



Yapay Sinir Ağları ve Derin Öğrenme Algoritmaları Kullanarak Nanokompozitlerde Deformasyonun Tahmin Edilmesi

Eser SÖZEN¹, Timuçin BARDAK², Deniz AYDEMİR¹, Selahattin BARDAK³

¹ Bartın Üniversitesi, Orman Fakültesi Orman Endüstri Mühendisliği Bölümü, BARTIN

² Bartın Üniversitesi, Meslek Yüksekokulu, Mobilya ve Dekorasyon Bölümü, BARTIN

³ Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, SİNOP

Öz

Nanoteknoloji birçok endüstri için devrim niteliğindedir. Ülkelerin bilimsel ve ekonomik olarak yaptığı yatırımlar, nanoteknolojinin önemini ortaya koymaktadır. Bilim dünyasında veri madenciliği önemli bir yere sahiptir. Teknolojinin birçok alanında veri biliminden faydalanılmaktadır. Nanokompozitlerin kullanım yerini özellikler genellikle mekanik belirler. Geleneksel testler ile mekanik özellikleri belirlemek pahalı ve zaman alıcıdır. Veri madenciliği teknikleri bu problemlere daha düşük maliyetler ile çözümler sunabilmektedir. Bu çalışmada, derin öğrenme ve yapay sinir ağları algoritmaları farklı nanokompozitlerin çekme testleri sırasında deformasyonunu tahmin etmek için kullanılmıştır. Çalışma nanokompozit uygulamalarında veri madenciliği algoritmalarının başarılı bir şekilde uygulanabileceği gösterilmiştir. Aynı zamanda derin öğrenme algoritmalarının, yapay sinir algoritmalarından daha başarılı olduğu belirlenmiştir. Nanoteknoloji alanında veri madenciliğinin uygulandığı bilimsel çalışmalar çok sınırlı sayıdadır. Nanokompozitlerin üretiminin veri madenciliği algoritmaları ile simüle edildiği yeni çalışmalara ihtiyaç vardır.

Anahtar Kelimeler: Nanoteknoloji, Derin Öğrenme, Yapay Sinir Ağları, Veri

Estimation of Deformation in Nanocomposites Using Artificial Neural Networks and Deep Learning Algorithms

Abstract

Nanotechnology is revolutionary for many industries. The investments that countries make scientifically and economically reveal the significance of nanotechnology. In the world of science, data mining has an important place. Data science is used in many areas of technology. The mechanical properties usually determine where the nanocomposites are use. Determining mechanical properties with conventional tests is expensive and time consuming. Data mining techniques can provide solutions to these problems with lower costs. In this study, deep learning and artificial neural network algorithms were used to predict the deformation of different nanocomposites during tensile tests. The study showed that data mining algorithms could be successfully applied to nanocomposite applications. At the same time, it was determined that deep learning algorithms are more successful than artificial neural algorithms. The scientific work of data mining in nanotechnology is very limited. New studies are needed to simulate the production of nanocomposites with data mining algorithms.

Keywords: Nanotechnology, Deep Learning, Artificial Neural Networks, Data

*Sorumlu Yazar (Corresponding Author):

Timuçin BARDAK (Dr.); Bartın Üniversitesi, Bartın Meslek Yüksekokulu, Mobilya ve Dekorasyon Bölümü, E-mail: timucinbardak@gmail.com, ORCID: 0000-0002-1403-1049

Geliş (Received) : 31.07.2018
Kabul (Accepted) : 05.08.2018
Basım (Published) : 15.08.2018

1. Giriş

Odun-plastik kompozitler (OPK) (Wood polymer composites, WPC) lignin içerikli materyallerin plastiklerle kombinasyonu ile elde edilen kompozitlere verilen bir isimdir. Odunun gerek lif haline getirilerek, gerekse un haline getirilerek termoplastik esaslı polietilen (PE), propilen (PP), polivinilklorür (PVC) gibi polimerler ile karıştırılmasıyla oluşan kompozit levhalara termoplastik esaslı kompozit malzemeler denilmektedir. PE, PP, PVC ve PS (polistiren) gibi plastikler, lignoselülozik materyallerin bozunmasını önlemek için tercih edilmektedir. 150–220 °C arasında değişen bu plastiklerin erime sıcaklıkları, odun plastik kompozitlerinin üretilmesi için uygun değerlerdir (Matuana ve Heiden, 2004). İki veya daha fazla materyalden oluşan kompozitler, genel olarak kendilerini oluşturan materyallerden daha iyi performans gösterirler (Mengeloğlu ve Karakuş, 2008).

Polimer endüstrisi çok geniş bir alan olup, Polietilen (PE), polipropilen (PP) gibi plastik polimerler ve lignin içerikli materyaller polimer kompozit alanında oldukça yoğun bir şekilde kullanılmaktadır. Özellikle son yıllarda geri dönüşüme verilen önemle birlikte atık plastiklerin polimer matrisi olarak kullanımı da artmıştır. Lignoselülozik olarak endüstriyel orman atıklarının yanında yıllık bitkiler, tarımsal atıkların kullanılmasıyla üretilen çeşitli polimer kompozitler mevcuttur. Tarımsal atıkların polimer-kompozit üretiminde değerlendirilmesi üzerine yapılan çalışmalarda kendir, kenevir, şeker kamışı, kapok vb. yıllık bitkiler kullanılmıştır. Bu malzemeler kapı-pencere doğraması, kamelya malzemesi, dış ortam peyzaj materyalleri gibi kullanım alanlarında kendine kullanım alanı bulmuştur. Bu malzemelerin avantajları arasında düşük yoğunluğa sahip olmaları, yüksek spesifik dirençlerinin olması ve kolay bulunabilmeleri sayılabilir (Chen ve ark., 1998; Gassan ve Bledzki, 1997; Vande Velde ve Keikens, 2001). Odun plastik kompozitlerinde destek olarak kullanılan doğal liflerinin rutubet oranları, lifi oluşturan amorf yapıya bağlıdır. Doğal liflerdeki rutubet oranının yüksek olması, hem kendi hem de oluşturduğu kompozitin fiziksel özelliklerini etkilemektedir (Wuppertal, 1981). Bouafif ve ark. (2009), destek materyali olarak lignoselülozik lif kullandığı çalışmada eğilme ve çekme direnç değerlerinin kontrol örneklerine oranla sırasıyla 2,2 ve 1,7 kat artırdığını bildirmiştir. Pramanick ve Dickson (1997), odun unlarının PP kompozitlerinde en çok darbe direncini artırdığını bildirmişlerdir.

Yapay sinir ağları ile geleceğe yönelik yapılan tahminlerde başarılı sonuçlar elde edilebilmesi daha çok bağımsız değişkenlerin alacağı değerin bilinmesine bağlıdır. Karar verici farklı ağ yapıları kullanılarak ve problem tipine hangi ağın daha uygun olduğunu belirleyerek daha iyi sonuçlar elde edilebilmektedir (Kurt ve ark., 2017). Verilerden anlamlı bilgiler elde etmek günümüzde kritik bir konudur. Anlamlı bilgiler sorunlara odaklanmakta oldukça yardımcı olmaktadır. Bilgisayar bilimlerindeki hızlı teknolojik gelişmeler veri madenciliği teknolojilerinin gelişmesine yol açmıştır (Leopord ve ark., 2016). Veri madenciliği büyük ölçekli veriler arasından gizli bilgiye ulaşma işidir (Terzi ve ark., 2011). Verilerin analizinde istatistik birçok problemin çözümünde yaygın olarak kullanılmaktadır. Fakat, bazı problemlerde kullanımı zordur. Özellikle çok büyük miktarda ve çeşitli veri ile çalışırken istatistik yöntemler yetersiz kalabilmektedir. Bu şartlarda, veri madenciliği karmaşık sorunlara çözüm ihtiyacını gidermektedir (Emel ve Taşkın, 2005; Sözen ve ark. 2017).

Son zamanlarda birçok bilim insanı, bileşim şirketi ve gelişmiş ülkeler veri madenciliğine olan yatırımını hızla artırmıştır. Birçok alanda (pazarlama sosyal, eğitim, iletişim ve mühendislik) veri madenciliği algoritmaları kullanılmıştır (Özel ve Topsakal, 2014; Terzi, 2006; Küçüksille ve ark., 2009). Veri Madenciliğinde bilgiye ulaşma amacı bir süreçtir. Doğru tasarlanmış bir süreç ile bu amacı gerçekleştirmek mümkündür (Terzi ve ark., 2011). Veri madenciliğinde birçok farklı yöntem kullanılmaktadır. Bu yöntemlerden bazıları; sınıflandırma, regresyon analizi, kümeleme, birliktelik analizi, sıralı dizi analizi ve zaman serileri analizi şeklindedir (Söylemez ve ark., 2016).

Bu çalışmada, polipropilen polimeri, lif levha (MDF) ve yonga levha fabrikalarından elde edilen selüloz lifleri ve odun unları ile farklı (%10 ve %20) oranlarda desteklenerek odun plastik kompozitleri elde edilmiştir. Kompozitlerin termal ve UV özelliklerinin artırılması için ise %0,5 ve %1 oranında nano boyutta TiO₂ ve bor nitrür ilave edilerek nano kompozitlerin çekme direncinde oluşan deformasyonu belirlenmiştir. Elde edilen deformasyon sonuçlarının Veri Madenciliği yöntemlerinden derin öğrenme ve yapay sinir ağları ile tahmin edilebilirliği araştırılmıştır.

2. Materyal ve Metot

2.1. Materyal

Çalışma kapsamında, polimer matrisi olarak polipropilen (PP), destek materyali olarak odun unu ve selüloz lifi, katkı maddesi olarak ise nano boyutta TiO₂ ve bor nitrür (BN) ilave edilmiştir.

2.1.1. Polypropilen (PP)

Çalışmada polimer matriks olarak kullanılan PP (EH241), Petkim Petrokimya Holding AŞ'den temin edilmiştir. PP – EH241'e ait genel özellikler Tablo 1'de verilmiştir.

Tablo 1. PP – EH241'e ait genel özellikler

Özellikler	Değerler
Erime akış hızı, g/10 dak. (230 °C/2.16 kg)	5-20
Yoğunluk (g/cm ³)	0,92
Su alma oranı (%)	0,1
İşlenme sıcaklığı (°C)	160-170
Çekmede Elastikiyet Modülü (MPa)	35
Eğilmede Elastikiyet Modülü (GPa)	1,5
Darbe direnci (kJ/m ²)	2

2.1.2. Odun Unu ve Selüloz Lifi

Odun unu örneklerinin elde edilmesi için, ortalama %70 yapraklı (*Fagus orientalis* L. ve *Populus sp*) %30 iğne yapraklı (*Pinus nigra* A. ve *Pinus sylvestris* L.) ağaç kullanan SFC Kastamonu yonga levha fabrikasından odun yongaları temin edilmiştir. Odun yongaları 0,3 mesh'lik elekler kullanılarak Wiley değirmeninde öğütülmüştür. Öğütülen odun unlarının büyüklükleri, polimer matriks ile yapılan bağlanmalar için önemli bir yer tutmaktadır. Dolgu maddesi ve polimer matriks arasında yüzey temasının artırılması, üretilecek odun polimer kompozitlerinin özelliklerine doğrudan etki etmektedir. Çalışmada kullanılan selüloz lifleri, Kastamonu Entegre MDF tesislerinden temin edilen, uzunlukları 2-5mm arasında değişen yapraklı ve iğne yapraklı ağaç lifleridir. Öğütülen odun unları ve fabrikadan temin edilen selülozlar ayrı etüvlerde 103±2 °C'de 24 saat bekletilerek tam kuru hale getirilmiştir. Şekil 1'de çalışmada kullanılan ana ham maddeler gösterilmiştir.



Şekil 1. Çalışmada kullanılan (a) polipropilen, (b) odun unu, (c) selüloz lifi

2.1.3. Odun Unu ve Selüloz Lifi

TiO₂ nano partikülleri MK Impex Corp. (Kanada) şirketinden temin edilmiştir. Ortalama 50 nm boyutunda olan partiküllerin spesifik yüzey alanı 150 m²/g, saflık derecesi ise %99'dur. Çalışmada kullanılan diğer bir nano partikül olan bor nitür, bor ve azot elementlerinden oluşmaktadır. Rudolph (2000), bor nitürün doğal olarak elde edilemeyeceğini, bu yüzden bor trioksit veya borik asitin amonyum veya üre ile sentezinden elde edilebileceğini bildirmiştir. Çalışmada kullanılan nano bor nitürün özgül ağırlığı 2,27 gr/cm³, erime sıcaklığı ise 2700-3000 °C arasındadır.

2.2. Metod

Dolgu maddeleri %10 ve %20 oranlarında kullanılırken nano materyaller %0,5 ve %1 oranlarında kullanılmıştır. Çalışma kapsamında üretilen odun plastik kompozitlerine ait reçeteler Tablo 2'de gösterilmiştir. Her bir gruptan 5 adet örnek üretilmiştir.

Tablo 2. Çalışma kapsamında üretilen odun plastik kompozitlerine ait reçeteler

Dolgu maddesi	Polipropilen Miktarı (gr)	Dolgu Maddesi Miktarı(gr)	Nano malzeme miktarı (gr)	Nano Malzeme Türü	Örnek Kodu	Çekmede Ortalama Deformasyon (mm)
Odun Unu	895	100	5	NB	O1NB0,5	7,142
	890	100	10	NB	O1NB1	6,646
	895	100	5	TiO ₂	O1T0,5	7,622
	890	100	10	TiO ₂	O1T1	7,736
	795	200	5	NB	O2NB0,5	5,294
	790	200	10	NB	O2NB1	5,242
	795	200	5	TiO ₂	O2T0,5	5,510
	790	200	10	TiO ₂	O2T1	5,724
Selüloz Lifi	895	100	5	NB	S1NB0,5	6,866
	890	100	10	NB	S1NB1	5,682
	895	100	5	TiO ₂	S1T0,5	6,192
	890	100	10	TiO ₂	S1T1	6,218
	795	200	5	NB	S2NB0,5	4,766
	790	200	10	NB	S2NB1	5,016
	795	200	5	TiO ₂	S2T0,5	4,642
	790	200	10	TiO ₂	S2T1	4,506

Tablo 2’de gösterilen karışımların homojen olarak karıştırılması, son ürünün özellikleri üzerinde etkili olmaktadır. Bu nedenle kullanılan selüloz ve odun unlarının boyutlarının homojen olmasına özen gösterilmiştir. Dolgu maddeleri (odun unu, selüloz) ve plastik madde (polipropilen)’nin homojen bir şekilde karışması için mekanik karıştırıcı vasıtasıyla 500 rpm hızla 10 dakika karıştırmaya tabi tutulmuştur. Karıştırma sonrası elde edilen malzemeler tek vidalı ekstruder ile 180 °C sıcaklıkta çekilerek plastik maddenin erimesi ve dolgu maddelerinin etkileşimi sağlanmıştır. Besleme olduğundan karışımlar ekstruder içine koyulmakta ve 4 farklı ısıtıcı ile vida uzunluğu boyunca sıcaklık 178 °C ile 182 °C arasında değişen sıcaklıklarda tutulmaktadır. Ekstruder 50 rpm hızla çalıştırılmıştır. Ekstruder sonrası çıkan karışım soğuması için su banyosuna tabi tutulmuştur. Soğutulan karışım yongalama makinasında yongalanarak içerisindeki suyun uzaklaştırılması için kurutma fırınında 103±2 °C’de ağırlığı değişmeye kadar bekletilmiştir.

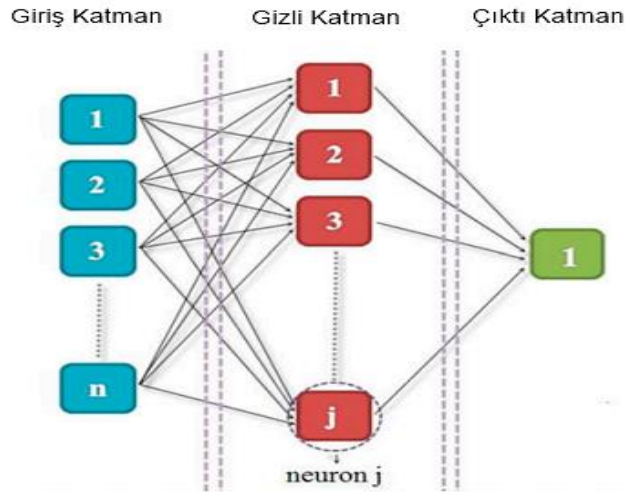
Fırında tamamen kurutulan örnekler enjeksiyon kalıplama işlemine alınmıştır. Enjeksiyon kalıplama işleminde, hazırlanan karışımların istenen boyutlardaki kalıplara basılması söz konusudur. Enjeksiyon kalıplama işleminden çıkan örnekler kesici aletler vasıtasıyla dikkatlice temizlenerek çekme direncine (ASTM D638) uygun hale getirilmiştir. Çekme direnci testlerinde kullanılan örnekler için görsel Şekil 2’de gösterilmiştir.

**Şekil 2.** Çekme testi örneği

Çekme testleri sırasında üniversal test cihazında test örneklerine ait deformasyon oranı modelleme işleminde kullanılmak üzere kaydedilmiştir.

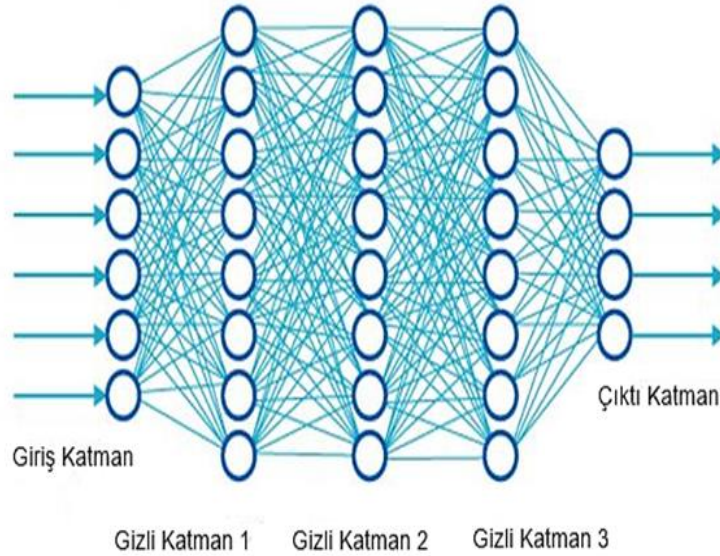
2.2.1. Modelleme

Çalışmanın amacı, yapay sinir ağları ve derin öğrenme algoritmalarını kullanarak nanokompozitlerde deformasyon tahmin modelleri geliştirmek ve modellerin geçerliliğinin araştırılmasıdır. Yapay sinir ağları biyolojik sinir ağlarının yapısı ve işlevinden esinlenerek oluşturulmuş bir matematiksel bir modeldir. Yapay sinir ağları genellikle girdi ve çıktı arasındaki modellemek için kullanılır (Rende ve ark., 2016). Şekil 3’de yapay sinir ağlarının genel yapısı gösterilmiştir.



Şekil 3. Yapay sinir ağlarının genel yapısı (Tiryaki ve ark., 2015).


Derin öğrenme algoritmaları yapay sinir ağlarının yapısal olarak daha karmaşık hali olarak düşünülebilir (Rende ve ark., 2016). Bu algoritmalarda giriş ve çıkış katmanları arasında birden fazla gizli katman bulunmaktadır (Wang ve ark., 2017). Derin öğrenme algoritması veri madenciliğinin makine öğrenme algoritmalarından birkaç yönden ayrılır. Bu algoritmalarda çok yüksek miktarda veri kullanılmaktadır. Aynı zamanda daha yüksek donanım ihtiyacı duyarlar (Rende ve ark., 2016).



Şekil 4. Derin öğrenmenin genel yapısı (URL-1).

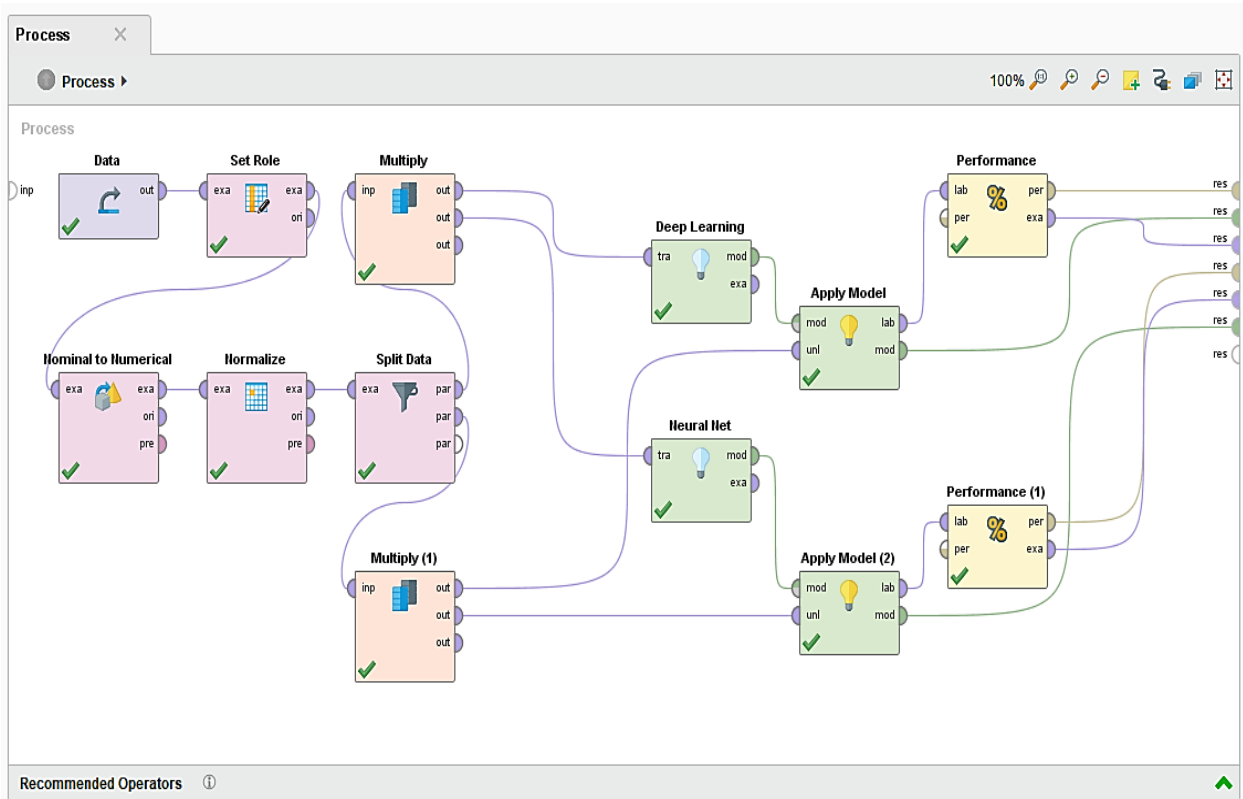
2.2.2. Verilerin Modellenmesi

Çalışmada, veri madenciliği ile model geliştirebilmek için RapidMiner yazılımı kullanılmıştır. RapidMiner, açık kaynak kodlu birçok veri madenciliği algoritmasını bünyesinde taşıyan Dortmund Teknoloji Üniversitesi tarafından geliştirilmiş bir yazılımdır (Kaya ve Özel, 2014). Literatüre uygun olarak modellerde verilerin %66,6 eğitim %33,3 modelin test edilmesi için kullanılmıştır (Jennings ve ark., 2016). Modellerin performans testlerinden önce model parametrelerinin optimizasyonu sağlanmıştır. Şekil 5'de optimizasyon için oluşturulan proses gösterilmiştir.



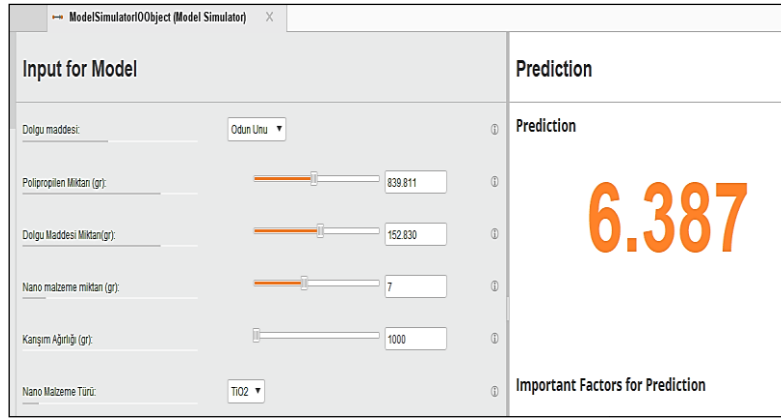
Şekil 5. Optimizasyon için oluşturulan proses

Modelin girdileri dolgu maddesi, polipropilen miktarı, dolgu maddesi miktarı, nano malzeme miktarı, karışım ağırlığı ve nano malzeme türü, çıktı olarak nanokompozitlerin deformasyonu belirlenmiştir. Modellerin kıyaslanması için operatörlerden oluşturulan proses şekil 6'da gösterilmiştir.



Şekil 6. Modellerin kıyaslanması için operatörlerden oluşturulan proses

Modeller tasarlandıktan sonra ayrı ayrı simülasyon işlemi yapılmıştır. Şekil 7'de derin öğrenme modeli için hazırlanmış simülasyon ekranı gösterilmiştir. Simülasyon terimi modelleme teriminden farklıdır. Simülasyon bir işlemin temsil edilmesi olarak tanımlanabilir. Simülasyon işlemi üç hedefe ulaşmak için yapılır: Birincisi, kullanıcılar derin öğrenme gibi karmaşık modelleri daha iyi anlamak. İkincisi, kullanıcılar modelin beklendiği gibi davranıp davranmadığını kontrol etmek. Üçüncü olarak, kullanıcılar istenen sonucu elde etmek amacı ile en uygun giriş ayarlarını bulmaktır (URL-2). Bu sayede zaman alıcı ve maliyetli deneylere ihtiyaç azalmaktadır.



Şekil 7. Derin öğrenme modeli için hazırlanmış simülasyon ekranı

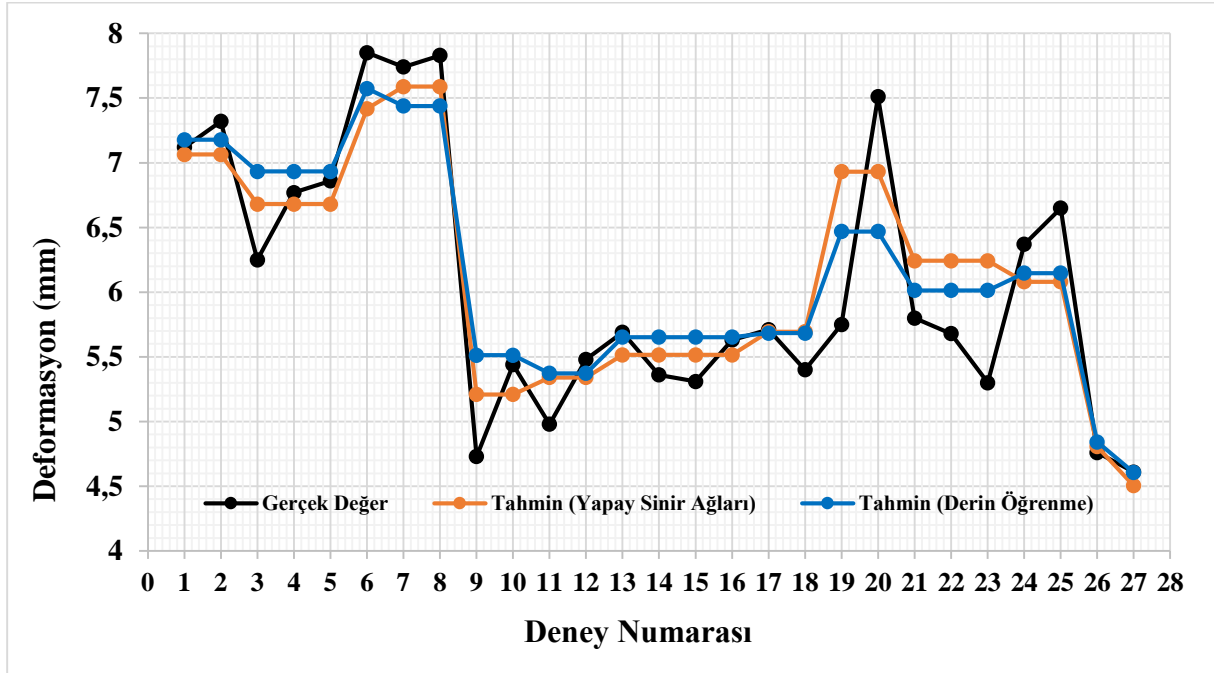
3. Bulgular ve Tartışma

Bu çalışmada farklı nanokompozitlerin deformasyon oranını tahmin etmek için yapay sinir ağları ve derin öğrenme modelleri uygulanmıştır. Test kısmında elde edilen sonuçlara göre, derin öğrenme modeli % 5,12 ortalama mutlak yüzde hata ile başarı gösterirken yapay sinir ağları modeli % 5,46 başarı göstermiştir. Çalışma derin öğrenme modelinin daha yüksek doğruluk oranına sahip olduğunu göstermiştir. Tablo 3’de test kısmı için ölçülen gerçek değerler, tahmin edilen değerler ve yüzde hataları gösterilmiştir.

Tablo 3. Test kısmı için ölçülen gerçek değerler, tahmin edilen değerler ve yüzde hataları

Örnek Kodu	Deformasyon (mm)			Hata (%) (Yapay Sinir Ağları)	Hata (%) (Derin Öğrenme)
	Gerçek	Tahmin (Yapay Sinir Ağları)	Tahmin (Derin Öğrenme)		
O1NB0,5	7,120	7,064	7,178	0,79	-0,81
O1NB0,5	7,320	7,064	7,178	3,50	1,94
O1NB1	6,250	6,680	6,933	-6,88	-10,93
O1NB1	6,770	6,680	6,933	1,33	-2,41
O1NB1	6,860	6,680	6,933	2,62	-1,06
O1T0,5	7,850	7,418	7,573	5,50	3,53
O1T1	7,740	7,588	7,439	1,96	3,89
O1T1	7,830	7,588	7,439	3,09	4,99
O2NB0,5	4,730	5,209	5,513	-10,13	-16,55
O2NB0,5	5,440	5,209	5,513	4,25	-1,34
O2NB1	4,980	5,341	5,373	-7,25	-7,89
O2NB1	5,480	5,341	5,373	2,54	1,95
O2T0,5	5,690	5,515	5,652	3,08	0,67
O2T0,5	5,360	5,515	5,652	-2,89	-5,45
O2T0,5	5,310	5,515	5,652	-3,86	-6,44
O2T0,5	5,630	5,515	5,652	2,04	-0,39
O2T1	5,710	5,694	5,683	0,28	0,47
O2T1	5,400	5,694	5,683	-5,44	-5,24
S1NB0,5	5,750	6,932	6,469	-20,56	-12,50
S1NB0,5	7,510	6,932	6,469	7,70	13,86
S1NB1	5,800	6,242	6,014	-7,62	-3,69
S1NB1	5,680	6,242	6,014	-9,89	-5,88
S1NB1	5,300	6,242	6,014	-17,77	-13,47
S1T1	6,370	6,080	6,147	4,55	3,50
S1T1	6,650	6,080	6,147	8,57	7,56
S2NB1	4,760	4,806	4,842	-0,97	-1,72
S2T0,5	4,610	4,504	4,606	2,30	0,09

Şekil 7’de test kısmı için ölçülen verilerin derin öğrenme ve yapay sinir ağları ile tahmin edilen sonuçların karşılaştırılması gösterilmiştir.



Şekil 7. Test kısmı için Ölçülen verilerin derin öğrenme ve yapay sinir ağları ile öngörülen sonuçların karşılaştırılması.

Korelasyon katsayısı (R^2) modellerin performansını değerlendirmek için yaygın olarak kullanılır. R^2 , değişkenler arasındaki ilişkiyi göstermek için kullanılmaktadır. Test kısmından elde edilen R^2 kriteri açısından performanslar değerlendirildiğinde, derin öğrenme modeli 0.844 yapay sinir ağları modeli 0.822 olarak belirlenmiştir. Literatürde R^2 değerinin 0.7 büyük olması durumunda modelin başarılı olduğu bildirilmiştir (Elarabi ve ark., 2014).

4. Sonuç ve Öneriler

Deformasyon analizi, malzemenin performansı açısından oldukça kritik bir konudur. Bu çalışmada, farklı nanokompozitlerin deformasyon oranlarını tahmin etmek için derin öğrenme ve yapay sinir ağları modellerinin performansı araştırılmıştır. Her iki modelde tahminde yüksek doğruluk oranına sahip olduğu belirlenmiştir. Modellerin tahmini performansını değerlendirmek için korelasyon katsayısı ve yüzde hata kriterleri kullanılmıştır. Derin öğrenme modeli daha yüksek bir tahmin performansı sergilemiştir. Veri miktarının çok büyük miktarda olduğu durumlarda derin öğrenme için performansın daha yüksek olacağı düşünülmektedir.

Nanokompozitlerin performanslarının belirlenmesinde deney materyallerinin üretimi büyük bir çaba ve maliyet gerektirmektedir. İyi eğitilmiş modeller sayesinde daha az sayıda test ile yüksek doğrulukta istenilen sonuçlara ulaşmak mümkündür. Bu da deneysel maliyetlerin azalmasında katkı sağlayacaktır. Bu nedenle modellerin farklı çalışma alanlarında kullanılmaları tavsiye edilmektedir.

Bilgi Notu

Bu çalışmanın özeti 15-17 Mayıs 2017 tarihleri arasında Nevşehir’de gerçekleştirilen “International Conference on Agriculture, Forest, Food Sciences and Technologies (ICAFOF 2017 Cappadocia / Turkey)” isimli konferansın Özet Kitabında yayınlanmıştır.

Kaynaklar

1. **Bouafif H, Koubaa A, Perré P, Cloutier A. (2009).** Effects of fiber characteristics on the physical and mechanical properties of wood plastic composites, *Composites Part A: Applied Science and Manufacturing*, 40(12), 1975-1981.
2. **Chen X, Guo Q, Mi Y. (1998).** Bamboo Fiber Reinforced Polypropylene Composites. A Study of the Mechanical Properties," *J. Appl. Polym. Sci.*, 69(10),1891-1899.
3. **Elarabi H, Abdelgalil S.A. (2014).** Application of artificial neural network for 242 prediction of Sudan soil profile," *Am. J. Eng. Technol. Soc.* 1, 7-10.
4. **Emel GG, Taşkın Ç. (2005).** Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması. *Sosyal Bilimler Dergisi*, 6(2).
5. **Gassan J, Bledzki AK, (1997).** The Influence of Fiber Surface Treatment on the Mechanical Properties of Jute-PP Composites," *Composites Part A*, 28(12), 993-1000, 1997.
6. **Jennings C, Wu D, Terpenney J. (2016).** Forecasting obsolescence risk and product life cycle with machine learning. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 6(9), 1428-1439.
7. **Kaya M, Özel SA. (2014).** Açık Kaynak Kodlu Veri Madenciliği Yazılımlarının Karşılaştırılması. Akademik Bilişim Konferansı, 5-7 Şubat, pp: 47-53, Mersin.
8. **Kurt R, Karayılmazlar S, İmren E, Çabuk Y. (2017).** Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kağıt-Karton Sanayi Örneği. *Journal of Bartın Faculty of Forestry*, 19(2), 99-106.
9. **Küçükşille EU, Selbas R, Şencan A, (2009).** Data mining techniques for thermophysical properties of refrigerants. *Energy Convers. Manage*, 50(2), 399-412.
10. **Leopord H, Cheruiyot WK, Kimani SA. (2016).** Survey and Analysis on Classification and Regression Data Mining Techniques for Diseases Outbreak Prediction in Datasets. *The International Journal Of Engineering And Science*, 5(9), 1-11.
11. **Matuana LM, Heiden PA. (2004).** Wood Composites, in: *Encyclopedia of Polymer Science and Technology*, J. I.Kroschwitz, Ed., John Wiley & Sons, Inc., New York.
12. **Mengeloğlu F, Karakuş K. (2008).** Polymer-Composites from Recycled High Density Polyethylene and Waste Lignocellulosic Materials, *Fresenius Environmental Bulletin*, 17(2), 211-217.
13. **Özel C, Topsakal A. (2014).** Veri Madenciliği Kullanarak Beton Basınç Dayanımının Belirlenmesi. *Cumhuriyet Science Journal*, 35(1), 1-11.
14. **Pramanick PK, Dickson B. (1997).** Thermoplastic composite from recycled plastic and wood flours," In: *Proceedings of the annual technical conference of the society of plastic engineers (ANTEC)*, Toronto, pp: 3136-3140.
15. **Rende FŞ, Bütün G, Karahan Ş. (2016).** Derin Öğrenme Algoritmalarında Model Testleri: Derin Testler. 10. Ulusal yazılım Mühendisliği Sempozyumu,24-26 Ekim, pp:54-59, Çanakkale.
16. **Rudolph S. (2000).** Boron Nitride (BN), *American Ceramic Society Bulletin*, 79(6), 2000
17. **Söylemez İ, Doğan A, Özcan U. (2016).** Trafik Kazalarında Birliktelik Kuralı Analizi: Ankara İli Örneği. *Ege Academic Review*, 16.
18. **Sözen E, Bardak T, Peker H, Bardak S. (2017).** Apriori Algoritması Kullanılarak Mobilya Seçimde Etkili Olan Faktörlerin Analizi. *İleri Teknoloji Bilimleri Dergisi*, 6(3), 679-684.
19. **Terzi Ö, Küçükşille EU, Ergin G, İlker A. (2001).** Veri madenciliği süreci kullanılarak güneş ışınımı tahmini. *SDU International Technologic Science*, 3(2), 29-37.
20. **Terzi S, (2006).** Modelling the pavement present serviceability index of flexible highway pavements using data mining. *J. Appl. Sci.*, 6(1), 193-197.
21. **Tiryaki S, Bardak S, Bardak T. (2015).** Experimental investigation and prediction of bonding strength of Oriental beech (*Fagus orientalis* Lipsky) bonded with polyvinyl acetate adhesive. *Journal of Adhesion Science and Technology*, 29(23), 2521-2536.
22. **URL-1:** <https://medium.com/diaryofawannapreneur/deep-learning-for-computer-vision-for-the-average-person-861661d8aa61> Erişim Tarihi:28.07.2018
23. **URL-2:** http://docs.rapidminer.com/studio/operators/modeling/predictive/neural_nets/neural_net.html Erişim Tarihi:24.07.2018
24. **Vande Velde K, Keikens P. (2001).** Thermoplastic Polymers; Overview of Several Properties and Their Consequences in Flax Fiber Reinforced Composites, *Polymer Testing*, 20(8), 885-893.
25. **Wang Y, Mao H, Yi Z. (2017).** Protein secondary structure prediction by using deep learning method. *Knowledge-Based Systems*, 118, 115-123.
26. **Wuppertal EW. (1981).** *Die Textilten Rohstoffe (Natur und Chemiefasern)*, Dr. Spohr-Verlag/Deutscher Fachverlag, Frankfurt.