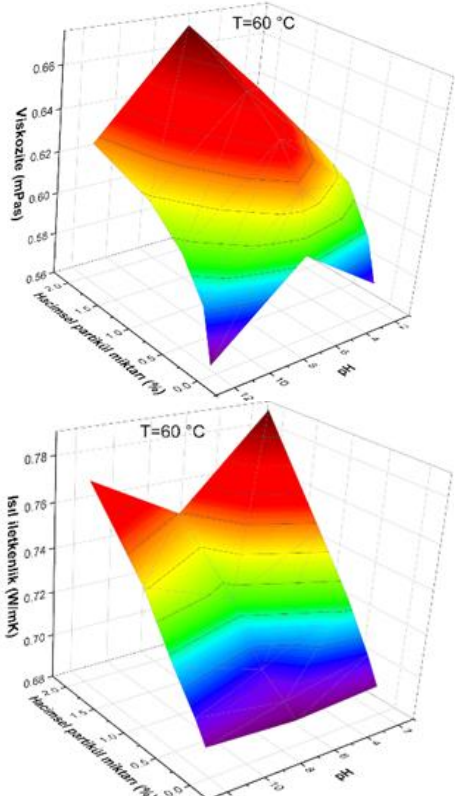
Bu çalışmada kullanılan veriler Zhang ve diğerlerinin yapmış olduğu deneysel çalışmadan alınmıştır [26]. Bu veriler TiO₂/su nanoakışkanlarının hacimsel partikül oranı, pH ve sıcaklık değişimlerine karşı ısı iletkenlik ve viskozite değişimleri içermektedir. Hacimsel partikül oranı için 5 farklı oran (% 0,08, % 0,25, % 0,6, % 1,1 ve %2) kullanılırken, sıcaklık (25°C, 40°C, 60°C) ve pH (2, 7, 12) için 3'er farklı değer kullanılmıştır. Sıcaklık değerleri dikkate alınarak (25°C, 40°C ve 60°C) için hacimsel partikül oranlar ve pH değerleri için ısı iletkenlik ve viskozite değişimleri Şekil 1, 2 ve 3'te verilmiştir.



Şekil 1. 25°C'de viskozite ve ısı iletkenlik değerlerinin pH ve hacimsel partikül miktarıyla değişimi



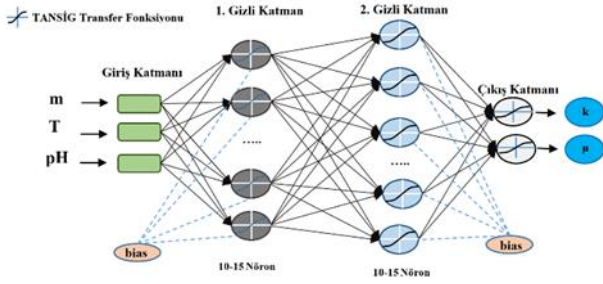
Şekil 2. 40°C'de viskozite ve ısı iletkenlik değerlerinin pH ve hacimsel partikül miktarıyla değişimi



Şekil 3. 60°C'de viskozite ve ısı iletkenlik değerlerinin pH ve hacimsel partikül miktarıyla değişimi

3 Yapay sinir ağı modeli

Nanoakışkan stabilite ölçüm yöntemlerinden biri olan zeta potansiyel ölçümleri su tabanlı nanoakışkanlar için kullanılmaktadır. Zeta potansiyeli, akışkanın pH değeri değiştirilerek en uygun stabilite değeri için belirlenmektedir. Bu çalışmada TiO₂/su nanoakışkanlarının temel termal özelliklerinden olan viskozite ve ısı iletkenlik değerleri hacimsel partikül oranı, sıcaklık ve pH değerine bağlı olarak yapay sinir ağlarıyla modellenmiştir. Bu termal özellikleri doğrudan etkileyen hacimsel partikül oranı ve sıcaklığın yanında stabilite değerini doğrudan etkileyen pH değeri YSA ağ yapısına dahil edilmiştir. Geliştirilen YSA modelinde ileri beslemeli (feed forward, FF) geri yayımlı (back propagation, BP) çok katmanlı algılayıcı (multi-layer perceptron, MLP) modeli kullanılmaktadır. MLP ağ modelleri güçlü tahmin yeteneğine sahip, bir giriş katmanı en az bir gizli katman ve bir çıkış katmanından oluşan ağ modelleridir. Kurulan ağ modelinde giriş katmanında hacimsel partikül oranı, sıcaklık, pH değerleri kullanılırken çıkış katmanında viskozite ve ısı iletkenlik değerleri kullanılmıştır. Gizli katmanda hesaplama elemanları olan nöronlar kullanılır. Gizli katmandaki nöron sayılarının hesaplanmasında belirgin bir yöntem bulunmamaktadır. Uygun nöron sayıları deneme yanılma yöntemi kullanılarak belirlenmektedir. Geliştirilen ağ modellerinin performans sonuçları dikkate alınarak en uygun nöron sayıları belirlenmiştir. Ağ yapısında iki gizli katman kullanılırken, gizli katmanlarda 10-15 aralığındaki tüm nöron kombinasyonları denenmiştir. Ağ yapısı Şekil 4'te verilmiştir.



Şekil 4. MLP ağ mimarisi yapısı

Ağın eğitiminden kullanılan verilerin optimizasyonu ve ağ performansını artırmak için verilerin % 70'i eğitim, % 15'i test ve % 15'i doğrulama verisi olarak bölünmüştür. TrainLM, eğitim fonksiyon türü olarak seçildi. Literatürde modelleme başarısı ve genelleme yeteneğinin yüksek olması nedeniyle Levenberg Marguardt algoritması tercih edilmiştir [4]. Adaptasyon öğrenme fonksiyonu türü olarak LearnGDM tercih edildi. Gizli katman ve çıkış katmanda TanSig transfer fonksiyonu kullanılmıştır. Fonksiyon Denklem 1'de verilmiştir. Yapay sinir ağ modelinin tahmin performansını analiz etmek için ortalama karesel hata (MSE), regresyon (R) ve yüzde sapma oranı (MoD) parametreleri seçilmiştir. Performans parametrelerinin hesaplanmasında kullanılan matematiksel formüller aşağıda Denklem 2, 3 ve 4'te verilmiştir.

$$f(x) = \frac{1}{1 + \exp(-2x)} - 1 \quad (1)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_{\text{exp}(i)} - X_{\text{ANN}(i)})^2 \quad (2)$$

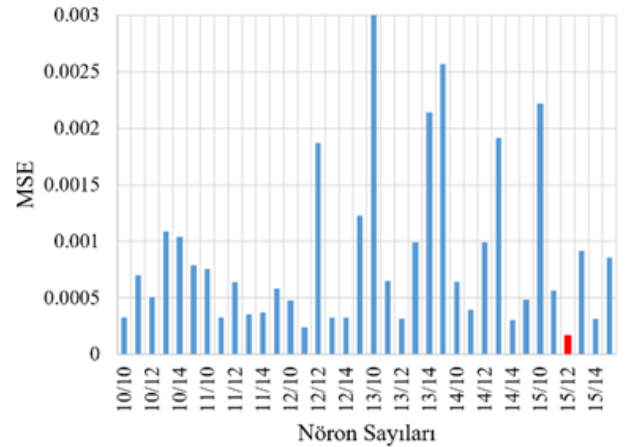
$$R = \sqrt{1 - \frac{\sum_{i=1}^N (X_{\text{exp}(i)} - X_{\text{ANN}(i)})^2}{\sum_{i=1}^N (X_{\text{exp}(i)})^2}} \quad (3)$$

$$\text{MoD} (\%) = \left[\frac{X_{\text{exp}} - X_{\text{ANN}}}{X_{\text{exp}}} \right] \times 100 \quad (4)$$

4 Bulgular ve tartışma

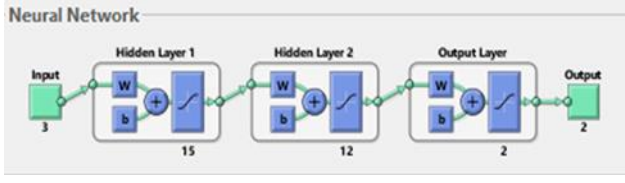
Nanoakışkanlar konusunda yapılan araştırmalar, genellikle ısı iletim katsayısını artırmak üzerine odaklanmaktadır. Isı iletim katsayısını artırmak için kullanılan en pratik yöntem partikül miktarının akışkan içerisinde artırmaktır. Bu durumda akışkanın ısı iletim katsayısı artarken aynı zamanda viskozitesinin artması kaçınılmazdır. Diğer yandan artan partikül oranı nanoakışkanlardan beklenen bir diğer önemli özellik olan stabilitenin olumsuz etkilenmesine yol açmaktadır. Bu çalışmada deneysel olarak elde edilen deneysel veriler kullanılarak [26], nanoakışkanların ısı iletkenlik ve viskozite değerleri yapay sinir ağları yoluyla modellenmiştir. Bu çalışmada yapılan modellemeye partikül miktarı ve sıcaklığın yanında stabiliteyi doğrudan etkileyen pH değeri dahil edilmiştir.

YSA modellemesi yapılırken gizli katmandaki nöron sayıları ağın geliştirilmesinde önemli bir aşamadır. Bu çalışmada iki gizli katmanda 10-15 aralığındaki tüm nöron kombinasyonları denenmiştir. Nöron sayılarına MSE değeri dikkate alınarak karar verilmiştir. Şekil 5'te nöron kombinasyonları ve MSE değerleri verilmiştir. En düşük MSE değerine sahip birinci katman için 15 ve ikinci gizli katman için 12 nöron sayısı seçilmiştir. Şekil 5'te uygun nöron kombinasyonu kırmızı renkli sütun ile gösterilmiştir.



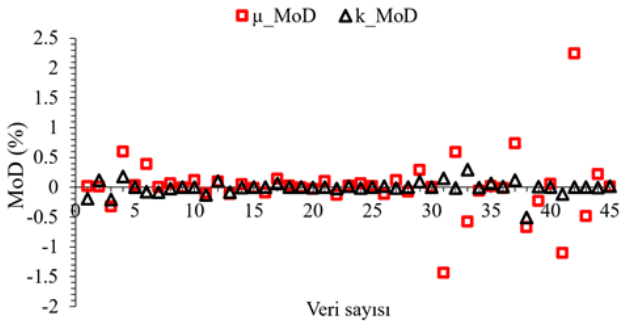
Şekil 5. Gizli katmanlardaki en iyi nöron kombinasyonu

Nöron sayılarının belirlenmesiyle oluşan ağı yapısı Şekil 6'da verilmiştir.



Şekil 6. Ağ yapısı

YSA modellemesinde önemli bir performans parametresi olan R^2 değeri 0,99982 olarak elde edilmiştir. Modelleme sonucunda elde edilen MSE değeri $4,2484E-06$ 'dır. R değerinin 1'e çok yakın olması ve MSE değerinin oldukça küçük bir değer olması ağı başarısını göstermektedir. R ve MSE değerlerinin yanında, ağı çıktılarını ne ölçüde tahmin ettiği, ağı bir diğer performans kriteridir. Ağı tahmin sonuçlarını doğrudan değerlendirme imkânı veren MoD değeri, gerçek değerlerle ağı tahmin sonuçlarının yüzde hatalarını vermektedir. Şekil 7'de ısı iletkenlik ve viskozite değerlerine ait MoD değeri verilmiştir.



Şekil 7. Viskozite ve ısı iletkenlik için ağı tahmin sonuçları sonucu elde edilen MoD grafiği

MoD grafiğinde viskozite ve ısı iletkenlik için sırasıyla % 2,25 ve % 0,51 hata oranları elde edilmiştir. Hata oranlarının kabul edilebilir ölçüde küçük olması ağı mevcut fiziksel koşulları modelleme başarısını göstermektedir.

Başarılı bir ağı elde edildikten sonra, gerçek girdi verileri maksimum ve minimum değerleri arasında 792 yeni tahmin verisi oluşturulmuştur. Hacimsel partikül oranı için 9, sıcaklık için 8 ve pH için 11 farklı veri seti eğitilen ağıdan tahmin sonuçları istenmiştir. Bu işlem modellenmek istenen sistemin ara değerlerinin sayısını artırarak çıktı verilerinin eğilimini daha yakından inceleme imkânı vermektedir. Ayrıca ortaya konulan YSA modeli karmaşık denklemlerden ve birçok ağırlık değerinin bu denklemlerde kullanılmasını gerektiren matematiksel bir ifade olarak karşımıza çıkmaktadır. YSA ile başarılı bir model oluşturulmasına rağmen, farklı araştırmacılar tarafından bu modelin kullanılabilirliği düşüktür. Veri setinin artırılmasıyla oluşan veriler sayesinde daha yakınsak matematiksel korelasyonlar türetme imkânı doğmaktadır. Bu çalışmada değişken olarak kullanılan hacimsel partikül oranı, pH ve sıcaklık değerlerine bağlı olarak viskozite ve ısı iletkenlik değerlerini veren matematiksel korelasyonlar elde edilmiştir. ısı iletkenlik ve

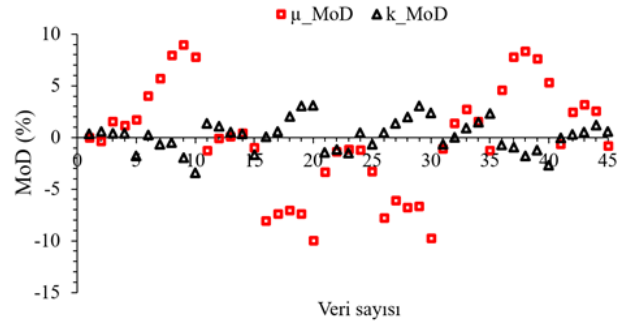
viskozite için geliştirilen denklemler sırasıyla Denklem 5 ve 6'da verilirken, denklemlere ait katsayılar Tablo 1'de düzenlenmiştir. Denklemlerde R^2 değerleri sırasıyla 0,9311 ve 0,9331 olarak elde edilmiştir. Denklemlerin deneysel değerlerden sapma oranları Denklem 4'ten hesaplanarak Şekil 8'de verilmiştir. Denklemlerdeki değişkenlerin sınır değerleri: kütle oran % $0,08 \leq \phi \leq 2$, pH değeri $2 \leq \phi \leq 12$ ve sıcaklık $25^\circ\text{C} \leq T \leq 60^\circ\text{C}$ aralığındadır.

$$k = A_0 + A_1 * \phi + A_2 * (pH) + A_3 * T \quad (5)$$

$$\mu = B_0 + B_1 * \phi + B_2 * (pH) + B_3 * T \quad (6)$$

Tablo 1. Isıl iletkenlik ve viskozite denklemlerine ait katsayılar

A_0	A_1	A_2	A_3
0.5801	0.0392	-4.56E-4	0.0019
B_0	B_1	B_2	B_3
1.2152	0.0345	-0.0013	-0.0106



Şekil 8. Türetilen ısı iletkenlik ve viskozite denklemlerinin deneysel değerlerden sapma oranları

Şekil 8 incelendiğinde ısı iletkenlik için deneysel değerlerden sapma oranları \pm % 3,5 aralığında iken viskozite için bu oran \pm % 9 aralığındadır. Her ne kadar hata oranları görece büyük olarak elde edilmesine rağmen, nanoakışkanlar gibi birçok parametreye bağlı karmaşık bir sistemin termal özelliklerinin kütle oran, pH ve sıcaklık gibi temel parametrelere bağlı olarak elde edilmesi değerlidir. Temel akışkanı su olan nanoakışkanlar için stabiliteyi doğrudan etkileyen pH değerini dikkate alarak, TiO_2 nanoakışkanları için daha önce ısı iletkenlik ve viskozite için ortaya konulmuş bir denkleme literatürde rastlanmamıştır.

YSA, sıcaklık, kütle oran ve pH gibi değişkenleri dikkate alarak kompleks analizler yapabildiği ortaya konmuştur. Gelecek çalışmalarda, ortaya konulan bu yaklaşım farklı nanoakışkanlar ve uygulamalar için de kullanılabilir, sürekli öğrenme ve optimizasyon yetenekleriyle endüstriyel süreçlerde enerji verimliliği ve maliyet avantajları sağlayabilir.

5 Sonuçlar

Nanoakışkanlar gibi deneysel sonuçlara son derece bağlı olan karmaşık bir sistemdir. Son yıllarda nanoakışkanların termal özelliklerini modellemek için biyolojik sınır ağlarından esinlenerek geliştirilen yapay zeka modelleri sıkça kullanılmaya başlanmıştır. YSA yöntemi, karmaşık işlevleri öğrenmek ve genelleştirmek için kullanılmaktadır.

Nanoakışkanların temel termal özelliklerinden olan ısı iletkenliği ve viskoziteyi sıcaklığa ve kütle oranına bağlı olarak ortaya birçok model konulmuştur. Bu çalışmada nanoakışkanların yaygın kullanımını ve termal özelliklerin zamanla geçerliliğini ortaya koyan stabilite etkisi öne çıkartılmıştır. Nanoakışkanların ısı iletkenlik ve viskozite değerleri sıcaklık ve kütle oranının yanında nanoakışkan stabilitesini doğrudan etkileyen pH değerini de içeren bir korelasyon geliştirilmiştir. Literatürde stabilite gibi önemli bir parametrenin nanoakışkanların termal özellikleri üzerindeki etkileri konusundaki önemli bir boşluğa bu çalışma ile katkıda bulunulmuştur. Bu çalışma sonuçları şu şekilde sıralanabilir;

- YSA ile nanoakışkan özelliklerini modellemek için çok katmanlı bir yapı kurulmuştur. YSA modeli için iki gizli katmanda 10-15 aralığındaki tüm nöron kombinasyonları denenmiştir. En düşük MSE değerine sahip birinci katman için 15 ve ikinci gizli katman için 12 nöron sayısı seçilmiştir.
- Ağın performansı için MSE, R^2 ve MoD parametreleri kullanılmıştır. R^2 değeri 0,99982 ve MSE değeri 4,2484E-06 olarak elde edilmiştir.
- MoD değerleri viskozite ve ısı iletkenlik için sırasıyla % 2,25 ve % 0.51 hata oranları elde edilmiştir.
- TiO_2 nanoakışkan kütle oran $0,08 \leq \phi \leq 0,2$, pH değeri $2 \leq \phi \leq 12$ ve sıcaklık $25^\circ C \leq T \leq 60^\circ C$ aralıkları için ısı iletkenlik ve viskozite için bir korelasyon elde edilmiştir.
- Ortaya konulan korelasyonların ısı iletkenlik için deneysel değerlerden sapma oranları $\pm \% 3,5$ aralığında iken viskozite için bu oran $\pm \% 9$ aralığın elde edilmiştir.

Çıkar çatışması

Yazar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %6

Kaynaklar

- [1] S. Özerinç, S. Kakaç and A.G. Yazıcıoğlu, Enhanced thermal conductivity of nanofluids: A state-of-the-art review, *Microfluidics and Nanofluidics*, 8, 145–170, 2010. <https://doi.org/10.1007/s10404-009-0524-4>
- [2] F. Sahin and O. Genc, Experimentally determining the thermal properties of NiFe₂O₄ magnetic nanofluid under suitable stability conditions: Proposal the new correlation for thermophysical properties, *Powder Technology*, 427, 118706, 2023. <https://doi.org/10.1016/j.powtec.2023.118706>.
- [3] W. Ajeeb, R.R.S. Thieleke da Silva and S.M.S. Murshed, Experimental investigation of heat transfer performance of Al₂O₃ nanofluids in a compact plate heat exchanger, *Applied Thermal Engineering*, 218, 119321, 2023. <https://doi.org/10.1016/J.APPLTHERMALENG.2022.119321>.
- [4] F. Sahin, O. Genc, M. Gökçek and A.B. Çolak, From experimental data to predictions: Artificial intelligence supported new mathematical approaches for estimating thermal conductivity, viscosity and zeta potential in Fe₃O₄-water magnetic nanofluids, *Powder Technology*, 430, 118974, 2023. <https://doi.org/10.1016/J.POWTEC.2023.118974>.
- [5] L. Li, Y. Zhai, Y. Jin, J. Wang, H. Wang and M. Ma, Stability, thermal performance and artificial neural network modeling of viscosity and thermal conductivity of Al₂O₃-ethylene glycol nanofluids, *Powder Technology*, 363, 360–368, 2020. <https://doi.org/10.1016/j.powtec.2020.01.006>.
- [6] F. Sahin, M. Kapusuz, L. Namli and H. Ozcan, Determination of the Optimum Stability Conditions in Al₂O₃ Nanofluids with Artificial Neural Networks, *International Journal of Thermophysics*, 41, 1–20, 2020. <https://doi.org/10.1007/s10765-020-02625-8>.
- [7] F. Sahin and L. Namli, Nanoakışkanlarda Kararlılığın Isı Transferini İyileştirme Açısından Önemi, *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 7, 880–898, 2018. <https://doi.org/10.28948/ngumuh.445339>.
- [8] F. Sahin, M. Kapusuz, L. Namli and H. Ozcan, Determination of the Optimum Stability Conditions in Al₂O₃ Nanofluids with Artificial Neural Networks, *International Journal of Thermophysics*, 41, 1–20, 2020. <https://doi.org/10.1007/s10765-020-02625-8>.
- [9] X. Zhang and J. Li, A review of uncertainties in the study of heat transfer properties of nanofluids, *Heat and Mass Transfer*, 59(4), 621–653, 2022. <https://doi.org/10.1007/S00231-022-03276-1>.
- [10] M. Hassanpour, B. Vaferi and M.E. Masoumi, Estimation of pool boiling heat transfer coefficient of alumina water-based nanofluids by various artificial intelligence (AI) approaches, *Applied Thermal Engineering*, 128, 1208–1222, 2018. <https://doi.org/10.1016/j.applthermaleng.2017.09.066>.
- [11] G.A. Longo, C. Zilio, L. Ortombina and M. Zigliotto, Application of Artificial Neural Network (ANN) for modeling oxide-based nanofluids dynamic viscosity, *International Communications in Heat and Mass Transfer*, 83, 8–14, 2017. <https://doi.org/10.1016/j.icheatmasstransfer.2017.03.003>.
- [12] A. Alirezaie, S. Saedodin, M.H. Esfe and S.H. Rostamian, Investigation of rheological behavior of MWCNT (COOH-functionalized)/MgO - Engine oil hybrid nanofluids and modelling the results with artificial neural networks, *Journal of Molecular Liquids*, 241, 173–181, 2017. <https://doi.org/10.1016/j.molliq.2017.05.121>.
- [13] M. Hemmat Esfe, Designing a neural network for predicting the heat transfer and pressure drop characteristics of Ag/water nanofluids in a heat exchanger, *Applied Thermal Engineering*, 126, 559–565, 2017. <https://doi.org/10.1016/j.applthermaleng.2017.06.046>.
- [14] M.H. Esfe, D. Toghraie and F. Amoozadkhalili, Optimization and design of ANN with Levenberg-Marquardt algorithm to increase the accuracy in predicting the viscosity of SAE40 oil-based hybrid

- nano-lubricant, Powder Technology, 415, 118097, 2023. <https://doi.org/10.1016/J.POWTEC.2022.118097>.
- [15] F. Sahin, O. Genc, M. Gökçek and A.B. Çolak, An experimental and new study on thermal conductivity and zeta potential of Fe₃O₄/water nanofluid: Machine learning modeling and proposing a new correlation, Powder Technology, 420, 118388, 2023. <https://doi.org/10.1016/J.POWTEC.2023.118388>.
- [16] M. Hemmat Esfe, F. Amoozadkhalili and D. Toghraie, Determining the optimal structure for accurate estimation of the dynamic viscosity of oil-based hybrid nanofluid containing MgO and MWCNTs nanoparticles using multilayer perceptron neural networks with Levenberg-Marquardt Algorithm, Powder Technology, 415, 118085, 2023. <https://doi.org/10.1016/J.POWTEC.2022.118085>.
- [17] M. Hemmat Esfe and S. Saedodin, An experimental investigation and new correlation of viscosity of ZnO-EG nanofluid at various temperatures and different solid volume fractions, Experimental Thermal and Fluid Science, 55, 1–5, 2014. <https://doi.org/10.1016/j.expthermflusci.2014.02.011>.
- [18] S.M.S. Murshed, K.C. Leong and C. Yang, Enhanced thermal conductivity of TiO₂—water based nanofluids, International Journal of Thermal Sciences, 44, 367–373, 2005. <https://doi.org/10.1016/j.ijthermalsci.2004.12.005>.
- [19] M. Hojjat, S.G. Etemad, R. Bagheri and J. Thibault, Thermal conductivity of non-Newtonian nanofluids: Experimental data and modeling using neural network, International Journal of Heat and Mass Transfer, 54, 1017–1023, 2011. <https://doi.org/10.1016/J.IJHEATMASSTRANSFER.2010.11.039>.
- [20] K.M. Yashawantha and A.V. Vinod, ANN modelling and experimental investigation on effective thermal conductivity of ethylene glycol:water nanofluids, Journal of Thermal Analysis and Calorimetry, 145, 609–630, 2021. <https://doi.org/10.1007/S10973-020-09756-Y/FIGURES/24>.
- [21] W. He, B. Ruhani, D. Toghraie, N. Izadpanahi, N.N. Esfahani, A. Karimipour and M. Afrand, Using of Artificial Neural Networks (ANNs) to predict the thermal conductivity of Zinc Oxide–Silver (50%–50%)/Water hybrid Newtonian nanofluid, International Communications in Heat and Mass Transfer, 116, 104645, 2020. <https://doi.org/10.1016/J.ICHEATMASSTRANSFER.2020.104645>.
- [22] M. Amani, P. Amani, A. Kasaeian, O. Mahian, I. Pop and S. Wongwises, Modeling and optimization of thermal conductivity and viscosity of MnFe₂O₄ nanofluid under magnetic field using an ANN, Scientific Reports, 7:1, 1–13, 2017. <https://doi.org/10.1038/s41598-017-17444-5>.
- [23] K. Verma, R. Agarwal, R.K. Duchaniya and R. Singh, Measurement and Prediction of Thermal Conductivity of Nanofluids Containing TiO₂ Nanoparticles, Journal of Nanoscience and Nanotechnology, 17, 1068–1075, 2017. <https://doi.org/10.1166/JNN.2017.12584>.
- [24] M. Tahani, M. Vakili and S. Khosrojerdi, Experimental evaluation and ANN modeling of thermal conductivity of graphene oxide nanoplatelets/deionized water nanofluid, International Communications in Heat and Mass Transfer, 76, 358–365, 2016. <https://doi.org/10.1016/J.ICHEATMASSTRANSFER.2016.06.003>.
- [25] A.B. Çolak, Developing optimal artificial neural network (ann) to predict the specific heat of water-based yttrium oxide (Y₂O₃) nanofluid according to the experimental data and proposing new correlation, Heat Transfer Research, 51, 1565–1586, 2020. <https://doi.org/10.1615/HEATTRANSRES.2020034724>.
- [26] H. Zhang, S. Qing, Y. Zhai, X. Zhang and A. Zhang, The changes induced by pH in TiO₂/water nanofluids: Stability, thermophysical properties and thermal performance, Powder Technology, 377, 748–759, 2020. <https://doi.org/10.1016/j.powtec.2020.09.004>.

