







Using group method of data handling (GMDH) neural network to predict the maximum stress on elastomeric layers in spherical elastomeric bearings

Yılmaz Kaya¹ , Murat Makaracı² , M. Said Bayraklılar³ , Melih Kuncan^{4*} 

¹Department of Computer Engineering, Siirt University, Siirt, 56100, Turkey

²Department of Mechanical Engineering, Kocaeli University, Kocaeli, 41380, Turkey

³Department of Mechanical Engineering, Siirt University, Siirt, 56100, Turkey

⁴Department of Electrical-Electronic Engineering, Siirt University, Siirt, 56100, Turkey

Highlights:

- While there is much work on planar elastomeric bearings, there is not much work on spherical elastomeric bearings
- The effect of different designs on spherical elastomeric bearing life has been investigated
- The effect of each of the parameters used in the design on the maximum stress was estimated by GMDH

Keywords:

- ABAQUS
- nonlinear finite element analysis
- air vehicles
- hyper-elasticity
- spherical elastomeric bearing
- GMDH

Article Info:

Research Article

Received: 21.04.2020

Accepted: 25.01.2021

DOI:

10.17341/gazimmfd.722514

Correspondence:

Author: Melih Kuncan

e-mail:

melihkuncan@siirt.edu.tr

phone: +90 484 212 1111 / 3033

Graphical/Tabular Abstract

In this study, GMDH model is used to estimate the maximum stresses in elastomeric layers in a spherical elastomeric bearing under compression and angular displacement loading. In the scope of the study, the spherical elastomeric bearing; The effects of hole diameter, hole shape, elastomer layer thickness, number of layers and elastomer bearing profile on maximum stress were investigated. θ (angular displacement loading), P (pressure loading), a (radius of axis), β_0 (first joint angle), $\cos(\beta_0)$ (first joint angle cosine value), β_1 (second joint angle), β_2 (third joint angle), ϕ_t (cone angle), ϕ_p (angle between the direction of the pressure loading and the plane perpendicular to the elastomer layer), $\cos(\phi_p)$, D (elastomer layer outer diameter), n_e (elastomer layer number), d (elastomer layer hole diameter) and H elastomer layer thickness) were used as input features for GMDH model. The results obtained with GMDH were also compared with different machine learning methods such as ANN, SVM, RF.

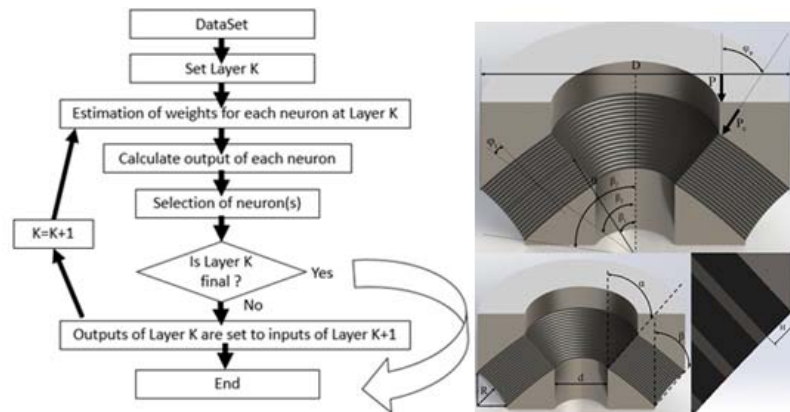


Figure A. Group method of data handling

Purpose: In this study, the Group Method of Data Handling (GMDH) model is used to estimate the maximum stresses in elastomeric layers in a spherical elastomeric bearing under compression and angular displacement loading in the Fig. 1.

Theory and Methods:

In this study, statistical criteria such as mean square error (MSE), root mean square error (RMSE) and correlation coefficient (R) were used to test the performance of GMDH and other models.

Results:





According to the results obtained, GMDH model was found to be more successful than other models in estimating spherical elastomeric bearing.

Conclusion:

The effects of hole diameter, hole shape, elastomer layer thickness, number of layers and elastomer bearing profile on maximum stress were investigated. θ , P , a , β_0 , $\cos(\beta_0)$, β_1 , β_2 , ϕ_t , ϕ_p , \cos , D , n_e , d and H were used as input features for GMDH model.



Veri işleme grup yöntemi (VİGY) sinir ağı kullanılarak küresel elastomerik yataklarda elastomer tabakalar üzerindeki maksimum gerilmenin tahmini

Yılmaz Kaya¹ , Murat Makaracı² , M. Said Bayraklılar³ , Melih Kuncan^{4*} 

¹Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Siirt, 56100, Türkiye

²Kocaeli Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Kocaeli, 41380, Türkiye

³Siirt Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Siirt, 56100, Türkiye

⁴Siirt Üniversitesi, Mühendislik Fakültesi, Elektrik- Elektronik Mühendisliği Bölümü, Siirt, 56100, Türkiye

Ö N E Ç İ K A N L A R

- Düzlemsel elastomerik yataklarla ilgili çok fazla çalışma varken küresel elastomerik yataklarla ilgili çalışma fazla yoktur
- Farklı tasarımların yatak ömrüne etkisi incelenmiştir
- Tasarımda kullanılan parametrelerin her birinin maksimum gerilme üzerine etkisi VİGY ile tahmin edilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 21.04.2020

Kabul: 25.01.2021

DOI:

10.17341/gazimmfd.722514

Anahtar Kelimeler:

ABAQUS,
doğrusal olmayan sonlu
elemanlar analizi,
hava araçları,
hiper-elastisite,
küresel elastomerik yatak,
veri işleme grup yöntemi

ÖZ

Uluslararası literatürde düzlemsel elastomerik yataklarla ilgili birçok çalışma dikkati çekerken, çok katmanlı olmasından ve tasarım zorluklarından dolayı küresel elastomerik yataklarla ilgili çok az çalışma bulunmaktadır. Elastomerik yataklar, tabakalara dik gelen yüklere karşı rijitken tabakalara paralel gelen yüklere karşı esnekler. Böylece küresel elastomerik yataklar helikopter pervanelerinin dönmesinden kaynaklı merkez kaç kuvvetine karşı rijit, pervanelerin kanat çırpma ve dönme hareketine karşı esneklik sağlamaktadır. Bu çalışmada, basınç ve açısız yer değiştirme yüklemesi uygulanan küresel elastomerik yatakta bulunan elastomer tabakalarda oluşan maksimum gerilmeleri tahmin etmek için VİGY (Veri İşleme Grup Yöntemi) modeli kullanılmıştır. VİGY sinir ağı modeline giriş olarak θ (açısal yer değiştirme yüklemesi), P (basınç yüklemesi), a (eksen yarıçapı), β_0 (birinci joint açısı), $\cos(\beta_0)$ (birinci joint açısı cosinüs değeri), β_1 (ikinci joint açısı), β_2 (üçüncü joint açısı), ϕ (koni açısı), ϕ_p (basınç yüklemesinin doğrultusuyla elastomer tabakaya dik düzlem arasındaki açı), $\cos(\phi_p)$, D (elastomer tabaka dış çapı), ne (elastomer tabaka sayısı), d (elastomer tabaka delik çapı) ve H (elastomer tabaka kalınlığı) değişkenleri kullanılmıştır. VİGY ile elde edilen sonuçlar ANN, SVM, RF gibi farklı makine öğrenmesi yöntemleri ile de karşılaştırılmıştır. Elde edilen sonuçlara göre VİGY sinir ağı modeli maksimum gerilmeleri tahmin etmede diğer modellere göre daha başarılı bulunmuştur.

Using group method of data handling (GMDH) neural network to predict the maximum stress on elastomeric layers in spherical elastomeric bearings

H I G H L I G H T S

- While there is much work on planar elastomeric bearings, there is not much work on spherical elastomeric bearings
- The effect of different designs on spherical elastomeric bearing life has been investigated
- The effect of each of the parameters used in the design on the maximum stress was estimated by GMDH

Article Info

Research Article

Received: 21.04.2020

Accepted: 25.01.2021

DOI:

10.17341/gazimmfd.722514

Keywords:

ABAQUS,
nonlinear finite element
analysis,
air vehicles,
hyper-elasticity,
spherical elastomeric bearing,
group method of data handling

ABSTRACT

While many studies on planar elastomeric bearings have attracted attention in the international literature, there are very few studies on spherical elastomeric bearings due to their multi-layered and design difficulties. While elastomeric bearings are rigid against loads perpendicular to the layers, they are flexible against the loads parallel to the layers. In this way, spherical elastomeric bearings provide rigid against the central force caused by the rotation of the helicopter propeller, and flexibility against the blade's flapping and rotational movement. In this study, the Group Method of Data Handling (GMDH) model is used to estimate the maximum stresses in elastomeric layers in a spherical elastomeric bearing under compression and angular displacement loading. θ (angular displacement loading), P (pressure loading), a (radius of axis), β_0 (first joint angle), $\cos(\beta_0)$ (first joint angle cosine value), β_1 (second joint angle), β_2 (third joint angle), ϕ (cone angle), ϕ_p (angle between the direction of the pressure loading and the plane perpendicular to the elastomer layer), $\cos(\phi_p)$, D (elastomer layer outer diameter), ne (elastomer layer number), d (elastomer layer hole diameter) and H (elastomer layer thickness) were used as input features for GMDH model. The results obtained with GMDH were also compared with different machine learning methods such as ANN, SVM, RF. According to the results obtained, GMDH model was found to be more successful than other models in estimating spherical elastomeric bearing.

1. GİRİŞ (INTRODUCTION)

Elastomerik yataklar polimer (elastomer) tabakalar arasına çelik levhalar yerleştirmek suretiyle sandviç şeklindeki yapılardan oluşmaktadır. Bu yataklar levhalara dik yönde gelen kuvvetlere karşı rijitken, levhalara paralel yönde salınım hareketlerine izin vermektedir. Bu sayede yüklerin ve salınımların yönlerine göre elastomer yatakların şekilleri belirlenmektedir. Örneğin düşey düzlemde yük altında rijitlik ve yatay düzlemde salınım maruz kalacak sistemlerde düzlemsel elastomerik yataklar kullanılırken, hem düşey hem yatay düzlemde yük altında çalışıp bu düzlemler etrafında salınım yapacak sistemlerde küresel elastomerik yataklar kullanılmaktadır. Son yıllarda araştırmacılar basitleştirilmiş rotor tasarımına (küçük parçalar, hafif, düşük aerodinamik direnç ve düşük bakım maliyeti) yönelmiştir. Düşük bakım maliyeti için yağlama gerektirmeyen yataklar [1-4] veya yataksız çözümler üzerinde çalışılmıştır. Bu sebeple geleneksel hidrolik sönümleyiciler yerine elastomerik veya fluidlastic tipi sönümleyiciler kullanılmaya başlanmıştır.

Elastomerik damperler birbirlerine yapıştırılmış elastomerik malzemelerin takviye tabakalarıyla desteklenmesiyle elde edilir. Elastomerler dinamik koşullar altında viskoelastik davranış gösterirler. Bu malzemeler hareketin genliğine, frekansına ve sıcaklığına karşı lineer tepki vermezler. Konvansiyonel hidrolik damperlerle kıyaslandığında elastomerik damperler daha hafif ve daha az parçaya sahiptir. Elastomerik damperlerde bir yüzey üzerinde kayma hareketi olmadığından tozdan ve yüzey kalitesinden etkilenmezler, zamanla yüzey kalitesinin bozulmasını takip etmeye gerek yoktur [5]. Elastomer üzerine gelen gerilmeler yükseldikçe yatağın ömrü azalmaktadır [6]. Bu sebeple elastomer yatağın ömrünü uzatmak için elastomer tabakalara gelen gerilmelerin azaltılması gerekmektedir.

Naghshineh [7] fiber ve çelik takviyeli düzlemsel elastomerik yatakların üzerine gelen gerilmeleri deneysel olarak incelemiştir ve simülasyon sonuçlarıyla karşılaştırmıştır. Simülasyon çalışmalarında ABAQUS programı kullanılmıştır. Çalışmada takviye malzemesinin yatay ve dikey rijitlik üzerine etkisi incelenmiştir. Fiber takviyeli düzlemsel elastomerik yatakların daha düşük yatay rijitliğe sahip olduğu görülmüştür.

Domaniç [8] köprülerde kullanılan üst ve alt bağlantı elemanı olmayan düzlemsel elastomerik yatakların deprem dayanımlarını deneysel ve sonlu elemanlar analiziyle incelemiştir. Üst ve alt bağlantı elemanı olmayan düzlemsel elastomerik yatakların deprem yüklemelerine maruz kaldıklarında kaymadıkları tespit edilmiştir. Üst ve alt bağlantı elemanı kullanılmamasına rağmen, bağlantı elemanları kullanılan yataklar gibi deprem yüklemelerine karşı kaymadıkları tespit edilmiştir.

Ruano vd. [9] üst ve alt bağlantı elemanı olmayan fiber takviyeli düzlemsel elastomerik yatakların (FREB) dikey ve

yatay yükleme altında sönümleme kapasitesini deneysel olarak incelemiştir. Çalışma sonucunda dairesel kesitli elastomerik yatakların kare kesitli elastomerik yataklara göre biraz daha fazla yatay rijitliğe sahip olduğu görülmüştür, ayrıca fiber takviyeli elastomerik yataklar (GFREB) cam elyaf takviyeli elastomerik yataklara göre daha rijit davranış göstermiştir.

Chen vd. [10] küresel elastomerik yatakların açılma yer değiştirme yüklemesi altında delik koniklik açısı, elastomer tabaka kalınlığı ve dış yüzey eğrilik yarıçapının maksimum gerilmeler üzerine etkisini incelemiştir. Elastomerin viskoelastik davranışı Moonley-Rivlin modeli ile temsil edilen çalışmada sonlu elemanlar yöntemi kullanılmıştır. Silindirik enjeksiyon holü kullanmak ve dış yüzey eğrilik yarıçapını arttırmanın maksimum gerilmeleri önemli ölçüde azalttığı görülmüştür. Su vd. [11] küresel elastomerik yataklara uygulanan basınç ve açılma yer değiştirme yüklemesi altında kauçuk cinsinin genlemeler üzerine etkisini incelemiştir. Elastomerin viskoelastik davranışını temsil eden Ogden modeli kullanılmıştır. Çalışma deneysel ve sonlu elemanlar yöntemi kullanılarak yapılmıştır. Genlemelerin kauçuğun cinsine göre değiştiği görülmüştür.

Ren vd. [12] küresel elastomerik yataklara uygulanan basınç ve açılma yer değiştirme yüklemesi altında yay uzunluğunun gerilme ve genlemeler üzerine etkisini incelemiştir. Elastomerin viskoelastik davranışını temsil eden Moonley-Rivlin modeli kullanılan çalışmada deneysel ve sonlu elemanlar yöntemi kullanılmıştır. Uygulanan kuvvetin artmasıyla genlemelerin arttığı, yay uzunluğunu artmasıyla da gerilmelerin arttığı görülmüştür.

Bayraklılar [13] küresel elastomerik yatakların geometrik parametrelerinin maksimum gerilmeler üzerindeki etkisini incelemiştir. Basınç ve açılma yer değiştirme yükü altındaki en yüksek gerilme, en dıştaki son katmanlarda meydana gelmiştir. Elastomer katmanların şeklini ve kalınlığını değiştirerek tüm katmanlar üzerindeki maksimum gerilmeleri azaltmanın mümkün olduğu görülmüştür. En önemli azalma, delik çapındaki değişikliklerle mümkün olmuştur ve böylece elastomer yatağın ömrünün uzatılabileceği ortaya çıkmıştır.


Bu çalışmada elastomer tabakalar üzerindeki maksimum gerilmeleri tahmin etmede bir tür ANN modeli olan VİGY sinir ağı modeli kullanılmıştır. Çalışmada ayrıca gerilme parametresinin tahmininde ANN, SVM, RF gibi farklı makine öğrenmesi yöntemleri de kullanılmıştır. VİGY sinir ağı modeli elastomer tabakalar üzerindeki maksimum gerilmeleri tahmin etmede diğer makine öğrenmesi yöntemlere göre daha başarılı bulunmuştur.

2. VERİ SETİ (DATA SET)

Elastomerler hiperelastik davranış göstermektedir. Ogden ve Moonley Rivlin bu davranışı temsil eden matematik modeller geliştirmiştir [14, 15]. Hiperelastik malzeme

davranışını simüle eden sınırlı sayıda programlardan biri ABAQUS olduğundan bu çalışmada ABAQUS programı tercih edilmiştir.

Bu çalışma kapsamında küresel elastomerik yatağın mekanik davranışı, sonlu elemanlar yöntemi kullanılarak ABAQUS programıyla simüle edilmiş ve elastomer tabakalarındaki gerilme dağılımı incelenmiştir.



Şekil 1. Elastomerik yatağa kullanılan malzemeler (Materials of elastomeric bearing)

Şekil 1’de küresel elastomerik yatağın kesiti görülmektedir. Elastomerik yatağa metal tabaka olarak çelik, üst ve alt destek elemanı olarak da Ti6Al4V kullanılmıştır. Bu malzemelerin mekanik özellikleri Tablo 1’de gösterilmiştir.

Tablo 1. Elastomerik yatağa kullanılan malzemelerin mekanik özellikleri (Mechanical properties of materials used elastomeric bearing)

Malzeme cinsi	Elastisite modülü	Poisson oranı
Çelik	200 GPa	0,3
Ti6Al4V	115 GPa	0,35


Mooney Rivlin hiperelastik malzeme şekil değiştirme modeli [15];

$$W = C_{10}(I_1 - 3) + C_{01}(I_2 - 3) \quad (1)$$


Eş. 1’deki C_{10} ve C_{01} Mooney-Rivlin malzeme sabitleri, I_1 ve I_2 sırasıyla genleme tensörünün birinci ve ikinci sabitleridir. Karbon siyahıyla güçlendirilmiş kauçuk malzemenin iki eksenli ve tek eksenli test sonuçları Shahzad vd. [16] çalışmalarından alındı. ABAQUS programının hesaplamalarına göre, $C_{10} = 0,155$, $C_{01} = 0,02758$ olarak bulunmuştur.

Elastomer yatağın ölçüleri Şekil 2’de görülmektedir. Burada; a : Küresel elastomerik yatağın aksel yarıçapı (mm), d : Elastomer tabakanın iç çapı (mm), D : Elastomer tabakanın dış çapı (mm), H : Elastomer tabakanın kalınlığı (mm), P : Basınç yüklemesi (N), P_c : Basınç yüklemesinin tabakaya dik bileşeni (N), R : Dış yüzey eğrilik yarıçapı (mm), α :

Delik koniklik açısı ($^\circ$), β : Dış yüzey koniklik açısı ($^\circ$), β_0 , β_1 , β_2 : Bağ (Joint) açıları ($^\circ$), ϕ_p : Basınç yüklemesinin tabakaya dik bileşeni ile basınç yüklemesi arasındaki açı ($^\circ$), ϕ_t : Koni açısı ($^\circ$).



Şekil 2. Elastomerik yatağın ölçülendirilmesi (Dimensioning of the elastomeric bearing)



Şekil 3. Elastomerik yatağa uygulanan basınç ve açılal yer değiştirme yüklemesi (Pressure and angular displacement loading applied to the elastomeric bearing)

Bu çalışmada ilk olarak 20, 30, 40, 50, 60, 70 ve 80 mm delik çaplarına sahip 6 kN kuvvet ve 0,17 radyan açılal yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek delik çapıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 2’de verilmiştir.

Daha sonra 5°, 10°, 15°, 20°, 25°, 30°, 35° dış yüzey koniklik açlarına ve silindirik (0°) dış yüzeye sahip 6 kN kuvvet ve 0,17 radyan açılal yer değiştirme yüklemesi uygulanan

elastomerik yatakların gerilme dağılımı incelenerek dış yüzey koniklik açısıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 3'te verilmiştir.

Daha sonra 500, 450, 400, 350, 300, 250, 200 ve 0 mm dış yüzey eğrilik yarıçaplarına sahip 6 kN kuvvet ve 0,17 radyan açısız yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek dış yüzey eğrilik yarıçapıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 4'te verilmiştir.

Daha sonra 5°, 10°, 15°, 20°, 25°, 30°, 35° delik koniklik açılarında sahip ve silindirik deliğe sahip 6 kN kuvvet ve 0,17 radyan açısız yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek delik koniklik açısıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 5'te verilmiştir.

Daha sonra 1, 1,5, 2, 2,5, 3, 3,5, 4 ve 4,5 mm elastomer tabaka kalınlıklarına sahip 6 kN kuvvet ve 0,17 radyan açısız yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek elastomer tabaka kalınlığıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 6'da verilmiştir.

Daha sonra 14, 15, 16, 17, 18, 19, 20 ve 21 adet elastomer tabakadan oluşan 6 kN kuvvet ve 0,17 radyan açısız yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek elastomer tabaka sayısıyla maksimum gerilmeler arasındaki ilişki belirlenmiştir. Simülasyonda kullanılan elastomerik yatakların geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 7'de verilmiştir.

Son olarak her elastomer katmanında düşük gerilme elde etmek için, büyük bir delik çapı (80mm), silindirik ve kavisli olmayan bir dış yüzey, büyük konik delik açısı (35°), 3mm elastomer katman kalınlığı kullanılması gerektiği yapılan çalışmalarda bulunmuştur. Bu geometrik parametreler elde

Tablo 2. Örnek 1-7'nin geometrik parametreleri ve maksimum gerilme (Geometric parameters of examples 1-7)

	Örnek 1	Örnek 2	Örnek 3	Örnek 4	Örnek 5	Örnek 6	Örnek 7
$a(mm)$	605,5	605,5	605,5	605,5	605,5	605,5	605,5
$\beta_0(^{\circ})$	41,8	41,8	41,8	41,8	41,8	41,8	41,8
$\beta_1(^{\circ})$	37,67	37,67	37,67	37,67	37,67	37,67	37,67
$\beta_2(^{\circ})$	45,92	45,92	45,92	45,92	45,92	45,92	45,92
$\varphi_t(^{\circ})$	41,8	41,8	41,8	41,8	41,8	41,8	41,8
$\varphi_p(^{\circ})$	35,26	35,26	35,26	35,26	35,26	35,26	35,26
$D_{last}(mm)$	150	160	170	180	190	200	210
n_e	18	18	18	18	18	18	18
$d(mm)$	20	30	40	50	60	70	80
$\alpha(^{\circ})$	0	0	0	0	0	0	0
$\beta(^{\circ})$	0	0	0	0	0	0	0
$R(mm)$	0	0	0	0	0	0	0
$H(mm)$	3	3	3	3	3	3	3
$\sigma_{max}(MPa)$	2,431	1,705	1,293	1,042	0,866	0,870	0,754

Tablo 3. Örnek 7-14'ün geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 7-14)

	Örnek 7	Örnek 8	Örnek 9	Örnek 10	Örnek 11	Örnek 12	Örnek 13	Örnek 14
$a(mm)$	605,5	605,5	605,5	605,5	605,5	605,5	605,5	605,5
$\beta_0(^{\circ})$	41,8	41,92	42,15	42,36	42,54	42,71	42,86	43,01
$\beta_1(^{\circ})$	37,67	37,67	37,67	37,67	37,67	37,67	37,67	37,67
$\beta_2(^{\circ})$	45,92	46,49	46,99	47,43	47,82	48,19	48,52	48,84
$\varphi_t(^{\circ})$	41,8	39,34	37,18	35,16	33,23	31,39	29,61	27,87
$\varphi_p(^{\circ})$	35,26	35,26	35,26	35,26	35,26	35,26	35,26	35,26
$D_{last}(mm)$	210	226,56	240,92	253,6	264,96	275,32	284,9	293,9
n_e	18	18	18	18	18	18	18	18
$d(mm)$	80	80	80	80	80	80	80	80
$\alpha(^{\circ})$	0	0	0	0	0	0	0	0
$\beta(^{\circ})$	0	5	10	15	20	25	30	35
$R(mm)$	0	0	0	0	0	0	0	0
$H(mm)$	3	3	3	3	3	3	3	3
$\sigma_{max}(MPa)$	0,754	0,799	0,854	0,903	0,952	0,997	1,055	1,058

Tablo 4. Örnek 14-21'in geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 14-21)

	Örnek 14	Örnek 15	Örnek 16	Örnek 17	Örnek 18	Örnek 19	Örnek 20	Örnek 21
$a(mm)$	605,5	605,5	605,5	605,5	605,5	605,5	605,5	605,5
$\beta_0(^{\circ})$	43,01	42,94	42,93	42,93	42,91	42,9	42,88	42,85
$\beta_1(^{\circ})$	37,67	37,67	37,67	37,67	37,67	37,67	37,67	37,67
$\beta_2(^{\circ})$	48,84	48,71	48,7	48,68	48,66	48,62	48,58	48,51
$\varphi_t(^{\circ})$	27,87	28,62	28,69	28,77	28,89	29,05	29,24	29,57
$\varphi_p(^{\circ})$	35,26	35,26	35,26	35,26	35,26	35,26	35,26	35,26
$D_{last}(mm)$	293,9	293,9	293,9	293,9	293,9	293,9	293,9	293,9
n_e	18	18	18	18	18	18	18	18
$d(mm)$	80	80	80	80	80	80	80	80
$\alpha(^{\circ})$	0	0	0	0	0	0	0	0
$\beta(^{\circ})$	35	35	35	35	35	35	35	35
$R(mm)$	0	500	450	400	350	300	250	200
$H(mm)$	3	3	3	3	3	3	3	3
$\sigma_{max}(MPa)$	1,058	1,072	1,071	1,070	1,074	1,073	1,073	1,082

Tablo 5. Örnek 21-28'in geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 21-28)

	Örnek 21	Örnek 22	Örnek 23	Örnek 24	Örnek 25	Örnek 26	Örnek 27	Örnek 28
$a(mm)$	605,5	605,5	605,5	605,5	605,5	605,5	605,5	605,5
$\beta_0(^{\circ})$	42,85	43,09	43,31	43,51	43,69	43,86	44,03	44,18
$\beta_1(^{\circ})$	37,67	38,12	38,52	38,89	39,23	39,55	39,86	40,15
$\beta_2(^{\circ})$	48,51	48,51	48,51	48,51	48,51	48,51	48,51	48,51
$\varphi_t(^{\circ})$	29,57	26,62	23,84	21,2	18,63	16,13	13,7	11,27
$\varphi_p(^{\circ})$	35,26	36,07	36,81	37,49	38,12	38,73	39,3	39,87
$D_{last}(mm)$	293,9	293,9	293,9	293,9	293,9	293,9	293,9	293,9
n_e	18	18	18	18	18	18	18	18
$d(mm)$	80	80	80	80	80	80	80	80
$\alpha(^{\circ})$	0	5	10	15	20	25	30	35
$\beta(^{\circ})$	35	35	35	35	35	35	35	35
$R(mm)$	200	200	200	200	200	200	200	200
$H(mm)$	3	3	3	3	3	3	3	3
$\sigma_{max}(MPa)$	1,082	1,170	1,128	1,022	0,856	0,819	0,661	0,575

Tablo 6. Örnek 28-35'in geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 28-35)

	Örnek 28	Örnek 29	Örnek 30	Örnek 31	Örnek 32	Örnek 33	Örnek 34	Örnek 35
$a(mm)$	605,5	587,5	592	596,5	601	610	614,5	619
$\beta_0(^{\circ})$	44,18	44,49	44,4	44,32	44,25	44,11	44,06	44,01
$\beta_1(^{\circ})$	40,15	40,31	40,27	40,23	40,19	40,11	40,07	40,04
$\beta_2(^{\circ})$	48,51	49	48,86	48,73	48,61	48,41	48,33	48,26
$\varphi_t(^{\circ})$	11,27	12,99	12,47	12,04	11,6	10,76	10,35	10,03
$\varphi_p(^{\circ})$	39,87	40,16	40,08	40,01	39,94	39,8	39,73	39,67
$D_{last}(mm)$	293,9	246,86	257,78	269,28	281,32	307,04	320,7	334,92
n_e	18	18	18	18	18	18	18	18
$d(mm)$	80	80	80	80	80	80	80	80
$\alpha(^{\circ})$	35	35	35	35	35	35	35	35
$\beta(^{\circ})$	35	35	35	35	35	35	35	35
$R(mm)$	200	200	200	200	200	200	200	200
$H(mm)$	3	1	1,5	2	2,5	3,5	4	4,5
$\sigma_{max}(MPa)$	0,575	0,755	0,647	0,785	0,897	0,988	0,790	0,794

edilen optimum parametrelerdir. Daha önce elde edilen Örnek 7, Örnek 14 ve Örnek 28 ile optimum parametrelere sahip Örnek 43'ün geometrik parametreleri ve elde edilen maksimum gerilmeler Tablo 8'de gösterilmektedir. 6 kN

kuvvet ve 0,17 radyan açılmalık yer değiştirme yüklemeleri uygulanan elastomerik yatakların gerilme dağılımı incelenerek optimum geometride oluşan maksimum gerilmeler belirlenmiştir.

Tablo 7. Örnek 36-42'nin geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 36-42)

	Örnek 28	Örnek 36	Örnek 37	Örnek 38	Örnek 39	Örnek 40	Örnek 41	Örnek 42
$a(mm)$	605,5	597,5	599,5	601,5	603,5	607,5	609,5	611,5
$\beta_0(^{\circ})$	44,18	44,31	44,28	44,25	44,22	44,16	44,13	44,1
$\beta_1(^{\circ})$	40,15	40,22	40,21	40,19	40,17	40,14	40,12	40,1
$\beta_2(^{\circ})$	48,51	48,71	48,66	48,61	48,56	48,47	48,43	48,39
$\varphi_t(^{\circ})$	11,27	11,98	11,8	11,62	11,44	11,1	10,93	10,75
$\varphi_p(^{\circ})$	39,87	39,99	39,96	39,93	39,9	39,84	39,81	39,78
$D_{last}(mm)$	293,9	271,9	277,24	282,68	288,24	299,68	305,54	311,54
n_e	18	14	15	16	17	19	20	21
$d(mm)$	80	80	80	80	80	80	80	80
$\alpha(^{\circ})$	35	35	35	35	35	35	35	35
$\beta(^{\circ})$	35	35	35	35	35	35	35	35
$R(mm)$	200	200	200	200	200	200	200	200
$H(mm)$	3	3	3	3	3	3	3	3
$\sigma_{max}(MPa)$	0,575	0,546	0,543	0,727	0,594	0,606	0,770	0,600

Tablo 8. Örnek 43'ün geometrik parametreleri ve maksimum gerilme (Geometric parameters of example 43)

	Örnek 7	Örnek 14	Örnek 28	Örnek 43
$a(mm)$	605,5	605,5	605,5	605,5
$\beta_0(^{\circ})$	41,8	43,01	44,18	28,41
$\beta_1(^{\circ})$	37,67	37,67	40,15	40,15
$\beta_2(^{\circ})$	45,92	48,84	48,51	45,92
$\varphi_t(^{\circ})$	41,8	27,87	11,27	42,97
$\varphi_p(^{\circ})$	35,26	35,26	39,87	39,87
$D_{last}(mm)$	210	293,9	293,9	210
n_e	18	18	18	18
$\varphi(mm)$	80	80	80	80
$\alpha(^{\circ})$	0	0	35	35
$\beta(^{\circ})$	0	35	35	0
$R(mm)$	0	0	200	0
$H(mm)$	3	3	3	3
$\sigma_{max}(MPa)$	0,709	0,729	0,575	0,250

3. YÖNTEM (METHOD)

3.1. Veri işleme grup yöntemi

(Group method of data handling (GMDH))

Son yıllarda, birçok mühendislik dalları ve benzer alanlarda bilgisayarlı hesaplamalarda yapay zeka uygulamaları ilk sırayı aldığını söylemek mümkündür [17-21]. Veri işleme grup yöntemi (VİGY) yapay zeka uygulamaları için kullanılan yöntemlerden biridir. VİGY sinir ağı modeli, bir dizi çoklu-giriş tek-çıkış veri çiftleri üzerindeki performanslarının değerlendirilmesine dayanarak oluşturulan, kendi kendini organize eden derin öğrenme metodu olarak bilinmektedir [22]. Veri madenciliği, optimizasyon ve görüntü tanıma gibi birçok alanda yaygın olarak kullanılmaktadır. VİGY sinir ağı, polinomial sinir ağı modelleri olarak bilinmektedir. Standart regresyon yöntemlerinde bulunan eşitlik karmaşıklığı ve doğrusal bağımlılık gibi problemlerin üstesinden gelmek için VİGY Ivakhnenko (1968) tarafından önerilmiştir. VİGY sinir ağının; eğitim sürecinde kendiliğinden organizasyon, öngörmede yüksek doğruluk, yüksek dereceli doğrusal olmayan sistemler için iyi tanımlama gibi avantajları

bulunmaktadır. VİGY sinir ağı modelin temel mantığı ileri beslemeli sinir ağlarında ağırlıkları regresyon tabanlı elde edilmesini sağlayan analitik bir fonksiyon kullanılmaktadır. Çoklu giriş tekli çıkış veriler göz önüne alındığında aralarındaki fonksiyon Eş. 2 gibi ifade edilir [23].

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, 3, \dots, M) \quad (2)$$

Burada $X = (X_1, X_2, X_3, \dots, X_n)$ girdi vektörünü, ve y_i ise çıktı değişkenini belirtmektedir. Tahmin eşitliği aşağıdaki gibi yazılabilir (Eş. 3) [24].

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (i = 1, 2, 3, \dots, M) \quad (3)$$

VİGY ağında amaç gerçek çıktı değerleri ile tahmin edilen değerler arasındaki farkın minimum olmasıdır.

$$\sum_{i=1}^M [f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow \text{Minimum} \quad (4)$$

Giriş ve çıkış değişkenleri arasındaki bağlantı, aşağıdaki gibi bir seri olan Volterra fonksiyonunun karmaşık bir biçimi ile ifade edilebilir [25]:

$$y = w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n w_{ijk} x_i x_j x_k + \dots, \quad (5)$$

Eş. 5 Kolmogorov-Gabor polinomu olarak bilinir.

VİGY sinir ağında bir katmandaki nöronlar kuadratik ve trikuadratik polinom yoluyla bir sonraki katmana bağlanarak sonraki katmanda yeni nöronlar oluşturulmaktadır. Bu çalışmada, bu şekilde yazılan VİGY sinir ağının ikinci dereceden polinomu kullanılmıştır: Bu fonksiyon aşağıdaki gibi yazılmaktadır [26].

$$Quadratic: \hat{y} = G(x_i, x_j) = w_0 + w_1 x_i + w_2 x_j + w_3 x_i x_j + w_4 x_i^2 + w_5 x_j^2 \quad (6)$$

Eş. 6'da ağırlıklar regresyon yöntemleri ile hesaplanmaktadır. Her giriş vektörü çifti (öznitelikler) bir ikinci kuadratik regresyon polinom eşitliği oluşturacaktır. İlk katman için L (L = m(m-1) / 2) kadar regresyon polinom eşitliği elde edilir. Bu eşitlikler kullanılarak 1.katmandan sonraki katman için yeni değişkenler elde edilmektedir. Dolayısıyla giriş değişkenlerinden çıkış değişkenini en iyi şekilde açıklayan yeni değişkenler üretilmektedir. VİGY sinir ağı modelinde belli bir katmandaki hata değeri bir önceki katmandaki hata değerinden küçük olması beklenir. Şekil 4'te VİGY sinir ağı mimarisi verilmiştir.

Her giriş veri çifti bir regresyon eşitliği oluşturur. Regresyon eşitliklerinin çıktıları, bir sonraki katmana yeni girdiler oluşturur. Son çıktı, tüm katmanlardan seçilen regresyon eşitliklerinde oluşur.

Bağımsız y değişkenini en küçük kareler yöntemi ile en iyi tahmin edecek Eşitlik 5'deki polinomial regresyon eşitliğini oluşturmak için n adet girdi değişkenlerin olası tüm ikili kombinasyonları kullanılarak VİGY ağı oluşturulur. Gözlenen $\{(y_i, x_{ip}, x_{iq}), (i = 1,2,3, \dots, M)\}$ örneklerden VİGY sinir ağın ilk katmanını n(n-1)/2 adet kuadratik polinom nöronları kullanılarak oluşturulur.

$$\begin{bmatrix} x_{1p} & x_{1q} & y_1 \\ x_{2p} & x_{2q} & y_2 \\ x_{mp} & x_{mq} & y_m \end{bmatrix} \quad (7)$$

Yukarıdaki belirtilen giriş-çıkış değişkenlerini kullanarak Eşitlik 5 matris formunda Eş. 8 gibi yazılabilir.

$$AW = Y \quad (8)$$

Burada W, kuadratik polinomun bilinmeyen ağırlık katsayılarının vektörüdür [27].

$$W = \{w_0, w_1, w_2, w_3, w_4, w_5\}^T \quad (9)$$

Y ise çıkış vektörüdür.

$$Y = \{y_1, y_2, y_3, y_4, y_5, \dots, y_M\}^T \quad (10)$$

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{mp} & x_{mq} & x_{mp}x_{mq} & x_{mp}^2 & x_{mq}^2 \end{bmatrix} \quad (11)$$

Ağırlıklar çoklu regresyon eşitliği kullanılarak matris formunda Eş. 12 gibi çözülür.

$$W = (A^T A)^{-1} A^T Y \quad (12)$$

Burada W tahmin edilecek ağırlık vektörü, A giriş matrisi ve Y ise çıkış vektörünü belirtir.

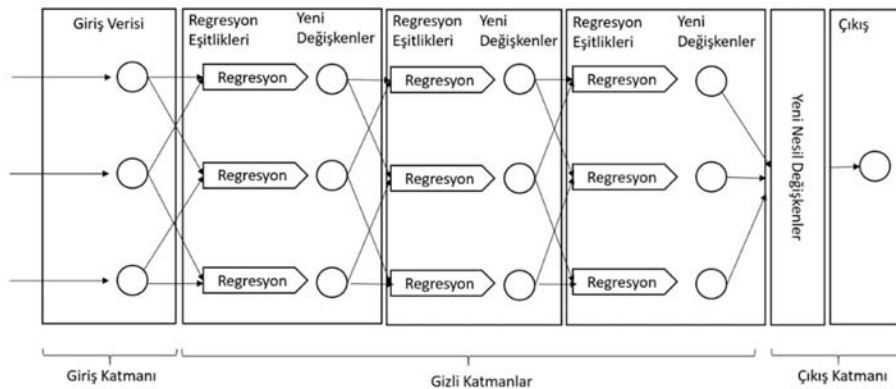
VİGY sinir ağı algoritmasına ait akış şeması Şekil 5'te gösterilmiştir.

3.2. Performans Ölçütleri (Performance Criteria)

Bu çalışmada VİGY ve diğer modellerin performansları test etmek için hata kareler ortalaması (MSE), hata kareler ortalaması karekökü (RMSE) ve korelasyon katsayısı (R) gibi istatistiksel ölçütler kullanılmıştır. Bu ölçütler Eş. 13, 14 ve 15 ile tanımlanır [28].

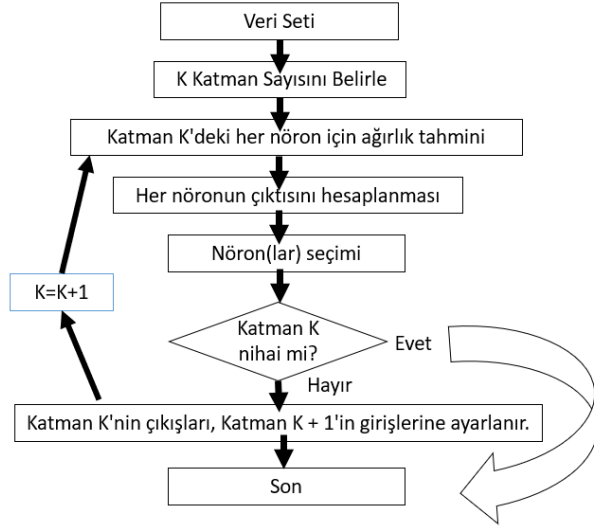
$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2 \quad (13)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2} \quad (14)$$



Şekil 4. VİGY sinir ağı mimari Yapısı (Architectural structure of the GMDH network)

$$R = \sqrt{\frac{\sum_{i=1}^N (Y_i - \bar{Y})^2 - \sum_{i=1}^N (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (15)$$



Şekil 5. VİGY algoritmasının akış şeması
(Flow chart of GMDH algorithm)

Burada Y_i , σ parametresinin gerçek değeridir. \bar{Y} ise bu parametrelerin ortalama değerlerini, \hat{Y}_i tahmin edilen σ değerlerini, N toplam gözlem sayısını belirtir. RMSE, MSE pozitif değerler olup bu istatistik ölçütlerin küçük olması tercih edilir. Sıfıra yakın değerler modellerin σ parametresini gerçeğe yakın tahmin ettiğini belirtir. R ölçütü ise gerçek σ parametre değerleri ile modellerin bu parametreler için tahmin ettiği değerler arasındaki ilişkiyi belirtir. Modellerin başarısı için R 'nin 1'e yakın olması beklenir.


4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Bu çalışmada σ 'nın tahmininde VİGY makine öğrenmesi metodu kullanılmıştır. σ parametresinin tahmininde θ , P , a , β_0 , $\cos(\beta_0)$, β_1 , β_2 , φ_t , φ_p , $\cos(\varphi_p)$, D , n_e , d ve H değişkenleri kullanılmıştır. Veri seti 770 örnekten oluşmaktadır. Veri seti öncelikle %70 eğitim ve %30 test şeklinde kullanılmıştır. Veri seti kullanılmadan önce normalize edilmiştir. VİGY sinir ağı modeli farklı sayıda katmandan, her katmanda farklı sayıda nöron ile inşa edilmiş mimarilerde kullanılabilir. Bu çalışmada farklı VİGY sinir ağı mimarileri ile analizler gerçekleştirilmiştir. Farklı sayıda gizli katman ile gerçekleştirilen analizler sonucunda elde edilen R , RMSE ve MSE performans ölçütleri Tablo 9'da verilmiştir. Gizli katman sayısı arttıkça hesaplama maliyeti arttığından dolayı en fazla 7 katmana kadar denemeler gerçekleştirilmiştir.

Tablo 9'a bakıldığında gizli katman sayısı %5'e kadar arttığında başarımın arttığı görülmektedir. Buna bağlı olarak RMSE ve MSE hata değerlerin azaldığı ve R belirleme katsayısının arttığı görülmüştür. Ancak gizli katman sayısının 5'ten büyük olması durumunda performans oranlarının düştüğü görülmüştür. En iyi performanslar gizli katman sayısının 5 olması durumunda elde edildiği görülmektedir. Gizli katman sayısının 5 olması durumunda eğitim seti için MSE = 0,015, RMSE = 0,125 ve $R = 92,30$ olduğu görülmektedir. Aynı mimari için test veri seti için MSE = 0,015, RMSE = 0,122 ve $R = 94,83$ elde edilmiştir. Şekil 6'da σ (N/mm^2) parametresine ait gerçek değerler ile tahmin değerleri arasındaki regresyon eşitlikleri verilmiştir. Regresyon eğrileri eğitim, test ve tüm veri setleri için oluşturulmuştur. Eğitim seti belirleme katsayısı $R = 0,9230$,

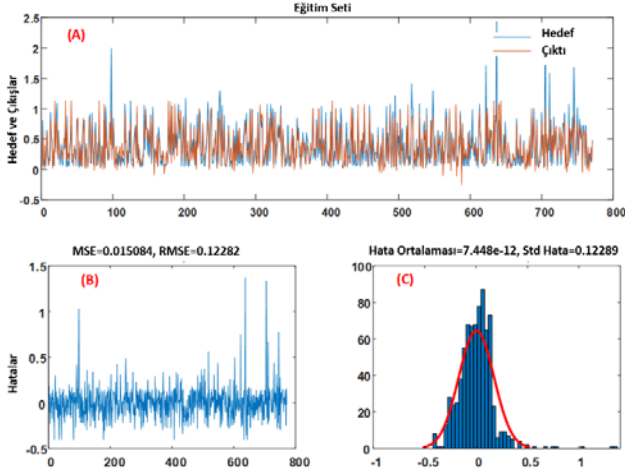
Tablo 9. Farklı sayıda gizli katman ile gerçekleştirilen denemelerin performans ölçütleri
(Performans measures for different number of hidden layers)

#Katman	Eğitim			Test		
	MSE	RMSE	R	MSE	RMSE	R
2	0,019	0,140	90,99	0,022	0,148	91,24
3	0,016	0,126	93,02	0,017	0,130	92,32
4	0,014	0,120	93,94	0,015	0,123	92,17
5	0,015	0,125	92,30	0,015	0,122	94,83
6	0,016	0,127	93,42	0,014	0,124	91,48
7	0,014	0,119	94,29	0,014	0,123	91,79



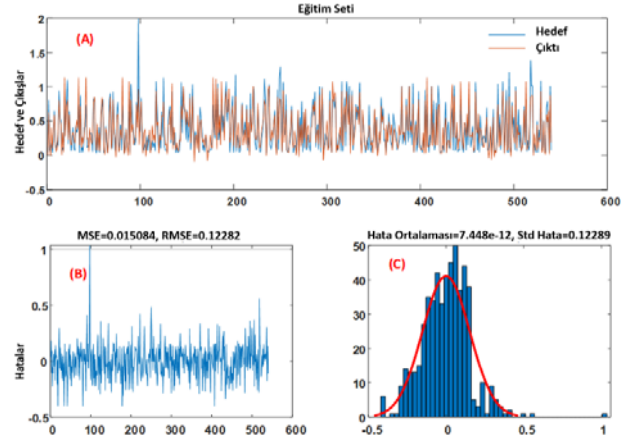
Şekil 6. Belirleme katsayısı performans değerleri (Determination coefficient performance values)

test seti için $R = 0,9483$ ve tüm veri seti için $R = 0,93319$ olarak elde edilmiştir. Şekil 7, Şekil 8 ve Şekil 9’da ise σ parametresi gerçek değerler ile tahmin edilen değerlere ait dağılım grafikleri, hata dağılımı ve hata dağılım histogramları verilmiştir. Eğitim, test ve tüm veri setine ait dağılımlara bakıldığında σ parametresini tahmin etmede VİGY sinir ağı modelin başarılı sonuçlar ürettiği görülmektedir.

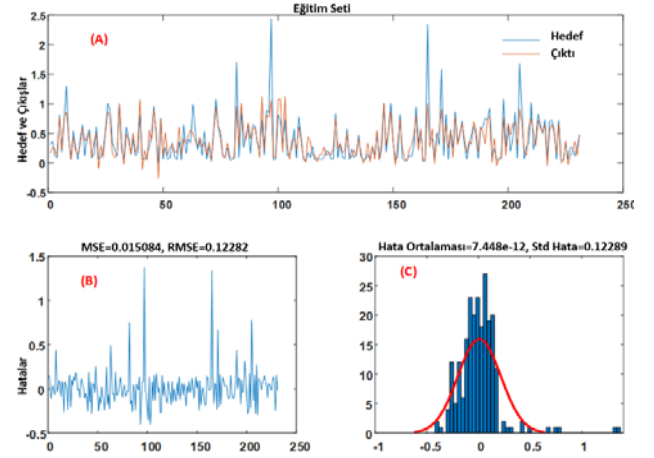


Şekil 7. (A) Tüm veri seti için σ gerçek değerler ve tahmin edilen değerler, (B) hata değerleri ve (C) hata histogramı ((A) σ actual values and estimated values, (B) error values and (C) error histogram for the whole data set)

Bu çalışmada farklı mimarilerde VİGY sinir ağı modelleri kullanılmıştır. Katmanlarda farklı sayıda nöron kullanılarak denemeler gerçekleştirilmiştir. Gizli katmanlarda farklı sayıda nöron sayısı kullanılarak elde edilen başarı oranları Tablo 10’da verilmiştir. Gizli katmanda 1-10 arasında farklı sayılarda nöron sayıları ile denemeler gerçekleştirilmiştir. Tablo 10’daki sonuçlara bakıldığında hem eğitim hem test veri setleri için başarının genel olarak nöron sayısına bağlı artış gösterdiği görülmektedir.



Şekil 8. (A) Eğitim veri seti için σ gerçek değerler ve tahmin edilen değerler, hata değerleri ve hata histogramı (σ actual values and estimated values, error values and error histogram for the training data set)



Şekil 9. (A) Test veri seti için σ gerçek değerler ve tahmin edilen değerler, (B) hata değerleri ve (C) hata histogramı ((A) For the test data set, σ actual values and estimated values, (B) error values and (C) error histogram)

Tablo 10. Farklı Topolojideki VİGY sinir ağı modelleri için performanslar (Performances for GMDH models in different Topology)

#Nöron	Eğitim			Test		
	MSE	RMSE	R	MSE	RMSE	R
1	0,048	0,219	76,64	0,048	0,219	76,34
2	0,020	0,140	91,68	0,023	0,151	87,73
3	0,020	0,140	90,53	0,018	0,140	92,88
4	0,017	0,130	92,15	0,016	0,130	93,10
5	0,015	0,122	93,26	0,015	0,125	93,30
6	0,016	0,127	92,68	0,013	0,115	94,50
7	0,016	0,126	93,17	0,015	0,125	92,47
8	0,013	0,112	94,74	0,012	0,108	94,03
9	0,015	0,123	93,47	0,015	0,123	92,66
10	0,015	0,125	92,30	0,015	0,122	94,83

Tablo 10'a bakıldığında en yüksek başarı oranının gizli katmanlarda 10 nöron bulunması ile elde edildiği görülmektedir. En yüksek başarımın gözlemlendiği 5 katmanlı ve her katmanda 10 nöron bulunan VİGY modeli ile elde edilen polinom eşitlikleri aşağıda verilmiştir. Ayrıca Şekil 10'da σ (N/mm²) parametresinin tahmini için kullanılan VİGY sinir ağı verilmiştir. Şekil 10'a bakıldığında VİGY sinir ağı modeli σ (N/mm²) tahmini için en etkili öznelikleri seçmiştir. Tahminler P (N/mm²), β_1 (°), β_2 (°), φ_1 (°), φ_p (°), $\cos(\varphi_p)$ ve D (mm) değişkenleri ile gerçekleştirilmiştir. Θ (°), a (mm), β_0 (°), $\cos(\beta_0)$, n_c , φ_{son} (mm) ve H (mm) değişkenleri hiçbir şekilde kullanılmamıştır. Bu değişkenler modele dâhil edilmeyen etkisiz değişkenler olarak gözlenmiştir. En etkin değişkenler ise polinom eşitliklerinde en çok kullanılan X_9 (φ_p (°)) ve X_{10} ($\cos(\varphi_p)$) değişkenler olduğu görülmektedir. Etkili değişkenlerin oluşturdukları ikili kombinasyonlar aşağıdaki gibidir.

$$\{X_2, X_9\}, \{X_2, X_{10}\}, \{X_8, X_{10}\}, \{X_{10}, X_{11}\}, \{X_7, X_{10}\}, \{X_9, X_{11}\}, \{X_8, X_9\}, \{X_6, X_9\}, \{X_7, X_9\} \text{ ve } \{X_6, X_{10}\}$$

Bu değişkenler kullanılarak elde edilen polinom fonksiyonlar aşağıda verilmiştir. Bu eşitliklere ait ağırlıklar en küçük hata kareler yöntemi ile tahmin edilmiştir.

Buradan aşağıdaki polinom eşitlikleri yazılabilir (Eş. 16-Eş. 46).

Gizli Katman 1 için Polinom Eşitlikler;

$$A_1 = 0,0413 + 0,5775x_2 + 0,0229x_9 + 0,0131x_2x_9 + 7,6272e - 04x_2^2 - 0,0231x_9^2 \quad (16)$$

$$A_2 = 0,0124 - 1,8156x_2 + 10,4853x_{10} + 0,0128x_2x_{10} - 10,1272x_2^2 + 1,9294x_{10}^2 \quad (17)$$

$$A_3 = 0,0034 + 0,0856x_8 - 21,3469x_{10} - 0,0003x_8x_{10} + 28,2386x_8^2 - 0,1061x_{10}^2 \quad (18)$$

$$A_4 = 0,0075 - 29,7310x_{10} + 0,0524x_{11} + 40,2413x_{10}x_{11} + 3,1668e - 05x_{10}^2 - 0,0820x_{11}^2 \quad (19)$$

$$A_5 = 0,0034 - 1,3941x_7 + 60,5350x_{10} + 0,0344x_7x_{10} + 40,4556x_7^2 - 2,2365x_{10}^2 \quad (20)$$

$$A_6 = 0,0449 + 0,3737x_9 - 0,0355x_{11} - 0,0086x_9x_{11} + 3,5127e - 05x_9^2 + 0,0006x_{11}^2 \quad (21)$$

$$A_7 = 0,0171 + 0,0375x_8 + 0,2186x_9 - 0,0004x_8x_9 - 0,0054x_8^2 - 0,0007x_9^2 \quad (22)$$

$$A_8 = -0,0040 - 6,7140x_6 + 6,8171x_9 + 0,2229x_6x_9 + 0,0393x_6^2 - 0,2647x_9^2 \quad (23)$$

$$A_9 = 0,0072 + 1,1445x_7 - 1,3300x_9 - 0,0141x_7x_9 + 0,0104x_7^2 + 0,0074x_9^2 \quad (24)$$

$$A_{10} = 0,0036 + 3,5121x_6 - 201,9609x_{10} - 0,0754x_6x_{10} + 63,9699x_6^2 + 3,1864x_{10}^2 \quad (25)$$

Gizli Katman 2 için Polinom Eşitlikler;

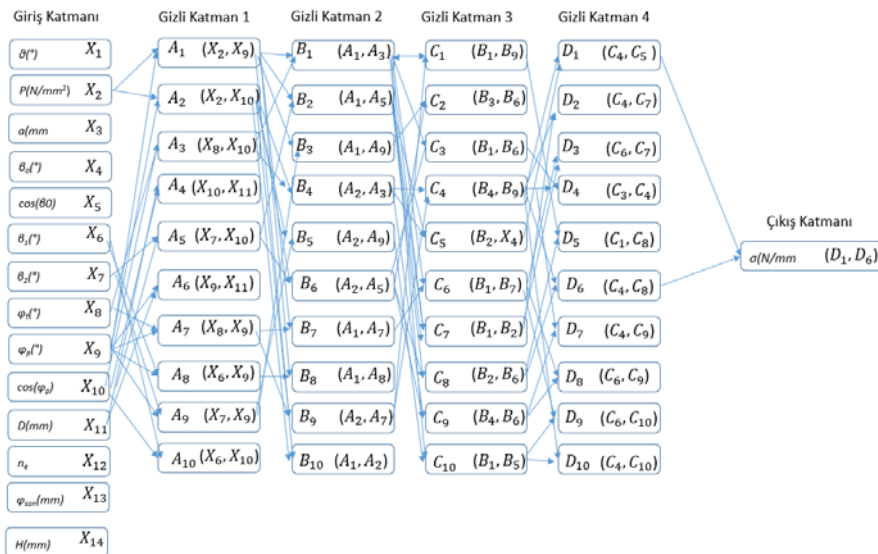
$$B_1 = 0,1025 - 0,0843A_1 + 0,2526A_3 - 0,6649A_1A_3 - 2,5564A_1^2 + 4,2664A_3^2 \quad (26)$$

$$B_2 = 0,0586 - 0,0479A_1 + 0,4537A_5 + 0,7323A_1A_5 - 0,4879A_1^2 + 0,4718A_5^2 \quad (27)$$

$$B_3 = 0,0547 - 0,0685A_1 + 0,5165A_9 + 0,3309A_1A_9 - 1,2164A_1^2 + 1,5919A_9^2 \quad (28)$$

$$B_4 = 0,1062 - 0,1328A_2 + 0,2745A_3 - 0,6897A_2A_3 - 2,7939A_2^2 + 4,5537A_3^2 \quad (29)$$

$$B_5 = 0,0557 - 0,1201A_2 + 0,5427A_9 + 0,4889A_2A_9 - 1,2046A_2^2 + 1,4495A_9^2 \quad (30)$$



Şekil 10. 5 katmanlı VİGY sinir ağı için oluşturulan ikili değişkenler (Paired variables created for the 5-layer GMDH network)

$$B_6 = 0,0589 - 0,0928A_2 + 0,4667A_5 + 0,9525A_2A_5 - 0,3671A_2^2 + 0,1688A_5^2 \quad (31)$$

$$B_7 = 0,1014 - 0,0251A_1 + 0,2239A_7 - 0,4066A_1A_7 - 2,0829A_1^2 + 3,4627A_7^2 \quad (32)$$

$$B_8 = 0,0789 - 0,0363A_1 + 0,3658A_8 + 0,0700A_1A_8 - 1,0845A_1^2 + 1,8271A_8^2 \quad (33)$$

$$B_9 = 0,1051 - 0,0638A_2 + 0,2378A_7 - 0,3886A_2A_7 - 2,2442A_2^2 + 3,6267A_7^2 \quad (24)$$

$$B_{10} = 0,0862 + 0,7817A_1 - 0,4935A_2 + 0,0296A_1A_2 - 1,2810A_1^2 + 2,0314A_2^2 \quad (25)$$

Gizli Katman 3 için Polinom Eşitlikler;

$$C_1 = -0,0090 + 1,5115B_1 - 0,4436B_9 - 25,3125B_1B_9 - 27,3105B_1^2 + 52,5925B_9^2 \quad (26)$$

$$C_2 = -0,0189 - 0,9939B_3 + 2,1412B_6 - 5,2830B_3B_6 - 8,7049B_3^2 + 13,8506B_6^2 \quad (27)$$

$$C_3 = 0,0036 - 0,0491B_1 + 1,0560B_6 - 1,4270B_1B_6 - 2,9781B_1^2 + 4,3955B_6^2 \quad (28)$$

$$C_4 = -0,0043 - 1,6885B_4 + 2,7235B_9 - 22,1196B_4B_9 - 27,4055B_4^2 + 49,4985B_9^2 \quad (29)$$

$$C_5 = 0,0121 + 1,5836B_2 - 0,7180B_4 + 6,3204B_2B_4 + 8,5391B_2^2 - 14,7590B_4^2 \quad (30)$$

$$C_6 = -0,0029 - 0,9277B_1 + 1,9564B_7 - 49,6591B_1B_7 - 53,9006B_1^2 + 103,5517B_7^2 \quad (31)$$

$$C_7 = 0,0080 - 0,2347B_1 + 1,1761B_2 + 2,8271B_1B_2 + 1,2999B_1^2 - 4,0854B_2^2 \quad (32)$$

$$C_8 = -0,0249 + 0,9029B_2 + 0,2602B_6 + 0,6981B_2B_6 - 2,1223B_2^2 + 1,2686B_6^2 \quad (33)$$

$$C_9 = 0,0049 - 0,3304B_4 + 1,2896B_6 + 3,3555B_4B_6 + 1,4756B_4^2 - 4,8120B_6^2 \quad (34)$$

$$C_{10} = 0,0111 + 0,5691B_1 + 0,4014B_5 - 5,2148B_1B_5 - 6,5481B_1^2 + 11,7872B_5^2 \quad (35)$$

Gizli Katman 4 için Polinom Eşitlikler;

$$D_1 = -0,0167 - 0,5294C_4 + 1,6457C_5 - 2,7343C_4C_5 - 3,9987C_4^2 + 6,6594C_5^2 \quad (36)$$

$$D_2 = -0,0148 - 0,3932C_4 + 1,4783C_7 - 0,9920C_4C_7 - 2,2619C_4^2 + 3,1953C_7^2 \quad (37)$$

$$D_3 = -0,0162 - 0,3338C_6 + 1,4241C_7 - 0,6867C_6C_7 - 2,1015C_6^2 + 2,7231C_7^2 \quad (38)$$

$$D_4 = -0,0153 + 1,5698C_3 - 0,5047C_4 + 2,8581C_3C_4 + 5,1645C_3^2 - 8,0819C_4^2 \quad (39)$$

$$D_5 = -0,0010 + 0,0793C_1 + 0,9230C_8 + 1,1792C_1C_8 + 0,1156C_1^2 - 1,3049C_8^2 \quad (40)$$

$$D_6 = 0,0094 - 0,5106C_4 + 1,4414C_8 + 3,7883C_4C_8 + 2,0554C_4^2 - 5,8183C_8^2 \quad (41)$$

$$D_7 = -0,0099 - 0,1346C_4 + 1,1984C_9 - 1,1521C_4C_9 - 2,3170C_4^2 + 3,4225C_9^2 \quad (42)$$

$$D_8 = -0,0114 - 0,0438C_6 + 1,1113C_9 - 0,5924C_6C_9 - 1,8451C_6^2 + 2,3871C_9^2 \quad (43)$$

$$D_9 = -0,0142 - 0,0903C_6 + 1,1555C_{10} + 4,0800C_6C_{10} + 1,8978C_6^2 - 6,0380C_{10}^2 \quad (44)$$

$$D_{10} = -0,0147 - 0,2989C_4 + 1,3693C_{10} + 2,5514C_4C_{10} + 0,6616C_4^2 - 3,2725C_{10}^2 \quad (45)$$

Çıkış Katmanı için Polinom Eşitlikler;

$$Output = 0,0013 + 0,1775F_1 + 0,8110F_6 + 0,2209F_1F_6 - 0,3470F_1^2 + 0,1384F_6^2 \quad (46)$$

VİGY sinir ağı modelin diğer modellere göre etkinliğini test etmek için σ parametresinin tahmininde farklı makine öğrenmesi yöntemler de kullanılmıştır. Veri setinin %70-30 eğitim-test oranları için Çoklu doğrusal regresyon (Multiple Linear Regression,MLR), Yapay Sinir ağları (Artificial Neural Network, ANN), Karar Destek Vektörleri (Support Vector Machine, SVM), Radyal Tabanlı sinir ağı (Radial Basis Function, RBF) Regresyon tabanlı en yakın k komşu yöntemi (Regressor, Instance Based 1 nearest neighbour, IBk), Rastgele Ağaç (RandomTree,RT) makine öğrenmesi yöntemleri test edilmiştir. Test için elde edilen MSE, RMSE ve R değerleri Tablo 11’de verilmiştir.

Tablo 11. Farklı Makine Öğrenmesi Yöntemlere ait sonuçlar (Results of Different Machine Learning Methods)

Model	MSE	RMSE	R
MLR	0,038	0,7191	0,8608
ANN	0,014	0,1995	0,9434
SVM	0,041	1,0194	0,8579
RBFRegressor	0,033	0,5871	0,9260
IBk	0,019	0,1979	0,9408
RandomTree	0,014	0,1999	0,9428
GMDH	0,015	0,1220	0,9483

Tablo 11’e bakıldığında VİGY sinir ağı modelin test edilen diğer makine öğrenmesi yöntemlere göre daha başarılı sonuçlar gözlenmiştir. Diğer yöntemlerden en başarılı ANN ve RBF Regressor yöntemlerin olduğu görülmektedir. ANN, RBF Regressor ve VİGY yöntemleri yapay sinir ağları modelleridir. Genel olarak yapay sinir ağları modelleri σ parametresinin tahmininde daha başarılı modeller olmuştur. Tablo 12’de elastomer gerilmelerin tahmin edilmesinde kullanılan makine öğrenmesi ile ilgili çalışmalar verilmiştir.

Tablo 12. Literatür ile Karşılaştırılması (Comparison with the Literature)

Yazar(lar)	Model	Veriseti	Doğruluk
Khan vd. [29] (2019)	-derin öğrenme sinir ağı -Convolutional Neural Network (CNN)	-Kompozit laminatlar	-90,01%
Yang vd. [30] (2019)	-tekrarlayan sinir ağı (RNN)	-Manyetoreolojik elastomer izolatörü (MRE)	-99,40%
Vatandoost vd. [31] (2019)	-yapay sinir ağı (YSA)	-Manyetoreolojik elastomer izolatörü (MRE)	-97%
Yu vd. [32] (2015)	-yapay sinir ağı (YSA) -karınca kolonisi algoritması	-Düzlemsel elastomerik yatak	-99,87%
Vatandoost vd. [33] (2017)	-phenomenological model	-Manyetoreolojik elastomer izolatörü (MRE)	Yazarlar; önerilen model, MRE'nin dinamik davranışını, eğitim deneysel veri seti aralığı dışında bile tahmin edebilir ve yine de uygunluk değerinin ortalaması% 79,11 olan makul bir% 64,33 ile% 93,19 arasında makul bir doğruluk elde edebilir.
Bu çalışma	- VİGY sinir ağı modeli	-Küresel elastomerik yatak	-R= 94,83%

Literatüre bakıldığında bu çalışmada önerilen VİGY sinir ağı modelin maksimum gerilmeleri tahmin etmede tatmin edici sonuçlar verdiği anlaşılmaktadır.

5. SONUÇLAR (CONCLUSIONS)

Bu çalışma elastomer tabakalar üzerindeki maksimum gerilmeler için, basınç yüklemesi ve açısal yer değiştirme yüklemesine maruz küresel elastomerik yatağın, delik çapı, delik şekli, elastomer tabaka kalınlığı, tabaka sayısı ve elastomer yatak profili ile bir tahmin modeli geliştirmek için VİGY sinir ağı modeli kullanılmıştır. VİGY sinir ağı modeli doğrusal olmayan bir regresyon yöntemidir, ancak denetimli ve denetimsiz yapay sinir ağlarının (YSA) özelliklerini taşıyan bir modeldir. Veri seti 770 örnekten oluşmaktadır. Veri seti öncelikle %70 eğitim ve %30 test şeklinde kullanılmıştır. VİGY sinir ağı modelin maksimum gerilme parametresinin tahminindeki başarısını göstermek için aynı veri seti için farklı makine öğrenmesi yöntemler de kullanılmıştır. Modellerde girdi olarak θ (açısal yer değiştirme yüklemesi), P (basınç yüklemesi), a (eksen yarıçapı), β_0 (birinci joint açısı), $\cos(\beta_0)$ (birinci joint açısının cosinus değeri), β_1 (ikinci joint açısı), β_2 (üçüncü joint açısı), φ_1 (koni açısı), φ_p (basınç yüklemesinin doğrultusuyla elastomer tabakaya dik düzlem arasındaki açı), $\cos(\varphi_p)$, D (elastomer tabaka dış çapı), n_c (elastomer tabaka sayısı), d (elastomer tabaka delik çapı) ve H (elastomer tabaka kalınlığı) değişkenleri kullanılmıştır. VİGY sinir ağı modelinin en iyi tahmin performansı, her bir gizli tabakada maksimum 10 nöron bulunan 5 katmanlı

mimari ile elde edilmiştir ($R = 94,83$, $MSE = 0,015$ ve $RMSE = 0,122$) (Tablo 9). VİGY sinir ağı modelin maksimum gerilmelerin tahmin edilmesinde diğer modellere göre daha başarılı bulunmuştur (Tablo 11). VİGY sinir ağı modeli ile maksimum gerilme parametresinin tahmininde etkili değişkenler belirlenmiştir. Tahminler P (N/mm²), β_1 (°), β_2 (°), φ_t (°), φ_p (°), $\cos(\varphi_p)$ ve D (mm) değişkenleri ile gerçekleştirilmiştir. Θ (°), a (mm), β_0 (°), $\cos(\beta_0)$, n_c , φ_{son} (mm) ve H (mm) değişkenleri hiçbir şekilde kullanılmamıştır. Sonuç olarak maksimum gerilme parametresinin tahmininde VİGY sinir ağı modeli başarılı bulunmuştur.

KAYNAKLAR (REFERENCES)

1. Kuncan, M., Kaplan, K., Minaz, M. R., Kaya, Y., & Ertunç, H. M., A novel feature extraction method for bearing fault classification with one dimensional ternary patterns. ISA transactions, 2019.
2. Kaya, Y., Kuncan, M., Kaplan, K., Minaz, M. R., & Ertunç, H. M., Classification of bearing vibration speeds under 1D-LBP based on eight local directional filters. Soft Computing, 1-12, 2020.
3. Kaplan, K., Kaya, Y., Kuncan, M., Minaz, M. R., & Ertunç, H. M., An improved feature extraction method using texture analysis with LBP for bearing fault diagnosis. Applied Soft Computing, 87, 106019, 2020
4. Kaya, Y., Kuncan, M., Kaplan, K., Minaz, M. R., & Ertunç, H. M., A new feature extraction approach based on one dimensional gray level co-occurrence matrices

- for bearing fault classification. *Journal of Experimental & Theoretical Artificial Intelligence*, 1-18, 2020.
5. Panda, B., Mychalowycz, E., & Tarzanin, F. J., Application of Passive Dampers to Modern Helicopters. *Smart Materials and Structures*, 5 (5), 509, 1996.
 6. Roeder, C. W., Stanton, J. F., & Taylor, A. W., Fatigue of Steel-Reinforced Elastomeric Bearings. *Journal of Structural Engineering*, 116 (2), 407-426, 1990.
 7. Naghshineh A. K., Experimental Studies on Fiber-Mesh Reinforced Elastomeric Bearings, PhD Thesis, Middle East Technical University, Civil Engineering, Ankara, 2013.
 8. Domaniç K. A., Seismic Performance of Unbonded Elastomeric Bearings on Bridges: An Experimental and Parametric Study, PhD Thesis, Middle East Technical University, Civil Engineering, Ankara, 2015.
 9. Ruano P. C., Strauss A., An Experimental Study on Unbonded Circular Fiber Reinforced Elastomeric Bearings, *Eng. Struct.*, 177, 72-84, 2018.
 10. Chen G.-S., Zhang L. H., Li F.P., Qin H.Y., Li M. F., Finite Element Analysis for the Influence of Spherical Layered Elastomeric Bearing Structure on the Mechanical Behavior, *Cailiao Gongcheng/Journal Mater. Eng.*, 10, 005, 2009
 11. Su H., Ren J. X., Xue M. Y., Tong Y., Zheng Q., Yang J. X., Influence of Pressure and Deflection Loads on the Critical Behavior of Flexible Joints, *Compos. Struct.*, 180, 772-781, 2017.
 12. Ren J., Zhang X., Yang J., Wang C., Liu Y., Yang W., Structural Analysis and Testing of a Miniature Flexible Joint under Pressure and Vector Loading, *J. Mech. Sci. Technol.*, 28 (9), 3637-3643, 2014.
 13. Bayraklılar M. S., Helikopterlerde Kullanılan Küresel Elastomerik Yatakların Mekanik Tasarımı, PhD Thesis, Kocaeli University, Kocaeli, 2019.
 14. Ogden R., Large Deformation Isotropic Elasticity-on the Correlation of Theory and Experiment for Incompressible Rubberlike Solids, *Proc. R. Soc. London. Ser. A*, 326 (1567), 565-584, 1972.
 15. Mooney M., A Theory of Large Elastic Deformation, *J. Appl. Phys.*, 11 (9), 582-592, 1940.
 16. Shahzad M., Kamran A., Siddiqui M. Z., Farhan M., Mechanical Characterization and FE Modelling of a Hyperelastic Material, *Mater. Res.*, 18 (5), 918-924, 2015.
 17. Dere M., Filiz İ.H., Experimental investigation of the effects of workpiece diameter and overhang length on the surface roughness in turning of free machining steel and modelling of surface roughness by using ANFIS, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (2), 675-686, 2018.
 18. Küçük H., Eminoğlu İ., Balcı K., Classification of neuromuscular diseases with artificial intelligence methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 1725-1742, 2019.
 19. Reşat H.G., Design and development of hybrid forecasting model using artificial neural networks and ARIMA methods for sustainable energy management systems: A case study in tobacco industry, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1129-1140, 2020.
 20. Kaplan, K., Kuncan, M., & Ertunc, H. M., Prediction of bearing fault size by using model of adaptive neuro-fuzzy inference system. *IEEE 23rd Signal Processing and Communications Applications Conference (SIU 2015)*, Malatya, Turkey, 1925–1928, 2015.
 21. Kaplan, K., Bayram, S., Kuncan, M., & Ertunç, H. M., Feature extraction of ball bearings in time-space and estimation of fault size with method of ANN. *Proceedings of the 16th Mechatronika, Brno, Czech Republic*, 2014.
 22. Nguyen T. N., Lee S., Nguyen-Xuan H., Lee J., A Novel Analysis-Prediction Approach for Geometrically Nonlinear Problems Using Group Method of Data Handling. *Computer Methods in Applied Mechanics and Engineering*, 354, 506-526, 2019.
 23. Jiang Y., Liu S., Peng L., Zhao N., A Novel Wind Speed Prediction Method Based on Robust Local Mean Decomposition, Group Method of Data Handling and Conditional Kernel Density Estimation, *Energy Conversion and Management*, 200, 112099, 2019.
 24. Naeini S. A., Moayed R. Z., Kordnaeij A., Mola-Abasi H., Elasticity Modulus of Clayey Deposits Estimation Using Group Method of Data Handling Type Neural Network. *Measurement*, 121, 335-343, 2018.
 25. Liu H., Duan Z., Wu H., Li Y., Dong S., Wind Speed Forecasting Models Based on Data Decomposition, Feature Selection and Group Method of Data Handling Network. *Measurement*, 148, 106971, 2019.
 26. No Y. G., Lee C., Seong P. H. Development of a Prediction Method for SAMG Entry Time in NPPs Using the Extended Group Method of Data Handling (GMDH) model, *Annals of Nuclear Energy*, 121, 552-566, 2018.
 27. Wu J., Wang Y., Zhang X., Chen Z., A Novel State of Health Estimation Method of Li-ion Battery Using Group Method of Data Handling. *Journal of Power Sources*, 327, 457-464, 2016.
 28. Kurnaz T. F., Kaya, Y., Prediction of the California Bearing Ratio (CBR) of Compacted Soils by Using GMDH-Type Neural Network. *The European Physical Journal Plus*, 134 (7), 326, 2019.
 29. Khan A., Ko D. K., Lim S. C., Kim H. S., Structural vibration-based classification and prediction of delamination in smart composite laminates using deep learning neural network, *Composites Part B: Engineering*, 161, 586-594, 2019.
 30. Yang Z., Fu J., Bai J., Liao G., Yu M., An Inverse Model of Magnetorheological Elastomer Isolator with Neural Network, 2019 Chinese Control And Decision Conference (CCDC), 1664-1667, IEEE, June 2019.
 31. Vatandoost H., Alehashem S. M. S., Norouzi M., Taghavifar H., Ni Y. Q., A Supervised Artificial Neural Network-Assisted Modeling of Magnetorheological Elastomers in Tension-Compression Mode, *IEEE Transactions on Magnetics*, 55 (12), 1-8, 2019.
 32. Yu Y., Li Y., Li J., Nonparametric modeling of magnetorheological elastomer base isolator based on artificial neural network optimized by ant colony

- algorithm, *Journal of Intelligent Material Systems and Structures*, 26 (14), 1789-1798, 2015.
33. Vatandoost H., Norouzi M., Alehashem S. M. S., Smoukov S. K., A novel phenomenological model for dynamic behavior of magnetorheological elastomers in tension-compression mode, *Smart Materials and Structures*, 26 (6), 065011, 2017.

