

UYARLAMALI AĞ TABANLI BULANIK ÇIKARIM SİSTEMİ KULLANARAK BİR MEKANİK JİROSKOPUN YALPALAMA KESTİRİMİ

İlyas KACAR*

Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Niğde, Türkiye

Geliş Tarihi/Received Date: 23.05.2023 Kabul Tarihi/Accepted Date: 25.12.2023 DOI: 10.54365/adyumbd.1301423

ÖZET

Jiro-tork üretme kabiliyetleri nedeni ile mekanik jiroskoplar, hava ve uzay araçları gibi tamamen asılı veya tek, çift tekerlekli kara araçlarını dengelemek, yön vermek için sıklıkla kullanılmaktadır. Jiro-tork yüksek hızda dönen volan ve onun üç eksen etrafında dönme hareketi yapabilmesine olanak tanıyan bir şasi sayesinde üretilmektedir. Jiro-torku kontrol etmek için yalpalama hızı uygulanmaktadır. Yalpalama hızına ilişkin zaman serisi verisi katı cisim dinamik analizi sayesinde elde edilmiştir. Veriye herhangi bir ön işlem uygulanmamıştır. Bu hızın açık çevrim kestirimi için uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) kullanılmıştır. Elde edilen modelde korelasyon değeri 0.99981 ve hata karesinin ortalamasının kökü 0.02467 rad/s olarak bulunmuştur. Model çıktıları ile veri seti arasında yüksek doğrusal bir ilişki mevcuttur. ANFIS ağının veriye herhangi bir ön işlem yapılması gereksinimini ortadan kaldırdığı da görülmüştür. Kullanılan ağ parametreleri ve bu ağ ile elde edilen kestirim performansı çalışmada sunulmuştur.

Anahtar Kelimeler: Jiroskop, Makine öğrenimi, Uyarlamalı ağ tabanlı bulanık çıkarım sistemi, Yalpalama

PRECESSION FORECASTING OF A MECHANICAL GYROSCOPE USING ADAPTIVE NEURO FUZZY INFERENCE SYSTEM

ABSTRACT

Due to their ability to generate gyro-torque, mechanical gyroscopes are frequently used to balance or orientate fully suspended air or spacecraft or single or double-wheeled land vehicles. Gyro-torque is produced with a high-speed rotating flywheel and its chassis that allows it to rotate around three axes. The precession is applied to control the gyro-torque. The time series data on the precession was obtained by rigid body dynamic simulation. No pre-processing was applied to the data. An adaptive network based fuzzy inference system (ANFIS) is used for open loop prediction of the precession. In the model obtained, the correlation value was found to be 0.99981 and the root of the mean square of the error was 0.02467 rad/s. High linear relationship between the model outputs and the data set is found. It has also been seen that the ANFIS network eliminates the need for any pre-processing of the data. The network parameters used and the prediction performance obtained are presented.

Keywords: Gyroscope, Machine Learning, Adaptive neuro fuzzy inference system, Precession

1. Giriş

Jiroskoplar mekanik, optik veya elektromekanik türlerde olabilmektedir. Ana uygulamaları navigasyon olsa da mekanik olanlar sayesinde jiroskopik tork üretilmesi de mümkündür. Hava ve uzay aracı gibi tamamen havada hareket eden araçları yönlendirmek için itki sistemlerine alternatif olarak kullanılmaktadır. Ayrıca karada tek tekerlekli bisikletlerin ve motosikletlerin otonom stabilizasyonu için de kullanılmaktadır. Çoğunlukla savunma sanayiine yönelik uygulamaları mevcuttur. Mekanik jiroskopların da çeşitli türleri vardır. Bu makale, ağırlık ve yalpalama hızına yanıt olarak jiro-tork üreten

* e-posta : ikacar@gmail.com ORCID ID: <https://orcid.org/0000-0002-5887-8807>

mekanik jiroskopları ele almaktadır. Bu tip jiroskoplarda dönen volan, elastik bir burulma çubuğu ile gimbal'e bağlanmaktadır. Volan, ayar hızı adı verilen özel bir hızda dönmektedir.

Jiroskoplar manyetik olarak yataklanmak sureti ile uzay aracının konum kontrolünde kullanılan önemli bir aktüatördür. Volan yüksek hızda döndüğü için hassas kontrol çok önemlidir. Rotor dinamiği, elektromanyetik kuvvet, pertürbasyon ve harici bozucular kontrolü güçleştirmektedir. Sorunlarının üstesinden gelmek için geleneksel kontrol yöntemlerine ilave olarak bulanık entegre kayan kipli denetleyici, makine öğrenme modelleri kullanılmaktadır.

Veri kullanılarak yapılan modelleme ve kestirim yöntemleri, analitik formüllerle modellenemeyecek kadar karmaşık olan yapıların modellenmesinde kullanılan bir yöntemdir. Her ne kadar geleneksel bir yöntem olan regresyonlar hâlâ günümüzde kullanılıyor olsa da makine öğrenme yöntemleri ile oluşturulan modellerin çok daha yüksek modelleme ve kestirim başarısına sahip olduğu bildirilmiştir [1]. Nikkhah ve ark. (2009) bir mekanik jiroskoptaki rastgele bozucu ve gürültüler nedeni ile oluşan hataları kestirmek üzere otomatik gerilemeli (AR), otomatik gerilemeli hareketli ortalama (ARMA), uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve nonlinear otomatik gerilemeli (NAR) yöntemlerinin kullanımını araştırmıştır [2]. Manyetometre, güneş sensörü ve jiroskop verilerini kullanarak bir uydunun durumu ve açısal hızları ANFIS gözlemcisi ile kapalı döngü kestirimi yapılmıştır [3]. Niu ve Cui (2017) kontrol moment jiroskop (CMG) sisteminin bulanık Takagi-Sugeno yöntemi ile kontrol stratejisi tasarlamıştır [4]. Manyetik olarak askıya alınmış kontrol momenti jiroskopu (MSCMG), uzay aracı kontrolünün konum hizalaması için önemli bir aktüatör olup kontrol sorunlarının üstesinden gelmek üzere bulanık entegre kayan kipli denetleyici kullanmışlardır [5].

Yazarların bilgisine göre, açık literatürde, ANFIS ağı kullanarak mekanik jiroskop yalpalamasının zaman serisi kestirimini içeren bir çalışma mevcut değildir. Bu çalışmada dinamik simülasyonla elde edilmiş olan yalpalama hızı verisinin zaman serisinin modellenmesinde ANFIS ağının randımanı değerlendirilmiş ve bir kestirim modeli oluşturulmuştur. Modeli oluşturmak için kullanılan ağ parametreleri ve bu model ile elde edilen kestirim performansları çalışma içerisinde sunulmuştur. İkinci bölümde jiro-tork elde edilmesine ilişkin esaslar verilmişken üçüncü bölümde veri toplama ve simülasyon anlatılmıştır. Müteakip bölümde modellerin randımanlarının değerlendirilmesinde kullanılan metrikler verilmiştir. ANFIS ağının parametreleri beşinci, sonuçlar ve tartışma ise altıncı başlıkta verilmiştir. Varılan temel çıkarımlar ise yedinci ve son bölümde sunulmuştur.

2. Materyal ve Metod

2.1. Jiro-tork eldesi

Jiro-tork ile yalpalama hızı arasındaki ilişki klasik (Newtonian) mekanik kullanılarak cisme sabitlenmiş bir eksen takımına göre Eşitlik (1) sayesinde hesaplanmaktadır [6].

$$\sum \vec{M} = \frac{d(\vec{L})_{xyz}}{dt} + \vec{\Omega} \times \vec{L} \quad (1)$$

Burada $\sum \vec{M}$ ifadesi net tork olup, yönü ise, bağıntıya göre $d\vec{L}$ veya $\vec{\Omega} \times \vec{L}$ vektörel çarpımı yönündedir. $\vec{\Omega}$, yalpalama olarak adlandırılan ikinci Euler açısındaki [7] açısal hızdır. $\vec{L}$ açısal momentum ve t ise zamandır. Jiroskopik tork üretmek için ağırlık kullanılan mekanik jiroskoplarda denklemin sol tarafı $\sum \vec{M} = \vec{r} \times m\vec{g}$ ifadesine eşit olacaktır. $\vec{r}$ moment kolu olup volan ağırlık merkezi ile dönme merkezi arasındaki mesafe, m volan kütlesi ve $\vec{g}$ yerçekimi ivmesidir. Açısal momentumun, volanın dönme hızı yönünde olacağı unutulmamalıdır. Volanın dönme hızı, yalpalama hızı ve moment eksenleri birbirlerine diktir. Tork oluşmasına neden olan unsur ağırlıktır.

2.2. Simülasyon ve veri toplama

$$MAPE = \frac{100}{N} \sum_{t=1}^N \frac{|p(t)-o(t)|}{o(t)} \quad (2.d)$$

$$\text{Hata} = p(t) - o(t) \quad (2.e)$$


$$R = \frac{N \sum_{t=1}^N p(t)o(t) - (\sum_{t=1}^N p(t))(\sum_{t=1}^N o(t))}{\left(\sqrt{N \sum_{t=1}^N p(t)^2 - (\sum_{t=1}^N p(t))^2} \sqrt{N \sum_{t=1}^N o(t)^2 - (\sum_{t=1}^N o(t))^2} \right)} \quad (2.f)$$

İfadelerde t zaman adımında, veri setindeki değerler $o(t)$ olup model tahmini ise $p(t)$ 'dir. R ifadesi korelasyon katsayısı ve R^2 ise determinant katsayısı olup -1 ile 1 arasında değer almaktadır, birimi yoktur. MSE hataların karelerinin ortalaması, MSE'nin karekökü RMSE, MAE mutlak hatanın ortalaması ve MAPE ise mutlak hatanın ortalamasının yüzdesidir. MSE (birim²), RMSE (birim), MAE (birim) ve MAPE (birim) değerlerinin sıfıra yakın olması hata değerlerinin azlığını göstermektedir. Ayrıca regresyon analizleri de modellerin iyiliklerini belirleme araçlarından biridir.

R (veya R^2) değerlerinin pozitif 1'e yakın olması, fonksiyon kestirimi ile ham veri arasında yüksek doğrusal bir ilişki olduğunu göstermektedir. Negatif 1'e yakın değerler yüksek doğrusal ters bir ilişki olduğunu göstermektedir. Sıfıra yakın değerler ise herhangi bir ilişki olmadığı anlamına gelmektedir.

2.4. ANFIS ile modelleme

Uyarlamalı ağ tabanlı bulanık çıkarım sistemi, hem YSA yapısına hem de bulanık karar verme stratejisine sahip bir tekniktir. YSA yapısından gelen sinirsel öğrenme kabiliyetine sahipken, kararlar ise bulanık teknikten gelen "eğer-ise" kurallarına ve üyelik fonksiyonlarına (ÜF) dayanmaktadır. Eğitim sırasında ÜF'larının boyutunu değiştirmek, bu bulanık çıkarım sistemine (FIS) uyarlamalılık özelliği katmaktadır. Bu çalışmada kullanılan ANFIS yapısı Şekil 2'de verilmiştir.




Şekil 2. On bir gecikmeli ANFIS ağı [10]

Genelleştirilmiş bir bulanıklaştırma kuralı Eşitlik (3)'te verilmiştir.

$$\begin{aligned} & \text{If } (in_1 = A_i) \wedge (in_2 = B_j) \wedge \dots \wedge (in_n = C_k) \\ & \text{then } f_n = f(in_1, in_2, \dots, in_n) \end{aligned} \quad (3)$$

Burada $\wedge$ işareti “ve” operatörüdür. $A, B, \dots, C$ kümeler karşılık gelen girdi değişkenlerinin dilsel ifadeleridir. $i, j, k = 1, 2, \dots$ bulanıklaştırma katmanındaki her girdi değişkeni için kümeleme sayılarıdır. $in_1, in_2, \dots$ giriş değişkenleridir. $n = 1, 2, \dots$ kural adetidir. f_n durulaştırma katmanındaki her bir düğümdeki çıktı fonksiyonudur. Bu sabit (sıfır dereceli Sugeno modeli olarak adlandırılır) veya lineer $f_n = p_n * in_1 + q_n * in_2 + \dots + r_n * in_n + s_n$ olabilmektedir. Burada p_n, q_n, r_n , ve s_n doğası gereği regresyon yoluyla belirlenecek katsayılarıdır. Bir kuralın “eğer” kısmındaki parametrelere *öncül* parametreler, “ise” kısmındaki parametrelere *sonuç* parametreleri denmektedir.

Zaman gecikmelerini tespit etmek için korelogramlar kullanılmıştır (Şekil 3). Yalpalamanın bileşenleri ve bileşkesi oto korelasyon ve kısmi oto korelasyon grafiklerinde değerlendirilmiştir. Her iki tip grafikten serideki verilerin rastgele olmadığı, kendi gecikmelerine bağlı olduğu görülmüştür. Otokorelasyon fonksiyonu (OKF) giderek azalmaktadır. OKF katsayıları sıfırdan önemli ölçüde farklıdır ve yavaş yavaş sıfıra doğru düşmektedir. Kısmi otokorelasyon fonksiyonu (KOKF) 11. gecikmeden sonra kesilmektedir. Sonraki gecikmeler sıfıra çok yakındır. İki standart sapma kadarlık oluşturulan güven sınırlarının hemen hemen dışında kalmaktadır. Bu durum 11 gecikmenin birbirleri ile yüksek ilişkili ve sonraki ardışık değerlerin birbiriyle ilişkili olmadığı anlamına gelmektedir. Bu davranış, serinin ilk on bir gecikmeye bağlı ve otomatik gerileyen bir seri AR(11) olduğunu göstermektedir. Şekilde sadece yalpalamanın bileşkesine ait grafikler verilmiş olsa da diğer bileşenlerin de benzer desende olduğu görülmüştür. Bu nedenden dolayı sadece bileşkeye ait grafikler verilmiştir.



Şekil 3. (a) Bileşke yalpalama verisine ait OKF, (b) KOKF

Toplam veri setinin ilk %60'ı eğitim için, geri kalan %40'ı ise kestirim için kullanılmıştır. Veriler yazılım içerisinde başlangıçta normalleştirilmiştir. NAR ağları, yazılım kodları kullanılarak oluşturulmuştur [11]. IoT (nesnelerin interneti) kullanan herhangi bir donanım uygulaması bu çalışmanın kapsamı dışındadır. Ağırlıklara eğitimden önce ilk değer olarak sıfır verilmiştir. Hata yakınsaması olarak RMSE gözlemlenmiştir. Bu çalışmada kullanılan ANFIS ağının özellikleri Çizelge 1'de verilmiştir.


Çizelge 1. ANFIS mimarisinin katman yapılandırması

Katman	Konfigürasyon	Parametreler
Çıktı	1	--
Giriş	11	11 gecikmeli geri besleme
Veri bölümlemesi	--	60% eğitim, 40% kestirim
Bulanıklaştırma ve veri kümeleme	Fuzzy C Means	Giriş ÜF: Gauss Kümeleme: Her ÜF için 4 $m=2$
Durulaştırma	Çıkış ÜF	Birinci mertbe Sugeno
Karar verme	Çarpım	VE
Eğitim algoritması	Hybrid	--
Epochs	İterasyon = Epoch	100 Epoch

3. Sonuçlar ve Tartışma


3.1. Doğrulama

Ağ eğitimi iteratif bir biçimde gerçekleşmektedir. Her iterasyonun sonunda modelin hata değerinin azalmış olması beklenmektedir. İterasyonlara göre hata değişimini gösteren hata yakınsama grafiği Şekil 4'te verilmiştir. Bütün eğriler sıfıra yaklaşmaya meyillidir. Gidişatta herhangi bir sapma yoktur. Bununla birlikte yalpalamanın z bileşenine ait tahmin modelinin diğerlerine göre en az hataya sahip olduğu görülmektedir.

**Şekil 4.** Ağın eğitimi sırasında hata yakınsaması


3.2. Kestirim eğrileri

İterasyonlar bittikten sonra elde edilen modellerinin verinin kestirim için kullanılan kısmı için kestirim eğrileri Şekil 5'te, kestirimdeki hata değerlerini içeren grafikler Şekil 6'da, varyans grafikleri Şekil 7'de ve modellerin lineer regresyon analizleri Şekil 8'de verilmiştir. Ağlar eğitim, test ve doğrulama sırasında kestirim verilerini bilmemekteydiler.




Şekil 5. Ağın (a) x doğrultusu, (b) y doğrultusu, (c) z doğrultusu etrafındaki ve (d) bileşke yalpalama hızına dair kestirimleri

Kestirim eğrileri incelendiğinde, ağların genel eğri, şekillerini temsiliyet yeteneklerinin yüksek olduğu, eğrilerdeki lokal tepe ve çukurlukları da temsil edebildiği görülmüştür. Tepe ve çukurlukları temsil etmede ağın Ω_z verisi üzerindeki başarısı daha yüksektir. Ancak ham veri ile model tahmini arasında bir gecikme mevcuttur. Ω_y verisine yönelik tahmin eğrisindeki salınımlar diğerlerine göre daha fazladır. Bunun nedeninin jiroskobun y eksenini etrafındaki dönme verisinin hem yalpalama hem de volan dönüşü nedeni ile olan dönmeleri bir arada içermesi, bu nedenle de veri üzerinde farklı etkilerin kestiriminde modelin başlangıçta salınım yaptığı düşünülmektedir. Zira zaman adımı ilerledikçe sapmaların azaldığı görülmektedir.




Şekil 6. Ağın kestirimi ile veri seti arasındaki fark (a) x doğrultusu, (b) y doğrultusu, (c) z doğrultusu etrafındaki ve (d) bileşke yalpalamadaki hata

Eğitilmiş modelin, kestirim verisi üzerindeki tahminleri ile kestirim ham verisi arasındaki farkı gösteren hata grafikleri incelendiğinde hatanın değişken olduğu, en az hatanın Ω_z verisi üzerinde olduğu gözlemlenmiştir.



Şekil 7. Ağın kestirimindeki (a) x doğrultusu, (b) y doğrultusu, (c) z doğrultusu etrafındaki ve (d) bileşke yalpalamadaki varyans

Bir modelin sabit varyansa sahip olup olmadığını belirlemenin en yaygın yolu, model kestirimine karşın fark (hata) grafiği oluşturmaktır. Modellemelerde temel varsayımlarından biri, farkların her seviyesinde sabit varyansa sahip olmasıdır. Fark dağılımı, kestirim değerlerinin her seviyesinde kabaca eşitse, sabit varyans varsayımı karşılanmış olacaktır. Aksi takdirde, farkın yayılması sistematik olarak artar veya azalır, bu varsayım büyük olasılıkla ihlal edilmiştir. Varyans dağılımları incelendiğinde başlangıçta sıfıra yakın olan fark dağılımı model kestirimi arttıkça, rasgele ve homojen olup sabit bir hâle ulaşmaktadır. Bu nedenle varyansın sabit olduğu anlaşılmıştır.



Şekil 8. (a) x doğrultusu, (b) y doğrultusu, (c) z doğrultusu etrafındaki ve (d) bileşke yalpalama için ağırlık kestirimi ile veri seti arasındaki lineer regresyon analizi

Regresyon analizleri modellerin iyiliklerini belirleme araçlarından biridir. Regresyon bir eğri uydurma yöntemidir [12]. Bir ekseninde veri setindeki değerler diğer ekseninde de modelin tahmin ettiği değerler bulunmaktadır. Arzu edilen, idealde olması beklenen durum *Model tahmini=Ham veri* olmasıdır. Bu durumda $R = 1$ olacaktır ve tüm noktalar tam olarak aynı doğru üzerinde bulunacaktır. Şekillerden model kestirimleri ile ham veri arasındaki korelasyonlarının çok yüksek olduğu görülmektedir. Bu durum modellerin temsiliyet yeteneğinin iyi olduğunun bir göstergesidir.

Çizelge 2. ANFIS ağırlık kestirim performans metrikleri

Metrikler	Ω_x	Ω_y	Ω_z	$\Omega_{\text{bileşke}}$
MAE (birim)*	0.054253	0.12298	0.00679	0.162059
MAPE (%)	0	31.10436	0	0
Ort. hata (birim)	0.007398	0.122684	-0.00479	-0.0889
MSE (birim ²)	0.005596	0.018588	0.000609	0.076139
RMSE (birim)	0.074804	0.136337	0.02467	0.275933
Hesaplama süresi (s)	5.216651	4.547085	4.218278	3.940082
R_{test}	0.99981	0.98312	0.99895	0.99643
R_{trn}	0.792613	0.809492	0.832657	0.811449
İterasyon adeti	100	100	100	100

(*) Birim, veri birimidir (rad/s).

Çizelge 2’de ise ağın kestirim performans metrikleri verilmiştir. R_{test} ve R_{trn} değerleri sırasıyla test ve eğitim esnasında modellerin korelasyon değerleridir. Hesaplama süresi en fazla 5.2 saniye olmaktadır. Elde edilen modelde en yüksek korelasyon 0.99981 ve en küçük RMSE ise 0.02467 rad/s olarak bulunmuştur. Model çıktıları ile veri seti arasında yüksek doğrusal bir ilişki bulunmuştur.

3.3. Tartışma

Mekanik jiroskoplarda yalpalama kestiriminde sıklıkla regresyon ve nadiren makine öğrenme yöntemlerinin kullanılmaktadır. Ancak regresyonların öncesinde veriye uygulanan ön işlemler verinin doğallığını bozmaktadır. Bu çalışmada ANFIS ile jiroskopik yalpalama hızı verisine bir ön işlem yapmaya gerek olmadan 0.99981 korelasyonla ve 0.02467 rad/s RMSE ile kestirim yapabilen bir model oluşturulmuştur. Model kestirimlerindeki varyans sabittir. Kestirim eğrileri incelendiğinde hem genel eğri hem de tepe-çukur şekilleri yüksek hassasiyetle kestirebilmiştir.

AR(4) modeli ile Akaike Information Criteria (AIC) kriterinin 1.5817, ARMA(4, 2) ile 0.9237, ANFIS ile 1.3568 ve MLP ile 1.4068 olduğu bildirilmiştir [2]. Yalpalama hızı tahmininde 0.01 derece/s’den ve mutlak hata 0.001°’den az olmuştur [4]. Shi ve ark. (2019) RMSE hatasını geriye yayılım (BP) algoritmasıyla 0.0135 °C, SVM yöntemiyle 0.0151°C ve LSTM yöntemiyle 0.0112 °C olarak bulmuştur [13]. Wang ve ark. (2022) yüksek hızda dönen hava ve uzay araçlarının tutum değişikliği parametrelerini kestirmek ve çözmek için BP, kapılı tekrarlayan birim (GRU), LSTM, BILSTM ağları kullanmışlardır. Simülasyon ve deney sonuçlarını kıyaslamak sureti ile BILSTM’nin kestirim doğruluğunun diğerlerine kıyasla daha iyi olduğunu göstermiştir [14].

4. Sonuçlar

Bu çalışmada bir mekanik jiroskopun dinamik analizi yapılarak elde edilen yalpalama verisinin ANFIS ağı ile modellenmesi sağlanmıştır. Model performansı araştırılmıştır. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Yalpalama hızının kestiriminde ANFIS ağı hem eğri genel şeklini hem de eğrilerdeki pik ve çukurları yüksek temsil yeteneğine sahiptir. Yöntem veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır.
- Giriş kümelemesi FCM, çıkış durulaştırması ise birinci mertebe Sugeno olan 11 gecikmeli bir ANFIS ağı oluşturulmuştur. Eğitim için hibrit algoritma kullanılmış, 100 adet iterasyon yapılmıştır.
- Jiroskopik yalpalama hızı verisine bir ön işlem yapmaya gerek olmadan 0.99981 korelasyonla ve 0.02467 rad/s RMSE ile kestirim yapabilen bir model oluşturulmuştur.

Teşekkür

Rijit dinamik simülasyonları için kullanılan Ansys®’in eğitsel amaçlı kullanım imkânını sağlayan Karadeniz Teknik Üniversitesi’ne, Dr. Mehmet Seyhan’a teşekkür ederim. Bu çalışmanın inceleme ve değerlendirme aşamasında yapmış oldukları değerli katkılardan dolayı editör, hakem ve emeği geçenlere içten teşekkür ederim.

Rekabetçi Menfaat Beyanı

Yazarlar rakip bir finansal çıkar beyan etmemektedir.

Finansman Kaynakları

Bu araştırma, kamu, ticari veya kâr amacı gütmeyen sektörlerdeki finansman kuruluşlarından herhangi bir özel hibe almamıştır.

Kaynaklar

- [1] Yalçın C, Sabah L. CBS tabanlı bulanık mantık ve ahp yöntemleri kullanılarak adıyaman İlçelerinin deprem tehlike analizinin oluşturulması. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi 2018; 5 (8): 101-113.
- [2] Nikkhah A, Heydari P, Khaloozadeh H, Heydari AP. Gyroscope random drift modeling, using neural networks, fuzzy neural and traditional time-series methods. Journal of Aerospace and Technology 2009; 6(1):37-44.
- [3] Wang X, Abtahi SM, Chahari M, Zhao T. An adaptive neuro-fuzzy model for attitude estimation and control of a 3 dof system. Mathematics 2022; 10 (6): 976. DOI: 10.3390/math10060976
- [4] Niu Z, Cui Y. Research on fuzzy control of control moment gyro driven by traveling wave hollow ultrasonic motor. 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP) 2017; 1-5.
- [5] Xudong Y, Pengfei Z, Yuanping X, Xingwu L. Forecasting method for axial ring laser gyroscope drifts in single-axis rotation inertial navigation system. High Power Laser and Particle Beams 2013; 25 (04): 847-852. <https://doi.org/10.3788/HPLPB20132504.0847>.
- [6] Kacar İ, Eroğlu MA, Yalçın MK, Design and development of an autonomous bicycle. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi 2021; 10 (1): 364-372. <https://doi.org/10.28948/ngumuh.628580>.
- [7] Wikipedia®, Precession, Wikimedia Foundation, Inc.: <https://en.wikipedia.org/wiki/Precession> (11.08.2023).
- [8] Ansys®, Academic research mechanical products, 2021 r2 help system, Ansys mechanical user's guide. ANSYS, Inc. 2023; 18-48.
- [9] Clenois N., Gyroscope physics. Cleonis 2023; 1 (1):1.
- [10] Tabari H, Kisi Ö, Ezani A., Talaei PH. SVM, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. Journal of Hydrology 2012; 444 (7): 78-89. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2012.04.007>.
- [11] Heris MK, Time-series prediction using ANFIS. The Yarpiz Project, Fuzzy Systems, 2015.
- [12] Kacar İ, Korkmaz C, Prediction of agricultural drying using multi-layer perceptron network, long short-term memory network and regression methods. Gümüşhane University Journal of Science and Technology Institute 2022; 12 (4): 1188-1206. <https://doi.org/10.17714/gumusfenbil.1110463>
- [13] Shi H, Hu S, Zhang J, LSTM based prediction algorithm and abnormal change detection for temperature in aerospace gyroscope shell. International Journal of Intelligent Computing and Cybernetics 2019; 12 (2):274-291. <https://doi.org/10.1108/IJICC-11-2018-0152>
- [14] Wang JW, Deng ZH, Shen K, Virtual gyros construction and evaluation method based on BILSTM. IEEE Transactions on Instrumentation and Measurement 2022; 71: 1007710. <https://doi.org/10.1109/TIM.2022.3212544>.