



Makine Öğrenimi Kullanarak Bir Mekanik Jiroskobun Yalpalama Tahmininde Zaman Serisi Modeli

İlyas Kacar^{1*} 

¹ Niğde Ömer Halisdemir Üniversitesi, Mekatronik Mühendisliği Bölümü, Niğde, Türkiye

ikacar@gmail.com

Öz

Jiroskobik tork üretebilmeleri nedeniyle, mekanik jiroskoplar uçak, uzay araçları gibi tamamen askıdaki veya tek/iki tekerlekli kara araçlarının dengelenmesinde sıklıkla kullanılmaktadır. Yüksek hızla dönen volan sayesinde jiroskobik tork üretmektedirler. Bu torkun kontrolü için yalpalama hızı uygulamak gerekmektedir. Çalışmada bir mekanik jiroskobun rijit dinamik analizi yapılarak 415 adet yalpalama hızı verisi toplanmıştır. Bu hızın açık çevrim tahmininde lineer olmayan, otomatik gerilemeli yapay sinir ağı (NAR) kullanılmıştır. Elde edilen modelde korelasyon değeri 0.998 ve hata karelerinin ortalamasının karekökü (RMSE) değeri de 0.016 rad/s olmuştur. Model çıktısı ile veri seti arasında yüksek doğrusal ilişki tespit edilmiştir. NAR ağı, veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır. Kullanılan ağ parametreleri ve bu model ile elde edilen tahmin performansları çalışma içerisinde sunulmuştur.

Anahtar Kelimeler: Jiroskop, Makine öğrenimi, Otomatik gerilemeli yapay sinir ağı, Yalpalama.

Time Series Model to Forecast the Precession of a Mechanical Gyroscope Using Machine Learning

Abstract

Due to the gyroscopic torque production ability, mechanical gyroscopes are frequently used for balancing fully suspended or single/two-wheeled land vehicles such as airplanes and spacecraft. They produce gyroscopic torque thanks to the flywheel rotating at high speed. Precession is required to control this torque. In the study, 415 precession data were collected by performing a rigid dynamic analysis of a mechanical gyroscope. A non-linear autoregressive artificial neural network (NAR) is used to estimate this velocity. In the model obtained, the correlation value was 0.998 and the root mean square of error (RMSE) value was 0.016 rad/s. A high linear relationship was detected between the model output and the data set. The NAR network has eliminated the need for any pre-processing on the data. The network parameters used and the estimation performances obtained with this model are presented in the study.

Keywords: Gyroscope, Machine Learning, Nonlinear autoregressive network, Precession.

1. Giriş (Introduction)

Mekanik, optik ve elektromekanik olmak üzere çeşitli jiroskoplar mevcuttur. Birincil kullanımları yön bulma olsa da mekanik jiroskoplar, ürettikleri jiroskobik tork nedeniyle uçak ve uzay aracı gibi tamamen havada asılı duran araçlara yön vermek için kullanılmaktadır. Ayrıca karada da tek ve iki tekerlekli araçların otonom dengelenmesi için kullanılmaktadır. Hava, uzay ve savunma sanayi için kullanılan bir uygulamadır. Bir uzay aracı tamamen asılı olduğundan dolayı ya yakıt

itkisi ya da mekanik jiroskoplarla yön kontrolü sağlanabilmektedir. Savunma sanayisinde ise tek veya iki tekerlekli otonom araçların dengelenmesi için de kullanılmaktadır.

Mekanik jiroskopların çeşitli türleri vardır. Bu çalışmada ağırlık esasına dayanan jiroskoplar incelenmiştir. İlave olarak her türlü mekanik jiroskoplar yalpalama hızına bağlı olarak jiroskobik tork üretebilmektedir. Bu tip jiroskopta dönen volan, elastik torsiyon çubukları vasıtasıyla gimballere bağlıdır. Volan ayar hızı adı verilen özel bir hızda dönmektedir.

* Sorumlu yazar
E-posta adresi: ikacar@gmail.com

Alındı : 31 Mayıs 2023
Revizyon : 14 Eylül 2023
Kabul : 29 Eylül 2023

Literatür araştırması tahmin yöntemlerinin öneminin dünya çapında arttığını göstermektedir. Gerekli jiroskobik momentumu üretecek yalpalama hızını tahmin etmek için analitik formüller veya simülasyon yöntemleri kullanılmaktadır. Bununla birlikte, karmaşık geometriler için analitik formüller sınırlıdır. Bu nedenle geometrinin modele uyacak şekilde basitleştirilmesi, kabuller yapılması bir çare gibi gözükse de bunlar sonuçtaki hata miktarını artırmaktadır. Bu gibi durumlarda çözüm olarak dinamik simülasyonların kullanıldığı görülmektedir (Osman vd., 1982). Belirli koşullar altında, çalışılan olayın çoklu fiziğini ve güvenilir sonuçları elde etmek mümkündür (Kownacki, 2011). Kontrollü tork jiroskobu (CMG) ile donatılmış uzay aracına yapılan dinamik analiz sayesinde titreşimlerin faydalı yük performansı üzerindeki olumsuz etkisi araştırılabilmiştir (Sun vd., 2023). Dinamik analiz kullanılarak, mobil robotun ihtiyaç duyduğu gücü ve bisikleti dengelemek için gereken momenti hesaplamak mümkün olmuştur (Sucuoğlu vd., 2018). 5 kg ilave yük ve 17,5 kg kütleyle sahip iki tekerlekli, otonom sürüş yapan bir bisikleti dengeleme amacıyla kullanılan bir CMG'nin, 30 Nm'lik bir tork üretmesi gerektiği simülasyonla tespit edilmiştir (Kacar vd., 2021). 20,5 kg'lık bir bisiklet tekerleğini dengelemek için 9,25 Nm reaktif jiroskop torkunun gerekli olduğu analitik formüller kullanılarak hesaplanmıştır (Ahmed vd., 2016). Modal analiz sayesinde, her iki uçtan yataklanmış, merkezinde bir disk bulunan şaftın kritik frekansları hesaplanabilmiştir (Fan vd., 2018). Yapının analizi ve optimizasyonu sayesinde, modelin dinamik özelliklerinin büyük ölçüde iyileştirildiği (Xiu vd., 2021) ve ortaya çıkan gerilmelerin hâlâ izin verilen sınırın altında olduğu bildirilmiştir (Ahmed vd., 2016; He vd., 2022; Xiu vd., 2021). CMG tasarımlarının yüksek hassasiyetli simülasyonu sayesinde, karmaşık elektromekanik cihazları hızlı ve yüksek kalitede geliştirmek, optimum çalışma özelliklerini tespit etmek mümkündür. Böylece dinamik analizlerin imalattan önce gerekli ön çalışmaların yapılabilmesine olanak tanıdığı anlaşılmaktadır (Kostyuchenko ve Indygasheva, 2018).

Modelleme ve tahmin için (Amiroh vd., 2021) *model* ve *veri* esaslı (Tobon-Mejia vd., 2012) olmak üzere iki çeşit yöntem kullanılmaktadır. Model esaslı olanlar fiziksel akıl yürütmeye dayalıdır ve kesin çözümler üretmektedir. Modelleme ve tahmin yapmak için artıklar (kalıntılar, farklar) değerlendirilmektedir. Bununla birlikte, gerçek sistemlerin karmaşıklığından dolayı, bu tür matematiksel modellerin oluşturulması nispeten zordur. Gerçek sistemlerin karmaşık yapısını varsayımlarla basitleştirmek mümkün olsa da ne kadar çok varsayım varsa sonuçlarda o kadar çok sapma oluşabilmektedir. Veriye dayalı yaklaşımlar ise veri setleri üzerine yapılan istatistiksel işlemler sayesinde modelleme ve tahmin yapmaktadır. Karmaşık şekilli sistemler için veri esaslı yöntemler ilk tercihtir. Dash ve Venkatasubramanian (2000) ve Venkatasubramanian ve ark. (2003) kapsamlı bir araştırma yürütmüş, iki yöntemi

karşılaştırmış ve veriye dayalı yöntemin daha avantajlı olduğu sonucuna varmıştır (Dash ve Venkatasubramanian, 2000) (Venkatasubramanian vd., 2003). Veriye dayalı yöntemler ise iki kategoriye ayrılmaktadır: Biri yapay sinir ağları, derin öğrenme gibi yapay zekâ yöntemleri, diğeri ise istatistiksel öğrenme yöntemleridir (gizli Markov modeli (HMM), destek vektör makinaları (SVM) vb.) (Dong vd., 2020). Bir sürecin gözlenebilir kısmını temsil etmede ARIMA, SARIMA, SARIMAX, Poisson otomatik gerileyen, lineer vb. regresyon yöntemleri kullanılırken, sürecin gözlenemeyen kısmının tahmini için HMM ve SVM yöntemleri kullanılmaktadır.

Navigasyon sistemlerinde yapay sinir ağlarının (YSA) kullanılması, filtreleme algoritmalarının doğruluğunu artırmıştır (Jamil ve Kim, 2019). Nuswantoro ve ark. (2020) YSA algoritması ile jiroskop ve ivmeölçerden gelen verileri değerlendirilerek hareket tanımlama sürecini geliştirmişler ve sürücü durumunun tespitini %96,2 doğruluk düzeyi ile yapabildikleri (Nuswantoro vd., 2020). Kathpalia ve Gulati (2022) üç eksenli jiroskop verisini tek giriş tek çıkışlı çok katmanlı algılayıcı (MLP) ağında kullanarak GPS doğruluğunu iyileştirmiştir (Kathpalia ve Gulati, 2022). Papakonstantinou ve ark. (2022) makine öğrenimi tekniklerinden derin sinir ağı (DNN) ve rastgele orman sınıflandırıcısı (RFC) kullanarak bir uydunun tutum kontrolü için kullanılan CMG için tekillikten kaçınma sorununu ele almışlardır. RFC tekniğinin, DNN'ye kıyasla test verileri için gelişmiş doğruluk gösterdiğini belirtmişlerdir (Papakonstantinou vd., 2022).

Yazarların bilgisine göre, açık literatürde, NAR ağı kullanarak jiroskop yalpalamasının zaman serisi tahminini içeren bir çalışma mevcut değildir. Bu çalışmada bir mekanik jiroskobun, sonlu eleman simülasyonu esaslı rijit dinamik analizi gerçekleştirilmiş ve elde edilen yalpalama verisinin, zamana bağlı olarak modellenmesi için NAR ağı kullanılmıştır. Sonuçlar göstermiştir ki NAR ağı ile yüksek korelasyona sahip bir tahmin modeli oluşturulabilmektedir. Modeli oluşturmak için kullanılan ağ parametreleri ve bu model ile elde edilen tahmin performansları çalışma içerisinde sunulmuştur. İkinci bölümde mekanik jiroskobun çalışma esası verilmişken üçüncü bölümde yapılan dinamik analiz ve bu analizden elde edilen veri izah edilmiştir. Dördüncü bölümde modellerin randımanlarının değerlendirilmesinde kullanılan istatistiksel yöntemler izah edilmiştir. Beşinci bölümde NAR ağı ve altıncı bölümde sonuçlar ve tartışma verilmiştir. Yedinci ve son bölümde ise bu çalışmadan elde edilen temel çıkarımlar sunulmuştur. NAR ağının bu alanda ilk defa kullanılmış olması neticesinde elde edilen temel bilimsel katkı, jiroskop tasarımcılarına yöneliktir. Zira daha jiroskop tasarımı esnasında optimum boyutların, zaman diliminin, torkun, güç gereksiniminin belirlenmesi bu model ve dinamik analiz sayesinde mümkündür. Çalışmanın ikincil katkısı ise dinamik analizcilere olmaktadır. Çünkü simülasyonlarda dönen bir diskin veya çemberin

meydana getirdiği jiroskobik etkinin elde edilebilmesinin bazı püf noktaları mevcuttur. Bu hususlar metin içerisinde dinamik analiz ve veri toplama isimli başlık altında okuyuculara izah edilmiştir.

2. Kavramsal Çerçeve (Conceptual Framework)

Ağırlık torkunu dengelemek için jiroskobik tork üreten bir mekanik jiroskobun cisme sabitlenmiş bir eksen takımına göre açısal momentumdaki değişimin genel denklemi, klasik (Newtonian) mekaniğine göre Eşitlik (1) kullanılarak hesaplanmaktadır. Bu eşitlik, simülasyon sonuçlarının doğrulanması için kullanılmıştır.

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

Burada $\sum \vec{M}$ ifadesi net tork olup, yönü ise, bağıntıya göre $d\vec{L}$ veya $\vec{\Omega} \times \vec{L}$ yönündedir. $\vec{\Omega}$, yalpalama olarak adlandırılan ikinci Euler açısındaki (Anonimouse, 2023) açısal hızdır. \vec{L} açısal momentum ve t ise zamandır. Açısal momentumun, volanın dönme hızı yönünde olacağı unutulmamalıdır. Volanın dönme hızı, yalpalama hızı ve moment eksenleri birbirlerine diktir. Jiroskobik 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 diskinin ağırlık merkezi ile dönme merkezi arasındaki fark, m volan kütlesi ve \vec{g} yerçekimi ivmesidir.

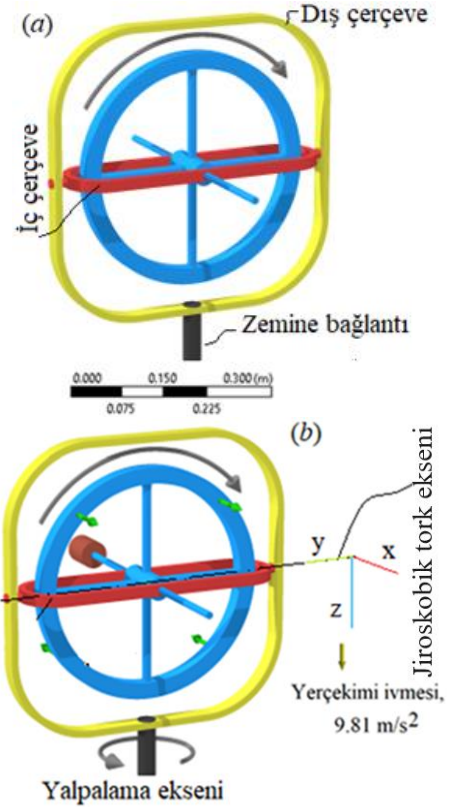
3. Metodoloji (Methodology)

3.1. Dinamik Analiz ve Veri Toplama (Dynamic Analysis and Data Acquisition)

Veri seti, sonlu eleman simülasyonuna dayalı dinamik simülasyon sonucunda elde edilmiştir. Simülasyonlar Ansys® yazılımı kullanılarak yapılmıştır (Ansys®, 2023). Analiz, toplam süresi 5 saniye olan iki adımda gerçekleştirilmiştir. Dinamik analizin iterasyonlarında minimum zaman adımı $1e-7$ s ve maksimum zaman adımı $5e-2$ s ile sınırlanmıştır. Dönen bir diskin veya çemberin meydana getirdiği jiroskobik etkinin hesaplanabilmesi için, diskin (veya çemberin) şaft ile birlikte yekpare olması yani birlikte dönmesi gerekmektedir. Eğer disk, şaft etrafında döndürülürse, jiroskobik tork elde edilemeyecektir! Zaman adımı sabit olduğu için eşit zaman aralıklarında, toplam 415 adet veri toplanmıştır. Volan kendi ana eksenini etrafında sabit bir açısal hızda döndürülmektedir. Bu esnada diğer iki eksenlerden birinde ağırlığın neden olduğu tork oluşurken, geriye kalan ekseninde de yalpalama meydana gelmektedir. Veri setini, yalpalama eksenindeki döner bağlantının yaptığı açısal hız ve karşılık gelen zaman

adımları oluşturmaktadır. Tek değişken yalpalama olup, zamana bağlıdır. Zamana bağlı serilerde çıktı değişkeni, belli bir gecikmeye bağlı olarak girdi olmaktadır. Bu çalışmada yalpalama verisi kendisine bir gecikmeli olarak bağlı olduğundan dolayı, yalpalama verisi çıktı iken, onun bir gecikmeli değeri ise girdi olmaktadır. Bu hâli ile bir girdi, bir çıktıya sahiptir. Verinin gecikme miktarının tayini müteakip başlıklar altında izah edilmiştir.

Her bir simülasyon, 3.40 GHz hızında çalışan dört çekirdekli işlemcili, 8 GB RAM'e sahip bir bilgisayarda 2.866 saniye sürmüştür. Şekil 1, bu çalışmada kullanılan ağırlık dengeleme ilkesine dayanan mekanik jiroskobu göstermektedir. Bir adet çember biçimli volan mevcuttur. Volanın dönme hızı, yalpalama hızı ve moment eksenleri birbirlerine dik olması nedeniyle gerektiğinde, bunların üçünü de sağlayabilmesi için, tasarlanan sistemde, volanın üç ekseninde de dönme hareketi yapabileceği kabiliyeti olması gerekmektedir.



Şekil 1. Çalışmada kullanılan mekanik jiroskop (NI, 2023) (a) kavramsal tasarımı, (b) ağırlık uygulanması hali (Mechanical gyroscope used in the study (a) conceptual design, (b) weight application)

Çalışmada Şekil 1'de verilen tasarım kullanılmış olup bu sayede volanın hem kendi eksenini etrafında hem de diğer iki eksen etrafında serbestçe dönebilmesine olanak sağlanmıştır. Böylece üç eksen etrafında da gerektiğinde olası dönüşler serbestçe yapılabilecektir. Yerçekimi ivmesi uygulanmıştır. Analizde kullanılan modelin temel varsayımları şunlardır: (1) malzemede

sönüm yoktur, (2) yatak sürtünmesi ihmal edilmiştir (3) yataklamalarda temas yüzeylerinin tamamı temas halindedir, (4) diğer dış koşullar dikkate alınmamıştır (5) Tüm parçalar rijittir. Bu nedenle eleman ağı üretilmemiştir. Rijit cisimlerde esneme veya hasar söz konusu değildir. Temas kullanılmamıştır.

Tork oluşmasına neden olan unsur ağırlıktır. Mevcut tasarıma göre kütle merkezinden dönme merkezine olan mesafe nedeni ile ağırlığın sebep olduğu tork $Tork_W = \vec{r} \times m\vec{g} = 0.03 * 1.59 * 9.8066 = 0.468 \text{ kgm}^2/s^2$ olarak hesaplanmıştır.

Ham verilere değişken varyans testlerden biri olan Engle's ARCH testi uygulanmıştır. Ham verilerin değişken varyansa sahip olduğu görülmüştür. Herhangi bir regresyondan önce, araştırmacılar genellikle ham deneysel verilerdeki değişken varyansı ortadan kaldırmak, veriyi iyileştirmek için ön işlem(ler) uygulayabilmektedirler (Hossein ve Tabari vd., 2012; Shen vd., 2020; Taheri vd., 2021). Bununla birlikte uygulanan ön işlemin miktarı, şiddeti ne olursa olsun, herhangi bir işlem, verilerin doğallığını bozmakta ve olayı temsil etme yeteneğini azaltmaktadır. Bu nedenle çalışmada ham veriler üzerinde herhangi bir ön işlem yapılmamıştır. Bu sayede genel veri eğrisini yakalayabilmenin yanı sıra eğrideki tepe ve çukurları da yakalayabilmesi, NAR ağı'nın ayırt edici özelliklerinden birisi olacaktır.

Bütün parçaların malzemesi yapı çeliği olup özellikleri Tablo 1'de verilmiştir. CMG'ye ait geometrik özellikler ise Tablo 2'de verilmiştir.

Tablo 1. Malzeme özellikleri

Özellik	Değer
Yoğunluk (kg/m ³)	7850
Çekmedeki akma gerilmesi (MPa)	250
Basmadaki akma gerilmesi (MPa)	250
Çekmedeki maksimum gerilme (MPa)	460
Basmadaki maksimum gerilme (MPa)	460

Tablo 2. CMG'nin geometrik özellikleri

Özellik	Değer
Dış çerçeve	
Hacim (m ³)	7.39E-05
Asal atalet momenti, I_{p1} , (kg·m ²)	4.23E-03
Asal atalet momenti, I_{p2} , (kg·m ²)	4.73E-03
Asal atalet momenti, I_{p3} , (kg·m ²)	8.94E-03
Kütle (kg)	0.58
İç çerçeve	
Hacim (m ³)	1.64E-04
Asal atalet momenti, I_{p1} , (kg·m ²)	6.23E-03
Asal atalet momenti, I_{p2} , (kg·m ²)	5.92E-03
Asal atalet momenti, I_{p3} , (kg·m ²)	1.20E-02
Kütle (kg)	1.29
Volan	
Hacim (m ³)	1.01E-04

Disk kalınlığı (mm)	5.00
Asal atalet momenti, I_{p1} , (kg·m ²)	1.28E-03
Asal atalet momenti, I_{p2} , (kg·m ²)	1.26E-03
Asal atalet momenti, I_{p3} , (kg·m ²)	2.53E-03
Disk yarıçapı (mm)	4.00E+02
Mil çapı (mm)	5.00E+00
Kütle (kg)	7.95E-01
Kendi eksenine etrafındaki dönme hızı, ω (rad/s)	128
Volan ağırlık merkezinin CMG merkezine olan mesafesi (mm)	30



3.2. Model Performans Değerlendirmesi (Model Performance Assessment)

Bir modelin tahmin yeteneğini belirlemenin en uygun yolu, ham veriler ile modelin öngördüğü değerlerin aralarındaki farkı hesaplamaktır. Hata analizi bu amaçla sıklıkla kullanılan bir yöntemdir. Diğer bir popüler yöntem de çoklu veri kümeleri arasındaki ilişkileri belirlemek üzere korelasyon miktarını araştırmaktır. Yaygın olarak kullanılan hata fonksiyonları ve korelasyon formülü Eşitlik (2)'de verilmiştir.

$$MSE = \frac{1}{N} \sum_{t=1}^N (p(t) - o(t))^2 \quad (2.a)$$

$$RMSE = \sqrt{MSE} \quad (2.b)$$

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

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

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

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


Burada $o(t)$ veri setindeki değerler ve $p(t)$ ise modeller tarafından tahmin edilen verilerdir. t ise zaman adıdır. R ifadesi korelasyon olup -1 ile 1 arasında değer almaktadır, birimi yoktur. MSE hatanın karesinin ortalamasıdır. MSE'nin karekökü RMSE'dir. MAE de mutlak hatanın ortalamasıdır. MSE, RMSE ve MAE değerlerinin sıfıra yakın olması istenir. RMSE incelenen veri ile aynı birimdeyken MAPE ise yüzde birimindedir. MSE ise birim² olmaktadır. MAE, hata ile aynı birimdedir. R veya R^2 değerlerinin pozitif 1'e yakın olması, fonksiyonun tahmin ettiği değerler ile ham veri arasında kuvvetli bir lineer ilişkinin olduğunu göstermektedir. -1'e yakın olması ise kuvvetli bir ters lineer ilişki olduğunu göstermektedir. Sıfır, herhangi bir ilişki olmadığını göstermektedir. RMSE, MSE, MAE

gibi hata değerlerinin sıfıra yakın olması da tahmindeki ortalama hata değerlerinin azlığını göstermektedir.

3.3. NAR ile Modelleme (Modelling using NAR)

Şekil 2’de bu çalışmada kullanılan doğrusal olmayan, otomatik gerileyen, çok katmanlı algılayıcı ağı şematik olarak gösterilmiştir. b ’ler $bias$ olup bir modelin tahmin değerlerini belli bir yöne doğru götürmeye yarayan değerlerdir. İstatistik ve makine öğreniminde sıklıkla kullanılan bir özelliktir. Ağ mimarisi $Out(t) = f((t - 1), \dots, (t - d))$ yapısındadır. d terimi gecikme olup 2 olarak alınmıştır. Bu, iki adet giriş olacağını ve bunlarında çıkıştan iki adım geride olacağı anlamına gelmektedir.

Toplam veri setinin ilk %60’ı eğitim için, geri kalan %40’ı ise tahmin için kullanılmıştır. Veriler yazılım içerisinde başlangıçta normalleştirilmiştir. Veri normalizasyonu için, veri seti değişkenlerinin ölçüm ölçeğindeki dramatik değişiklik nedeniyle, tüm değişkenler (-1,1) aralığında minimum-maksimum ölçeklendirme yöntemi kullanılarak normalleştirilmiş bu da eğitim aşamasında daha iyi veri yorumu ve daha iyi model yakınsaması ve doğruluğu sağlamıştır. NAR ağları, yazılım kodları kullanılarak oluşturulmuştur (Heris, 2015). IoT (nesnelerin interneti) kullanan herhangi bir donanım uygulaması bu çalışmanın kapsamı dışındadır.

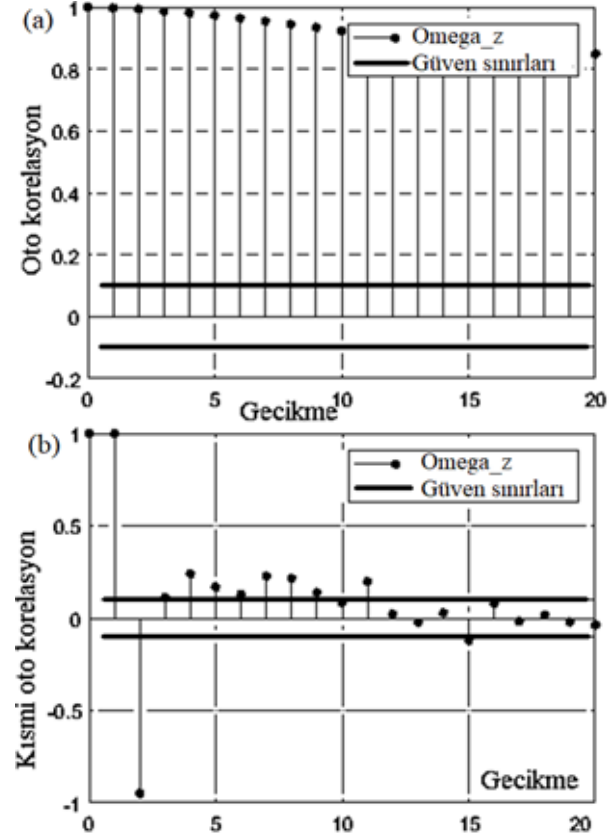


Şekil 2. NAR topolojisi (NAR topology)

Zaman gecikmelerini tespit etmek için korelogramlar kullanılmıştır (Şekil 3).

Şekilde sadece z bileşene dair diyagramlar verilmiş olup, diğer bileşmelerin de aynı desende olduğu görülmüştür. Yalpalamanın bileşenleri ve bileşkesi oto korelasyon ve kısmi oto korelasyon grafiklerinde değerlendirilmiştir. Her iki tip grafikten serideki verilerin kendi gecikmelerine bağlı olduğu yani rastgele olmadığı görülmektedir. Otokorelasyon fonksiyonu (OKF) giderek azalmaktadır. OKF katsayıları sıfırdan önemli ölçüde farklıdır ve yavaş yavaş sıfıra doğru düşmektedir. Kısmi otokorelasyon fonksiyonu (KOKF) ikinci gecikmeden sonra kesilmektedir. Daha fazla gecikme sıfıra yakın olup iki standart sapma kadarlık

güven sınırlarının hemen hemen içerisinde kalmaktadır. Bu durum 2 gecikmenin birbirleri ile yüksek ilişkili ve ikiden sonraki ardışık değerlerin birbiriyle ilişkili olmadığı anlamına gelmektedir. Bu davranış, serinin ilk iki gecikmeye bağlı ve otomatik gerileyen bir seri yani AR(2) türünde olduğunu göstermektedir.



Şekil 3. z doğrultusundaki yalpalama bileşenine ait (a) OKF (b) KOKF ((a) ACF (b) PACF for the precession component in the z direction)

YSA’da gizli katman sayısı ve gizli katmanlardaki nöronların sayısının belirlenmesinde tüm ağ türleri için kullanılabilecek tek bir yöntem henüz mevcut değildir. Optimum sayıyı tutturmak hayattır çünkü gizli katmanlarda çok az nöron kullanılması *yetersiz uydurma*, çok fazla nöron olması ise *aşırı uydurma* olarak adlandırılan hatalı durumlara neden olabilmektedir. Bununla birlikte veri seti ile modelde hesaplanan değerler arasında en yüksek korelasyona veya en büyük farka sahip modelin sıklıkla deneme-yanılma yoluyla belirlendiği görülmektedir (Amini vd. , 2021; Beigi ve Torki, 2021). Deneme-yanılma süreci zaman alıcı ve zaman-verimlilik ve maliyet açısından yetersizdir (Öğündür, 2019).

Gizli katmanların âdeti ise problemin karmaşıklığına bağlıdır. Sınır ağlarındaki daha fazla sayıda gizli katman, daha karmaşık özellikleri temsil etmektedir. Sıfır gizli katman, doğrusal ayrılabilir fonksiyonlarda veya kararlarda iyidir. 1 gizli katman, bir sonlu uzaydan diğerine sürekli bir eşleme içeren herhangi bir

fonksiyona yaklaşabilirken, 2 gizli katman, rasyonel aktivasyon fonksiyonları sayesinde isteğe bağlı bir karar sınırını isteğe bağlı doğrulukla temsil edebilmektedir. Herhangi bir düzgün işlemeyi herhangi bir doğrulukla yaklaştırabilmektedir (Heaton, 2008). Bu çalışma yalpalama uzayında tahminleme içerdiği için gizli katman sayısı 1 olarak belirlenmiştir.

Gizli katmanlardaki nöronların sayısı ile ilgili deneme-yanılma yoluyla üretilmiş bazı formüllerin literatürde verildiği de görülmüştür. Heaton (2008) Eşitlik (3)'teki formülü kullanarak gizli katmandaki nöron sayısı N_h 'nin en fazla olabilecek sayısını hesaplamıştır (Heaton, 2008).

$$N_h = \frac{N_s}{(\alpha * (N_i + N_o))} \quad (\text{Eş. 3})$$

Burada N_i giriş nöronlarının sayısıdır, N_o çıkış nöronlarının sayısı, N_s eğitim veri setindeki örnek sayısıdır. α , keyfi bir ölçeklendirme çarpanı olup genellikle 2-10 arasında alınmaktadır. Örneğin $N_s = 415$ ve $N_i = 2$, $N_o = 1$ ve $\alpha = 10$ için gizli katmandaki nöron sayısı $N_h \leq 14$ olmalıdır. İlave olarak gizli katman(lar)daki nöron sayısı giriş katmanı boyutu ile çıkış katmanı boyutu arasında olmalıdır. Bir başka yaklaşıma göre gizli katmandaki nöron sayısı, giriş katmanı boyutunun 2/3'ü ile çıkış katmanı boyutunun 2/3'ünün toplamı kadar olmalıdır. Başka bir yaklaşıma göre gizli nöronların sayısı, giriş katmanı boyutunun iki katından az olmalıdır. Öyleyse, $N_h < 4$ olmalıdır. Master'a (1993) göre tek gizli katmanlı bir sinir ağı için gizli nöron sayısı $N_h = \sqrt{N_i * N_o}$ 'tür. Yukarıdaki örnek için $N_h \approx 2$ olacaktır. Bir örüntüye ve öznetelik çıkarımına giderek daha fazla yaklaşmak ve hedef sınıfı belirlemek için sonraki katmanlarda gizli nöronların sayısı azalmaya devam etmelidir (Masters, 1993). Sartori ve Antsaklis (1991), $N_h = N_i - 1$ ile bir gizli katman kullanmıştır (Sartori ve Antsaklis, 1991). Buna göre $N_h = 1$ olmalıdır. Rachmatullah ve ark. (2020)'na göre bir sinir ağı iki gizli katmana sahipse, birinci katmandaki nöron sayısı $N_{h1} = N_o * r^2$ ve ikinci katmandaki nöron sayısı $N_{h2} = N_o * r$ ile hesaplanmaktadır. Burada $r = \sqrt[3]{N_i/N_o}$ olmaktadır (Rachmatullah vd., 2020). Buna göre $N_{h1} = 2$ ve $N_{h2} = 2$ olmalıdır. Tamura ve Tateishi (1997) iki gizli katman kullanmış, karşılık gelen gizli katmanın nöron sayısı $N_h = 3 + N_i/2$ kullanılarak hesaplanmıştır (Tamura ve Tateishi, 1997). Buna göre $N_{h1} = 4$ ve $N_{h2} = 5$ olmalıdır. Tüm çalışmalar bir bütün halinde değerlendirildiğinde nöron sayısının 14'ü aşmaması ve 1'den büyük olması gerektiği sonucu çıkmaktadır. Bütün bu hususlar bir arada düşünüldüğünde, bu çalışmada gizli katmandaki nöron sayısı 5 olarak belirlenmiştir.

YSA eğitimi için kullanılan birçok algoritma arasında hız ve kararlılık sağladığı için Levenberg-Marquardt algoritması oldukça tercih edilmektedir

(Çavuşlu vd. , 2012). Ağırlıklara eğitimden önce ilk değer olarak sıfır verilmiştir. Hata yakınsaması olarak MSE gözlemlenmiştir. Bu çalışmada kullanılan ağ özellikleri Tablo 3'te verilmiştir.

Tablo 3. NAR ağ mimarisinin katman yapılandırması (Layer configuration of NAR net topology)

Parametre	Değer
Öğrenme sürecinde hata kriteri	MSE=0.02 birim ²
Maksimum yineleme sayısı	1000
Gizli katman sayısı	1
Gizli katmandaki nöron sayısı	$N_h = 5$
Gizli katman(lar)daki aktivasyon fonksiyonu	Tanjant hiperbolik
Çıkış katmanındaki aktivasyon fonksiyonu	Lineer
Eğitim algoritması	Levenberg-Marquardt
Gecikme, d	2
Harici giriş	--
Çıkış nöronu	1
Çıkış eşiği	0.99
Öğrenme oranı, η	0.1
Momentum, α	0.1
Öğrenme eşiği	0.0001
Veri kümesi bölümlenme	İlk 60% (eğitim+test+doğrulama) son 40% tahmin

"Eşik değer" terimi tabloda verilmiş olup 0 - 1 arasındadır. Eşik değerinin altındaki değerler hesaba katılmamaktadır. Böylece zayıf bilgi unutulmakta ve daha verimli bir ağ elde edilebilmektedir. Öte yandan ağı eğitirken, tahmin performansını iyileştirmek üzere eklenecek veya eksiltilecek değerleri belirlemek için "öğrenme hızı" ve "momentum" terimleri dikkate alınmaktadır. Momentum, ağırlıklar güncellenirken, uygulanacak değişimlere, önceki ağırlık değişimlerin belli bir oranda eklenmesini sağlamaktadır. Eğitim esnasında ağ ağırlıklarının bir önceki değişim değerlerinden ne ölçüde etkileneceğini belirlemektedir. Böylece hesaplanan ağırlık değerlerinin yerel optimuma takılıp kalması riski önlenmektedir. Çıktı ve hata çarpımının başına getirilecek çarpana ise "öğrenme hızı" denmektedir. Öğrenme hızı, ağ eğitiminin ne kadar süreceğini belirlemektedir. Yavaş öğrenme güçlü ağlar oluştururken, hızlı öğrenme zayıf ağlar oluşturmaktadır. Bununla birlikte yavaş öğrenme neticesinde adım büyüklüğü azalacağından, özellikle yerel minimumlara rastlandığında öğrenme yavaşlayıp durma riski mevcuttur. Öğrenme hızı terimi, 0 - 1 arasında değer alabilmektedir. Sayı ne kadar yüksekse öğrenme hızı o kadar yüksektir. Tecrübeler $0.01 \leq \eta \leq 0.9$ aralığında seçilen öğrenme hızının iyi sonuçlar verdiğini göstermektedir.


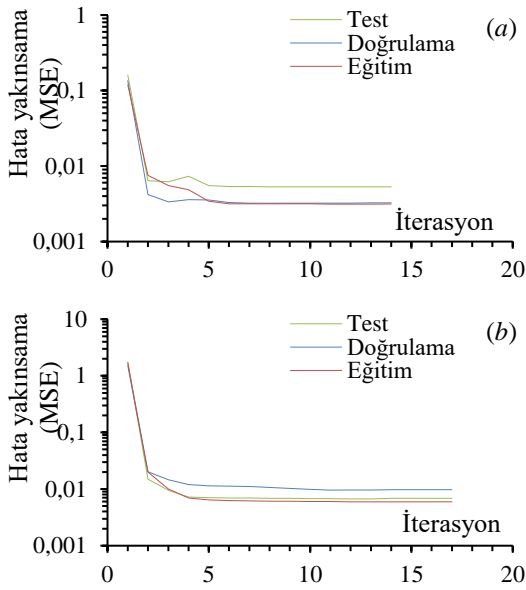
Veri kümesi esasen başlangıçta ikiye ayrıldı. İlk 60% (eğitim+test+doğrulama), son 40% tahmin için kullanılmıştır. %60'lık ilk bölüm ise ayrıca üç parçaya %70, %15 ve %15 (eğitim, test ve doğrulama)

bölünmüştür. Literatürde veri kümesi bölümlenmesinin rastgele yapıldığı görülmüştür (Çavuşlu ve ark. 2012).

4. Sonuçlar ve Tartışma (Results and Discussions)

4.1. Doğrulama (Validation)

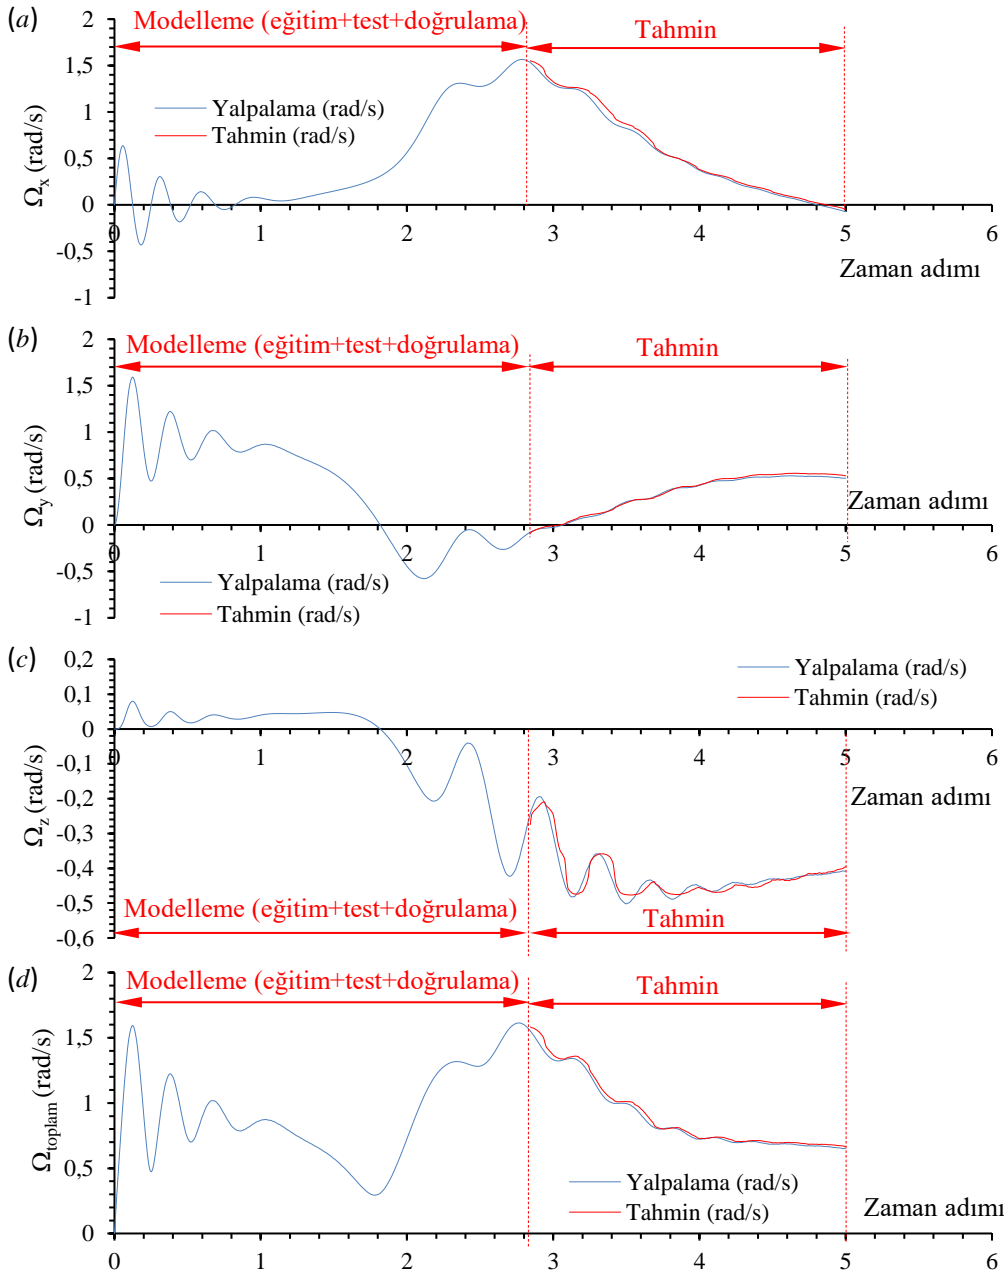
Eğitim esnasında izlenen MSE'deki hata yakınsama eğrileri Şekil 4'te verilmiştir. Eğriler incelendiğinde genel olarak eğitim, test ve doğrulama esnasında hatanın gittikçe sifıra yaklaştığı ve bu esnada da hatanın değişiminde herhangi bir sapma olmadığı görülmektedir. Bu durum ağların eğitimleri esnasında kararlılıklarını kaybetmediğini göstermektedir.



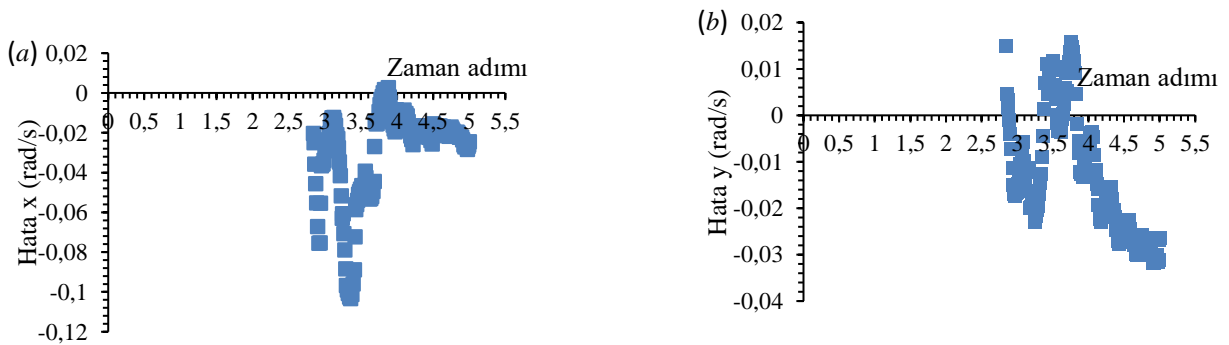
Şekil 4. Ağın eğitimi sırasında (a) x doğrultusundaki (b) y doğrultusundaki (c) z doğrultusundaki (d) bileşke yalpalamadaki hata yakınsaması, dikey eksen logaritmiktir (Error convergence during training of the networks where vertical axis is logarithmic (a) the network to predict the precession in the x-direction, (b) y-direction, (c) z-direction, (d) the resultant precession)


4.2. Tahmin eğrileri (Prediction curves)

Modellerinin tahmin eğrileri sırasıyla Şekil 5'te karşılaştırılmıştır. Ağlar eğitim, test ve doğrulama sırasında tahmin verilerini bilmemekteydiler. Veri kümesinin son %40'lik kısmı, eğitime başlamadan önce tahmin için ayrılmıştı. Şekil 6'da yatay ekseninde zaman adımı hâlinde hata (veri seti ile model tahmin değerleri arasındaki fark) değerleri verilmiştir. Böylece her bir zaman adımıdaki ve her bir verideki hata tek tek görülebilmektedir. Fark hesaplaması model tahmini ve veri seti arasında yapıldığından dolayı verinin sadece test kısmına denk gelen kısmı görülmektedir. Farkın küçük olması, modelin tahmin ettiği değerlerin, veri setindeki değerlere çok yakın olduğu ve böylece model performansının yüksek olduğu anlamına gelmektedir.



Şekil 5. Ağın (a) x doğrultusundaki, (b) y doğrultusundaki, (c) z doğrultusundaki, (d) toplam yalpalama hızı (The precession in (a) x-direction, (b) y-direction, (c) z-direction, (d) the resultant precession)





Şekil 6. Ağın tahmini ile veri seti arasındaki fark (a) x doğrultusundaki, (b) y doğrultusundaki, (c) z doğrultusundaki, (d) bileşke yalpalamadaki hata (Difference between the network's prediction and the data set (a) error in x -direction, (b) error in y -direction, (c) error in z -direction, (d) error in the resultant precession)

Tablo 4'te NAR ağının tahmin performans metrikleri verilmiştir. Tüm veri için en fazla iterasyon sayısı 34 olmuştur. Tüm veri için yüksek ve pozitif korelasyon görülmektedir. Bu durum, oluşturulan ağların yaptığı tahminlerin, veri seti ile yüksek uyuma sahip olduğunu göstermektedir. Ancak tek başına yüksek korelasyon, modelin yüksek performansa sahip olduğunu ispata yeterli değildir. Bu nedenle hata metrikleri de incelenmiştir. RMSE metriğinin en yüksek değeri, Ω_y verisinde $\cong 0.124$ rad/s olmaktadır. Bu durum MSE, MAPE, MAE metriklerinde de benzerdir. En düşük hata ise Ω_y tahminlemede oluşmaktadır.

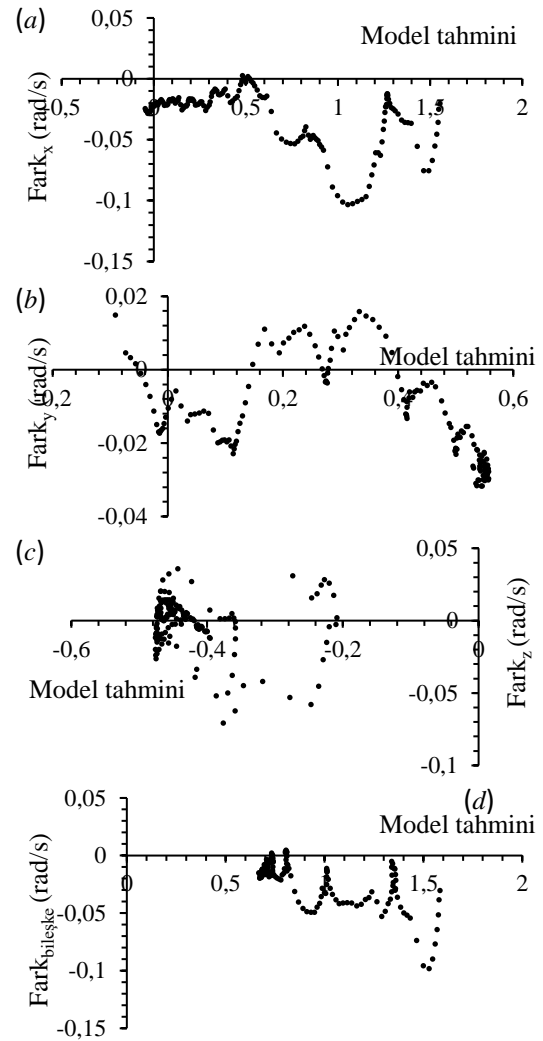
Tablo 4. NAR ağının tahmin performans metrikleri (Prediction performance metrics of the NAR net)

Yalpalama (rad/s)	Ω_x	Ω_y	Ω_z	$\Omega_{bileşke}$
MAE (birim)*	0.032	0.007	0.014	0.02
MAPE (%)	3.543	2.387	-3.408	1.61
Hata (birim)	0.032	0.007	0.014	0.02
MSE (birim ²)	0.015	0	0.001	0.011
RMSE (birim)	0.124	0.016	0.031	0.106
Hesaplama süresi (s)	0.709	0.941	0.726	0.927
R	0.971	0.998	0.922	0.928
İterasyon (adet)	12	13	10	34

(*) Birimler değişkenlerin birimi (rad/s) ile aynıdır.

Şekil 7'de yatay ekseninde model tahmini hâlinde hata (veri seti ile model tahmin değerleri arasındaki fark)

değerleri verilmiştir. Böylece tahmin edilen değer arttıkça her bir verideki hatanın değişim biçimi görülebilmektedir. Bu sayede değerlerde varyansın değişip-değişmediği hakkında fikir elde edilebilmektedir. Değişen varyans istenmeyen bir durumdur çünkü en küçük kareler regresyonu, sabit varyansa varsayımına dayanmaktadır. Yani varyans sabit ise regresyon sonucu doğru olmaktadır. Şekillerde dağılımın salınım yapmakla birlikte sabit varyansa sahip olduğu ve sifıra yakın rastgele dağıldığı görülmektedir. Sabit ve rastgele dağılımlar sabit varyansı temsil etmektedir. Engle'nin ARCH testine göre ham veriler değişken varyans içermekteydi. Bununla birlikte, NAR modellerinin sabit varyansa sahip olması, değişken varyansa sahip ham veriler için herhangi bir ön işleme gereksiniminin ortadan kaldırıldığını göstermektedir.



Şekil 7. Ağın tahmini ve fark dağılımı (a) x doğrultusundaki, (b) y doğrultusundaki, (c) z doğrultusundaki, (d) bileşke yalpalama (Estimation and difference distribution of the network (a) x -direction, (b) y -direction, (c) z -direction, (d) the resultant precession)

4.3. Tartışma (Discussion)

Jiroskop modelleme çalışmalarında sıklıkla regresyon ve nadiren SVM, HMM yöntemlerinin kullanıldığı görülmektedir. NAR ağı veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır. Genel veri eğrisini yakalayabilmenin yanı sıra eğrideki tepe ve çukurları da yakalayabilmiştir. Modelin performans göstergesi olarak MAE, MAPE, Kalıntı, MSE, RMSE, R değeri kullanılmıştır. $R=0.998$, $RMSE=0.016$ rad/s değerleri elde edilebilmiştir. Shi ve ark. (2019) RMSE hatasını BP yöntemi için 0.0135 °C, SVM yönteminde 0.0151 °C ve LSTM yönteminde 0.0112 °C olarak bulmuştur (Shi vd., 2019). NAR yönteminin BP, SVM ve LSTM yöntemleriyle kıyaslanabilir nitelikte iyiliğe sahip olduğu söylenebilmektedir. Nikkhah ve ark. (2009) bir mekanik jiroskoptaki rastgele bozucu ve gürültüler nedeni ile oluşan hataları tahmin etmek üzere doğrusal ve doğrusal olmayan AR, ARMA, ANFIS ve NAR yöntemlerinin kullanımını araştırmış ve NAR ağının rasgele kayma analizi ve telafisi için en iyi çözüm olduğunu bildirmiştir (Nikkhah vd., 2009). Wang ve ark. (2022) yüksek hızda dönen hava ve uzay araçlarının tutum değişikliği parametrelerini tahmin etmek ve çözmek için BP, kapalı tekrarlayan birim (GRU), LSTM, BILSTM ağırları kullanmışlardır. Simülasyon ve deney sonuçlarının BILSTM'nin tahmin doğruluğunun diğerlerine kıyasla daha iyi olduğunu göstermiştir (Wang vd., 2022). Muthusamy ve Kumar (2022) uydularda kullanılan CMG'lerin hasar ve geriye kalan faydalı ömür tahmininde veriye dayalı bir model geliştirmek için Chebyshev sinir ağı kullanılmıştır. Model, çevrimiçi tahmin için %30 veri mevcut olduğunda %96,25 doğrulukla çalışmıştır (Muthusamy ve Kumar, 2022). Yang ve ark. (2023) jiroskobun kapalı döngü alt uzay

öngörülü kontrolünü gerçekleştirmişlerdir. CMG'lerin yörünge izleme problemi için bir çözüm sunmaktadır. Bu amaçla kapalı döngü alt uzay öngörülü kontrolü (CSPC) yöntemi kullanılmıştır. Konum kontrolü 0.0128 ° ortalama bağıl kare hatası ile sağlanabilmiştir (Yang vd., 2023). Wisesa ve Mahardika (2018) LSTM ağırları kullanarak jiroskobun ivmeölçer verilerine dayalı olarak hasar algılama modeli geliştirmişlerdir (Wisesa ve Mahardika, 2019). İvme tahmininde eğitim esnasında % 91,43 doğruluk (x doğrultusunda) elde ederken test esnasında % 92,31 doğruluk elde etmiştir. Yang ve ark. (2022) akıllı telefonlardaki ivme ölçmede kullanılan jiroskop sayesinde insan aktivitesi tanıma için aktivite grafiği tabanlı konvolüsyonel sinir ağı (CNN) kullanmışlardır (Yang vd., 2022). CNN modelinin ortalama tanıma doğruluğunu yaklaşık %5-10 arasında artırdığı bildirilmiştir. Huang vd (2022) derin öğrenmeye dayalı bir MEMS IMU jiroskop kalibrasyon yöntemi kullanmışlardır (Huang vd., 2022). Temporal convolutional ağ (TCN) kullanılmıştır. Modelin tutum ve konum doğruluğunun iyileştirildiği bildirilmiştir. Bu da önerilen yöntemin jiroskop hatasını etkili ve doğru bir şekilde kalibre edebileceğini kanıtlamaktadır.

Farklı modellere ait metriklerinin karşılaştırılması: Tablo 5'te verilmiştir. Tablodan görülmektedir ki literatürde çok farklı modeller kullanılmış, bununla birlikte farklı değişkenler incelenmiştir. Bu nedenle mevcut çalışma ile doğrudan kıyaslamak yerine her çalışmadaki farklı parametrelerin kendileri içerisinde değerlendirilmesi yapılabilmektedir. Bununla birlikte ML yöntemlerinin, diğer yöntemlere göre daha başarılı olduğu sonucu çıkartılabilmektedir. Bu hâli ile mevcut çalışmanın yalpalama tahmini konusunda özgünlük içerdiği anlaşılmaktadır.

Tablo 5. Farklı modellere ait metrikler

	Hata (birim)	RMSE (birim)	Doğruluk (%)	Metot
<i>Mevcut çalışma</i>	0.007 rad/s	0.016 rad/s	--	NAR
(Shi vd., 2019)	--	0.0112 °C	--	LSTM
(Shi vd., 2019)	--	0.0151°C	--	SVM
(Shi vd., 2019)	--	0.0135 °C	--	BP
(ZhouHu, 2008)	-0.0111 rad/s	--	--	ARMA
(Montoya-Chairez vd. , 2019)	13.25°	--	--	PD
(Montoya-Chairez vd., 2019)	1.3336°	--	--	PID
(Montoya-Chairez vd., 2019)	0.74515°	--	--	Adaptif
(Montoya-Chairez vd., 2019)	0.184°	--	--	YSA
(Pan vd. , 2019)	--	0.013 mrad/s	--	PID
(İbrahim vd. , 2023)	--	2.013 pulse/s	--	LSTM

(Muthusamy and Kumar 2022	--	--	96,25	Chebyshev NN
Yang, Wu et al. 2023		0.0128°	--	CSPC
(Wisesa and Mahardika 2019	--	--	92,31	LSTM
(P. Yang vd., 2022)	--	--	5-10 artış	CNN

5. Sonuçlar (Conclusions)

Bu çalışmada bir mekanik jiroskobun dinamik analizi yapılarak elde edilen yalpalama verisinin NAR ağı ile modellenmesi sağlanmıştır. Model performansı araştırılmıştır. Mekanik jiroskopların kullanım alanları havacılık, uzay ve otonom sürüş alanları olduğu için model tahminlerinin isabetli olması bu alanda faaliyet gösteren firmalar için faydalı olacaktır. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Yalpalama hızının tahmininde NAR ağı hem eğri genel şeklini hem de eğrilerdeki pik ve çukurları yüksek temsil yeteneğine sahiptir. NAR ağı veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır.
- $R=0.998$, $RMSE=0.016$ rad/s değerleri elde edilmiştir olup model çıktısı ile veri seti arasında yüksek ilişki mevcuttur.

6. Destek ve Teşekkür Beyanı (Statement of Support and Acknowledgments)

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

7. Çatışma Beyanı (Conflict Declaration)

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

8. Teşekkür (Acknowledgment)

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.

Kaynaklar (References)

Ahmed, A., Adnaik, I., Bhavsar, D., & Sargar, T. S. (2016). Design and Analysis of Gyro Wheel for Stabilization of a Bicycle. *International Journal for Scientific Research & Development*, 4(04), 349-351.

Amini, G., Salehi, F., & Rasouli, M. (2021). Drying kinetics of basil seed mucilage in an infrared dryer: Application of GA-ANN and ANFIS for the prediction of drying time and moisture ratio. *Journal of Food Processing and Preservation*, 45(3), e15258. doi: 10.1111/jfpp.15258

Amiroh, K., Rahmawati, D., & Wicaksono, A. Y. (2021). Intelligent System for Fall Prediction Based on Accelerometer and Gyroscope of Fatal Injury in Geriatric. *Jurnal Nasional Teknik Elektro*, 10(3). doi: 10.25077/jnte.v10n3.936.2021

Anonimouse. (2023). Precession *Wikipedia®*. en.wikipedia.org: Wikimedia Foundation, Inc.,.

Ansys®. (2023). Academic Research Mechanical Products, 2021 R2, Help System, ANSYS Mechanical User's Guide: ANSYS, Inc.

Beigi, M., & Torki, M. (2021). Experimental and ANN modeling study on microwave dried onion slices. *Heat and Mass Transfer*, 57, 787-796.

Çavuşlu, M. A., Becerikli, Y., & Karakuzu, C. (2012). Hardware implementation of neural network training with Levenberg-Marquardt algorithm. *TBV Journal of Computer Science and Engineering*, 5(1), 1-7.

Dash, S., & Venkatasubramanian, V. (2000). Challenges in the industrial applications of fault diagnostic systems. *Computers & Chemical Engineering*, 24(2-7), 785-791.

Dong, L., Wang, J., Tseng, M.-L., Yang, Z., Ma, B., & Li, L.-L. (2020). Gyro Motor State Evaluation and Prediction Using the Extended Hidden Markov Model. *Symmetry*, 12(11). doi:10.3390/sym12111750

Fan, Y., Ding, H., Li, M., & Li, J. (2018). Modal Analysis of a Thick-Disk Rotor with Interference Fit Using Finite Element Method. *Mathematical Problems in Engineering*, 2018, 5021245. doi: 10.1155/2018/5021245

He, Z., Wen, T., Zhang, X., Li, H., Chen, X., & Liu, X. (2022, 25-27 Nov. 2022). *Multi-physics Coupling and Thermal Network Analysis of MSCMG*. Paper presented at the 2022 China Automation Congress (CAC).

Heaton, J. (2008). *Introduction to Neural Networks with Java*: Heaton Research.

Heris, M. K. (2015). Time-series prediction using ANFIS. *The Yarpiz Project, Fuzzy Systems*.

HosseinTabari, Kisi, O., Ezani, A., & Talaei, P. H. (2012). SVM, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. *Journal of Hydrology*, 444-445, 78-89. doi: 10.1016/j.jhydrol.2012.04.007

Huang, F., Wang, Z., Xing, L., & Gao, C. (2022). A MEMS IMU Gyroscope Calibration Method Based on Deep Learning. *Ieee Transactions on Instrumentation and Measurement*, 71, 1-9. doi: 10.1109/TIM.2022.3160538

- Ibrahim, M., Badran, K., & Esmat, A. (2023). Anomaly Detection for Agile Satellite Attitude Control System Using Hybrid Deep-Learning Technique. *Aiaa Journal*, <https://doi.org/10.2514/2511.I011280>. doi: 10.2514/1.I011280
- Jamil, F., & Kim, D. (2019). Improving Accuracy of the Alpha-Beta Filter Algorithm Using an ANN-Based Learning Mechanism in Indoor Navigation System. *Sensors*, *19*, 3946. doi: 10.3390/s19183946
- Kacar, İ., Eroğlu, M. A., & Yalçın, M. K. (2021). Design and development of an autonomous bicycle. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, *10*(1), 364-372. doi: 10.28948/ngumuh.628580
- Kathpalia, N., & Gulati, T. (2022). 3 Axis Gyro Accelerometer & Artificial Intelligence based Enhancement of GPS Accuracy. *Measurement: Sensors*, 100618. doi: <https://doi.org/10.1016/j.measen.2022.100618>
- Kostyuchenko, T., & Indygasheva, N. (2018). Computer-aided design system for control moment gyroscope. *MATEC Web Conf.*, *158*, 01021.
- Kownacki, C. (2011). Optimization approach to adapt Kalman filters for the real-time application of accelerometer and gyroscope signals' filtering. *Digital Signal Processing*, *21*(1), 131-140. doi: 10.1016/j.dsp.2010.09.001
- Masters, T. (1993). *Practical Neural Network Recipes in C++*. Elsevier Inc. : Academic Press.
- Montoya-Chairez, J., Santibanez, V., & Moreno-Valenzuela, J. (2019). Adaptive control schemes applied to a control moment gyroscope of 2 degrees of freedom. *Mechatronics*, *57*, 73-85. doi: 10.1016/j.mechatronics.2018.11.011
- Muthusamy, V., & Kumar, K. D. (2022). Failure prognosis and remaining useful life prediction of control moment gyroscopes onboard satellites. *Advances in Space Research*, *69*(1), 718-726. doi: <https://doi.org/10.1016/j.asr.2021.09.016>
- Nikkhah, A., Heydari, P., Khaloozadeh, H., & Heydari, A. (2009). Gyroscope Random Drift Modeling, Using Neural Networks, Fuzzy Neural and Traditional Time-Series Methods. 6.
- NI, C. (2023). Gyroscope physics. *Cleonis*, *1*(1), 1.
- Nuswanto, F. M., Sudarsono, A., & Santoso, T. B. (2020, 29-30 Sept. 2020). *Abnormal Driving Detection Based on Accelerometer and Gyroscope Sensor on Smartphone using Artificial Neural Network (ANN) Algorithm*. Paper presented at the 2020 International Electronics Symposium (IES).
- Öğündür, G. (2019). Overfitting, underfitting and bias-variance contradiction. Retrieved 12.12.2020, 2020, from <https://medium.com>
- Osman, M. O. M., Sankar, S., & Dukkipati, R. V. (1982). Design synthesis of a gyrogrinder using direct search optimization. *Mechanism and Machine Theory*, *17*(1), 33-45. doi: 10.1016/0094-114X(82)90022-2
- Pan, S., Xu, Z., & Zhao, C. (2019). A novel single-gimbal control moment gyroscope driven by an ultrasonic motor. *Advances in Mechanical Engineering*, *11*(4), 1687814019844382. doi: 10.1177/1687814019844382
- Papakonstantinou, C., Daramouskas, I., Lappas, V., Moulitanitis, V. C., & Kostopoulos, V. (2022). A Machine Learning Approach for Global Steering Control Moment Gyroscope Clusters. *Aerospace*, *9*(3). doi:10.3390/aerospace9030164
- Rachmatullah, M. I. C., Santoso, J., & Surendro, K. (2020). A Novel Approach in Determining Neural Networks Architecture to Classify Data With Large Number of Attributes. *Ieee Access*, *8*, 204728-204743. doi: 10.1109/ACCESS.2020.3036853
- Sartori, M. A., & Antsaklis, P. J. (1991). A simple method to derive bounds on the size and to train multilayer neural networks. *IEEE Transactions on Neural Networks*, *2*(4), 467-471. doi: 10.1109/72.88168
- Shen, L., Zhu, Y., Liu, C., Wang, W., Liu, H., Kamruzzaman, . . . Zheng, X. (2020). Modelling of moving drying process and analysis of drying characteristics for germinated brown rice under continuous microwave drying. *Biosystems Engineering*, *195*, 64-88.
- Shi, H., Hu, S., & Zhang, J. (2019). LSTM based prediction algorithm and abnormal change detection for temperature in aerospace gyroscope shell. *International Journal of Intelligent Computing and Cybernetics*, *12*(2), 274-291. doi: 10.1108/IJICC-11-2018-0152
- Sucuoglu, H. S., Bogrekci, I., Gultekin, A., & Demircioglu, P. (2018). Design, Analysis and Development of Mobile Robot with Flip-Flop Motion Ability. *IFAC-PapersOnLine*, *51*(30), 436-440. doi: <https://doi.org/10.1016/j.ifacol.2018.11.323>
- Sun, J., Cai, Z., Sun, J., & Jin, D. (2023). Dynamic analysis of a rigid-flexible inflatable space structure coupled with control moment gyroscopes. *Nonlinear Dynamics*, *111*(9), 8061-8081. doi: 10.1007/s11071-023-08254-8
- Taheri, S., Brodie, G., & Gupta, D. (2021). Optimised ANN and SVR models for online prediction of moisture content and temperature of lentil seeds in a microwave fluidised bed dryer. *Computers and Electronics in Agriculture*, *182*, 106003. doi: 10.1016/j.compag.2021.106003
- Tamura, S., & Tateishi, M. (1997). Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Transactions on Neural Networks*, *8*(2), 251-255. doi: 10.1109/72.557662
- Tobon-Mejia, D. A., Medjaher, K., Zerhouni, N., & Tripot, G. (2012). A Data-Driven Failure Prognostics Method Based on Mixture of Gaussians Hidden Markov Models. *IEEE Transactions on Reliability*, *61*(2), 491-503. doi: 10.1109/TR.2012.2194177

- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., & Yin, K. (2003). A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers & Chemical Engineering*, 27(3), 327-346. doi: 10.1016/S0098-1354(02)00162-X
- Wang, J. W., Deng, Z. H., & Shen, K. (2022). Virtual Gyros Construction and Evaluation Method Based on BILSTM. *Ieee Transactions on Instrumentation and Measurement*, 71. doi: 10.1109/TIM.2022.3212544
- Wisesa, I., & Mahardika, G. (2019). Fall detection algorithm based on accelerometer and gyroscope sensor data using Recurrent Neural Networks. *IOP Conference Series: Earth and Environmental Science*, 258, 012035. doi: 10.1088/1755-1315/258/1/012035
- Xiu, T., Yue-dong, L., Xin-xiao, L., & Er-yong, H. (2021). Structural Engineering Analysis for a Control Moment Gyroscope Framework. *Journal of Physics: Conference Series*, 1939, 012119. doi: 10.1088/1742-6596/1939/1/012119
- Yang, P., Yang, C., Lanfranchi, V., & Ciravegna, F. (2022). Activity Graph Based Convolutional Neural Network for Human Activity Recognition Using Acceleration and Gyroscope Data. *IEEE Transactions on Industrial Informatics*, 18(10), 6619-6630. doi: 10.1109/TII.2022.3142315
- Yang, X., Wu, X., Yu, X., & Basin, M. V. (2023). Closed-Loop Subspace Predictive Control of Gyroscope. *Ieee Transactions on Industrial Electronics*, 1-10. doi: 10.1109/TIE.2023.3286008
- Zhou, Z.-J., & Hu, C.-H. (2008). An effective hybrid approach based on grey and ARMA for forecasting gyro drift. *Chaos, Solitons & Fractals*, 35(3), 525-529. doi: 10.1016/j.chaos.2006.05.039