



Bir Mekanik Jiroskopun Yalpalama Tahmininde Uzun Kısa Süreli Bellek Ağı Yaklaşımı

Long-short-term memory network approach to forecast the precession of a mechanical gyroscope

İlyas KAÇAR¹

¹Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Niğde, TÜRKİYE

Başyuru/Received: 07/05/2023

Kabul / Accepted: 29/09/2023

Çevrimiçi Basım / Published Online: 31/12/2023

Son Versiyon/Final Version: 31/12/2023

Öz

Mekanik jiroskoplar, ürettikleri jiroskopik tork sayesinde hava ve uzay araçları gibi tamamen asılı duran araçlara yön vermek için kullanılmaktadır. Kara araçlarında da tek veya iki tekerlekli araçların otonom dengesi için kullanılmaktadır. Her ne kadar uzun yıllardır regresyonlar mevcut veriyi modelleme amaçlı kullanılagelen bir yöntem olmuşsa da son yıllarda makine ve derin öğrenme yöntemlerinin sınıflama, modelleme konularında yüksek başarıya sahip oldukları görülmüştür. Bu çalışmada bir derin öğrenme yöntemi olan uzun kısa süreli bellek ağı kullanılarak mekanik bir jiroskopun yalpalama hızı tahmin edilmiştir. Elde edilen modelde RMSE 0.0055 rad/s iken ME değeri -0.0012 rad/s ve R ise 0.9998 olup model çıktısı ile veri seti arasında yüksek ilişki mevcuttur. Netice olarak derin öğrenme yöntemlerinin mekanik jiroskop tasarımlarında kullanılmasının mümkün olduğu görülmüştür.

Anahtar Kelimeler

“Jiroskop, Makine öğrenimi, Uzun kısa süreli hafıza, Yalpalama”

Abstract

Mechanical gyroscopes are used to orient fully suspended vehicles such as air and space vehicles, thanks to the gyroscopic torque which they produce. It is also used in land vehicles for the autonomous balance of single or two-wheeled vehicles. Although regressions have been used for modeling existing data for many years, it has been seen that machine and deep learning methods have had higher success in classification and modeling in recent years. In this study, the precession of a mechanical gyroscope was forecasted using a long-short-term memory network, a deep learning method. In the model obtained, the RMSE was 0.0055 rad/s, the ME value was -0.0012 rad/s, and the R was 0.9998, and there was a high correlation between the model output and the dataset. As a result, it is possible to usage of deep learning methods in mechanical gyroscope designs.

Key Words

“Gyroscope, Machine Learning, Long short-term memory, Precession”

1. Giriş

Jiroskopların mekanik, optik ve elektromekanik türleri mevcuttur. Temel kullanım alanları, yön tayini olsa da, mekanik jiroskoplar, ürettikleri "jiroskopik tork" sayesinde hava ve uzay araçları gibi tamamen asılı duran araçlara yön vermek için kullanılmaktadır. Karada ise tek veya iki tekerlekli otonom araçların dengesi için kullanılmaktadır. Tamamen endüstriye ve savunma sanayilerine yönelik özel bir araçtır. Momentum değiştiricilerdir. Bu sayede jiroskopik tork olarak adlandırılan bir tork üretebilmektedirler. Mekanik jiroskopların türleri mevcuttur. Bu çalışmada ağırlık ve yalpalama hızının sayesinde jiroskopik tork üreten jiroskoplar ele alınmaktadır. Ancak gereken jiroskopik torkun üretilebilmesi için hangi ağırlıkta hangi yalpalama hızı verilmesi gerektiğinin hesaplanması bu cihazların tasarım aşamasında önemlidir.

Literatür çalışmaları, tahmin yöntemlerinin öneminin tüm dünyada giderek arttığını göstermektedir. Araştırmacılar, gerekli jiroskopik torku üretecek yalpalama hızının tahmini için analitik formüller veya simülasyon yöntemleri kullanılmaktadır. Ancak kompleks geometriler için analitik formüller kısıtlıdır. Formüle uyması için geometri üzerinde basitleştirme yapmak ise sonuçtaki hata miktarını artırmaktadır. Bu durumlarda dinamik simülasyonlardan faydalandığı görülmektedir (Osman, Sankar, & Dukkipati, 1982). Simülasyonlar belli şartlar altında, incelenen olayın çoklu fizik sonuçlarını görebilmeye, güvenilir sonuçlar elde edilmesine olanak sağlamaktadır (Kownacki, 2011). Kontrol moment jiroskopları (CMG) bulunan bir uzay aracının dinamik analizi yapılarak titreşimlerin, faydalı yüklerin performansı üzerindeki olumsuz etkisi incelenmiştir (Sun, Cai, Sun, & Jin, 2023). Rijit dinamik analiz sayesinde bir mobil robotun güç gereksinimi hesaplanabilmiştir (Sucuoğlu, Bogrekcı, Gultekin, & Demircioğlu, 2018). Üzerinde 5 kg yük bulunan ve 17.5 kg kütledeki iki tekerlekli bir bisikletin otonom sürüşünü sağlayabilmek için dengeleme amaçlı olarak kullanılacak bir CMG'nin 30Nm'lik tork gereksinimine sahip olacağı dinamik simülasyon neticesinde bildirilmiştir (Kacar, Eroğlu, & Yalçın, 2021). 20.5 kg kütleli bir bisiklet tekerleğini dengelemek için 9.25 Nm reaktif jiroskopik tork gerekeceği analitik formüllerle hesaplanmıştır (Ahmed, Adnaik, Bhavsar, & Sargar, 2016). Modal analiz sayesinde de ortasında disk bulunan ve iki ucu yataklanmış bir milden oluşan mekanik jiroskobun kritik frekansları hesaplanabilmiştir (Fan, Ding, Li, & Li, 2018). Yapısal analiz ve optimizasyon sayesinde modelin dinamik özelliklerinin büyük ölçüde iyileştirildiği (Xiu, Yue-dong, Xin-xiao, & Er-yong, 2021), oluşan gerilmelerin izin verilen sınır altında kaldığı görülmüştür (Ahmed et al., 2016; Z. He et al., 2022; Xiu et al., 2021). CMG tasarımlarının yüksek hassasiyetli simülasyonu sayesinde karmaşık elektromekanik cihazların hızlı ve hatasız geliştirilmesi mümkün olmaktadır. Aynı zamanda optimum çalışma özellikleri elde edilebilmektedir. Tüm bu hususlar bir mekanik jiroskop tasarımının temelini oluşturmaktadır (Kostyuchenko & Indygashva, 2018).

Arıza teşhis ve tahmin yöntemleri (Amiroh, Rahmawati, & Wicaksono, 2021), *model* ve *veri* esaslı olmak üzere iki kategoriye ayrılmaktadır (Tobon-Mejia, Medjaher, Zerhouni, & Tripot, 2012). Model esaslı olanlar kesin fizik çıkarımlarına dayanmaktadır ve kesin çözüm vermektedirler. Tahminleri, artık (fark) kullanarak yapmaktadırlar. Bununla birlikte, gerçek sistemlerin karmaşık doğası nedeniyle bu tür matematiksel modellerin karmaşık geometrilere sahip cisimler için oluşturulabilmesi nispeten zordur, bazen imkânsızdır. Gerçek sistemlerin karmaşık yapısını, kabullerle basitleştirmek mümkün olsa da ne denli çok kabul yapılırsa sonuçlar üzerinde o denli çok hata oluşmasına yol açmaktadır. Veri esaslı yöntemler ise sistemden çıkarılan veri setini ve istatistiksel özellikleri öğrenerek tahmin gerçekleştirmektedir. Karmaşık sistemlerin tanımlanması için tercih edilmektedir. Dash ve ark. (2000) her iki yöntemin derinlemesine araştırmasını ve karşılaştırmasını yapmış ve veriye dayalı yöntemlerin daha avantajlı olduğu sonucuna varmıştır (Dash & Venkatasubramanian, 2000) ve Venkatasubramanian ve ark. (2003) (Venkatasubramanian, Rengaswamy, Kavuri, & Yin, 2003). Veriye dayalı yöntem ayrıca iki kategoriye ayrılmaktadır: Biri, sinir ağı ve bulanık mantık tarafından temsil edilen yapay zekâ yöntemleri ve diğeri ise istatistiksel öğrenme yöntemleridir (destek vektör makinesi (SVM) ve gizli Markov modeli (HMM) vs...) (Dong et al., 2020).

ARIMA, SARIMA, SARIMAX, Poisson Oto-Regresif, Doğrusal vs... gibi regresyonlar sürecin gözlemlenebilir kısmı temsil etmek için uygun modellerdir. Gözlemlenemeyen sürecin tahmini ise HMM, SVM ile mümkündür.

Seyrüsefer sisteminde yapay sinir ağları (YSA) kullanılarak filtre algoritmasının doğruluğu artırılmıştır (Jamil & Kim, 2019). HMM kullanılarak jiroskop motorunun durum değerlendirmesi ve tahmini yüksek hassasiyetle gerçekleştirilmiştir (Dong et al., 2020). Tek eksenli jiroskopta tahmin yöntemi olarak SVM kullanılmıştır (Miao, Li, & Ye, 2015; Song, Hu, & Zhou, 2017; Xudong, Pengfei, Yuanping, & Xingwu, 2013). Jiroskoplarda kayma olarak adlandırılan hatanın tahmininde gri ve Box-Jenkins otoregresif hareketli ortalama (Box-Jenkins ARMA) modellerine dayanan hibrit bir modelleme ve tahmin yaklaşımının başarısı sunulmuş ve kullanılması önerilmiştir (Zhou & Hu, 2008). Sıcaklıktaki anormal değişiklikler, bir jiroskopun kararlılığını ve güvenilirliğini doğrudan etkilemektedir. Sıcaklığın tahmin edilmesi ve anormal değişimin saptanması, jiroskopun çalışma durumunun zamanında anlaşılması için büyük önem taşımaktadır. Sıcaklık verilerini tahmin etmek için çift gizli katmanlı uzun-kısa süreli bellek (LSTM) ağı kullanılmış ve tahmin performansı da geriye yayılım (BP) ağı, SVM ile karşılaştırılmıştır (Shi, Hu, & Zhang, 2019). BP algoritması ve Gauss-Newton algoritması ile sıcaklık sapması (X. Chen, 2004) ve rasgele sapmalar modellenmiştir (X. Chen, 2003). BP ve RBF (radyal tabanlı fonksiyon) ağları sıcaklık sapma tahminlerinde sıklıkla kullanılmıştır (Zhu, Zhang, & Bo, 2000). Abbas vd. (2014), dört serbestlik dereceli bir kontrol momenti jiroskopu (CMG) için doğrusal parametre değiştiren (LPV) bir kontrol stratejisinin tasarımını ve deneysel doğrulamasını gerçekleştirmiştir. Önerilen LPV kontrolörü, literatürde bildirilen doğrusal kontrolörlerden çok daha geniş bir çalışma aralığında ve daha iyi bir performans elde etmiştir (Abbas, Ali, Hashemi, & Werner, 2014). He ve Zhao (2015) bir bisikleti dengelemek için CMG cihazının mekanik yapısını ve kontrol sistemini tasarlamışlardır. Sistemi kararlı tutmak amacıyla kutupları yapılandırmak için durum geri besleme kontrolünü kullanılmıştır. Deneysel çalışmada da geri besleme kontrol yönteminin bisikleti

dengede tutmak için kullanılabileceği gösterilmiştir (J. R. He & Zhao, 2015). Aranovskiy vd (2021) yürüyen bir robotun antropomorfik olmayan dinamik stabilizasyonu için çift kontrol momenti jiroskopu ile dengelenen 2D ters sarkaç tasarlamaşlardır. Bu ters sarkaç, bir robotun makul bir modelidir. Böylece sistem dinamiklerinin basitleştirilmiş ortamlarda incelenmesine olanak tanımaktadır (Aranovskiy et al., 2021). Montoya-Chairez vd. (2019) CMG'nin hareket kontrolü yapmışlardır. İlk olarak, geri besleme doğrusallaştırma tekniği kullanılarak bir yörünge izleme kontrolörü geliştirilmiştir. İkinci olarak, uyarlanabilir bir sinir ağı algoritması ve uyarlanabilir bir model regresör şemasına karşılık gelen iki yeni uyarlanabilir algoritma tanıtılmıştır. Doğrusal PD kontrol yasası, kademeli PID-PID kontrolör ve tanıtılan şemalar arasında gerçek zamanlı deneysel bir karşılaştırma yapılmıştır. Gerçek zamanlı deneysel çalışma, kontrolörlerin performansının girişte periyodik bir bozucu varken ve yokken değerlendirildiği tanıtılan teoriyi doğrulamıştır (Montoya-Chairez, Santibanez, & Moreno-Valenzuela, 2019). Pan vd. (2019) doğrudan ultrasonik bir motor tarafından tahrik edilen, tek gimbal kontrol momenti jiroskopunu tasarlamış ve optimize etmiştir. Jiroskopun dinamik bozukluğu ve ultrasonik motorun doğrusal olmayan özellikleri göz önünde bulundurularak, gimbal servo sistemi için iki serbestlik dereceli kutup yerleştirme kontrolörünü bir model muhakeme kontrolörü ile birleştiren bir uzman kontrol algoritması tasarlanmıştır. Sunulan kontrol momenti jiroskopu ve kontrol kartı üretilmiş ve deneyler için monte edilmiştir. Deneysel sonuçlar, CMG'nin yüksek hızlarda gimbal servo sistemi üzerinde neredeyse hiç bozucu etkisi olmadığını, ancak gimbal hızındaki düşüşle birlikte etkinin kademeli olarak arttığını göstermiştir (Pan, Xu, & Zhao, 2019). Li vd. (2022) tek-gimbal CMG için hata izolasyonu ve tahmini sorununu elde etmek üzere sinir ağı tabanlı bir hasar teşhis şeması önermektedir. Bu amaçla, hasar teşhisinin doğruluğunu artırmak için aktif bozulma önleme için sinir ağına dayalı bir gözlemci geliştirilmiştir. Yörüngedeki periyodik bozulma, sinir ağının uydurma ve hafıza yeteneğine başvurularak hasar ile ayrıştırılmıştır. Daha sonra, bilgi füzyonu fikrine dayalı olarak hasar teşhis şeması oluşturulmuştur. Uyarlanabilir tahmin edici ve sinir ağı yöntemleri kullanılarak hasar izolasyonu ve tahminini uygulamak için uzay aracı tutumu ve gimbal pozisyonu verileri birleştirilmiştir. Ardından, aktif hasar toleranslı bir kontrol elde etmek için bozulma ve hasar tahmin sonuçlarını içeren uyarlanabilir bir kayan kipli kontrolör tasarlanmıştır. Önerilen şemalar ve simülasyon sonuçları, önerilen şemanın daha iyi teşhis ve kontrol sonuçları elde ettiğini göstermiştir (Li, Hu, & Shao, 2022). Hibrit derin öğrenme tekniği kullanarak çevik uydu yönelim kontrol sistemi için anomali tespiti yapılabilmıştır (İbrahim, Badran, & Esmat, 2023).

Yazarların bilgisine göre, açık literatürde, LSTM ağı kullanarak jiroskop yalpalamasının zaman serisi tahminini içeren bir çalışma mevcut değildir. Bu çalışmada sonlu eleman simülasyonu esaslı rijit dinamik analiz ile elde edilmiş olan mekanik jiroskopun yalpalamasının zamana bağlı olarak modellenmesi için LSTM ağı kullanılmıştır. Sonuçlar göstermiştir ki LSTM ağı sayesinde yüksek korelasyona sahip bir tahmin modeli oluşturulabilmektedir. Bu modeli oluşturmak için kullanılan ağ parametreleri ve model ile elde edilen tahmin performansları çalışma içerisinde sunulmuştur.

2. Jiroskopik Tork


Ağırlık torkunu dengelemek suretiyle jiroskopik tork üreten bir mekanik jiroskopun cisme sabitlenmiş bir eksen takımına göre açısız momentumdaki değişimin genel denklemi, klasik (Newtonian) mekanik ile Eşitlik (1) ile hesaplanmaktadır.

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

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 açısız hızdır (Anonimouse, 2023). \vec{L} açısız momentum ve t ise zamandır. Bu eşitlik, simülasyon sonuçlarının doğrulanması için kullanılmıştır.

3. Dinamik Analiz ve Veri Toplama

Veri seti, sonlu eleman simülasyonu esaslı gerçekleştirilen bir rijit dinamik analizi neticesinde elde edilmiştir. Simülasyonlar, Ansys® yazılımı kullanılarak gerçekleştirilmiştir (Ansys®, 2023). Analiz, iki adımda ve toplam 5 saniye süreyi kapsayacak şekilde gerçekleştirilmiştir. Toplam 415 adet veri toplanmıştır. Bu hâli ile 83 Hz frekansında veri toplanmıştır. Ultrasonik motor ile sürülen bir CMG'nin dinamik davranışı için jiroskop dönmesinin 0.35 s boyunca incelendiği görülmüştür (Pan et al., 2019). Uydu davranış kontrolü için kullanılan bir CMG'nin açısının değerlendirilmesi için 10000 s inceleme yapılmıştır (İbrahim et al., 2023). İki serbestlik dereceli bir kontrol momenti jiroskopu (CMG) 15 saniye boyunca incelenmiştir (Montoya-Chairez et al., 2019). CMG ile kendinden dengeli bisikletlerin kontrol sistemi tasarımı esnasında 6 s çalışma süresi incelenmiştir (J. R. He & Zhao, 2015). Görülmektedir ki, uygulama alanına göre farklı süreler incelenmiştir. Bu çalışmada CMG'nin dengeleme işlemini beş saniye içerisinde gerçekleştirmek amaçlandığından dolayı CMG'nin 5 s'lik çalışma süresi analiz edilmiştir. Dinamik analizin iterasyonlarında, minimum zaman adımı $1.e-7$ s ve maksimum zaman adımı $5.e-2$ s olarak sınırlandırılmıştır. Her bir simülasyon, 3.40 GHz quad core CPU, 8 GB RAM özellikli bir bilgisayar ile 2.866 s sürmüştür. Volanın yatakları bağlandıdaki üç eksen etrafındaki ve bileşke yalpalama hızı kaydedilmiştir. Şekil 1'de bu çalışmada kullanılan ağırlık dengeleme esaslı çalışan mekanik jiroskop gösterilmiştir. Bir adet volan mevcuttur. Tasarım sayesinde volanın hem kendi eksenini etrafında hem de diğer iki eksen etrafında dönme hareketi serbesttir. Yerçekimi ivmesi uygulanmıştır. Analizde kullanılan modelin sahip olduğu ana varsayımlar şunlardır: (1) malzemede sönümleme yok, (2) yatak sürtünmeleri ihmal edilmiştir (3) yatak veya temas yüzeyleri tamamen temas halinde, (4) diğer dış koşullar dikkate alınmamaktadır (5) Bütün parçalar, rijit cisimdir. Bu nedenle esneme, kopma vb. deformasyonlar mümkün değildir.



Şekil 1. Çalışmada kullanılan mekanik jiroskop (NI, 2023) (a) kavramsal tasarımı; (b) ağırlık uygulanması hali

Temas çifti kullanılmamıştır. Dolayısıyla eleman ağı oluşturulmamıştır. Veri olarak yalpalama eksenindeki açısal hızın bileşkesi ve bileşenleri kaydedilmiştir. Ağırlığa sebep olan ek kütedir. Ek kütle merkezinin, dönme merkezine uzaklığı $Tork_W = \vec{r} \times m\vec{g} = 0.03 * 1.59 * 9.8066 = 0.468 \text{ kgm}^2/s^2$ ile hesaplanan torkun oluşmasına sebep olmaktadır. Jiroskop ise bu torku dengeleyecek kadar yalpalama yapmaktadır.

Herhangi bir regresyondan önce, araştırmacılar, deneysel ham verilerdeki varyansı ve heteroskedastisiteyi ortadan kaldırmak, veri eğrisini yumuşatmak için sıklıkla veriye bazı ön işlemler uygulamaktadırlar (HosseinTabari, Kisi, Ezani, & Talae, 2012; Shen et al., 2020; Taheri, Brodie, & Gupta, 2021). Ancak hangi şiddette uygulanırsa uygulansın, her türlü ön işlem verinin doğallığını azaltmakta bu nedenle de olayı temsil yeteneğini düşürmektedir. Bu durumdan dolayı bu çalışmada ham veriler üzerine herhangi bir ön işlem yapılmamıştır. Dolayısıyla, genel eğri formuna ek olarak tepe ve çukurlukların tahmin edilebilmesi, LSTM ağıının ayırt edici özelliklerinden biri olacaktır. Ayrıca ham veriler üzerine değişen varyans testlerinden Engle's ARCH Testi uygulanmıştır. Ham verilerin değişen varyans içerdiği görülmüştür.


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} , ($\text{kg} \cdot \text{m}^2$)	4.23E-03
Asal atalet momenti, I_{p2} , ($\text{kg} \cdot \text{m}^2$)	4.73E-03
Asal atalet momenti, I_{p3} , ($\text{kg} \cdot \text{m}^2$)	8.94E-03
Kütle (kg)	0.58
İç çerçeve	
Hacim (m^3)	1.64E-04
Asal atalet momenti, I_{p1} , ($\text{kg} \cdot \text{m}^2$)	6.23E-03
Asal atalet momenti, I_{p2} , ($\text{kg} \cdot \text{m}^2$)	5.92E-03
Asal atalet momenti, I_{p3} , ($\text{kg} \cdot \text{m}^2$)	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)		88
Volan ağırlık merkezinin CMG merkezine olan mesafesi (mm)		30

4. Modellerin Performans Değerlendirmesi

Modellerin verimliliğini değerlendirmenin en pratik yolu mevcut veri ile modeller tarafından tahmin edilen değerler arasındaki farka bakmaktır. Bu amaçla da hata analizi yapmak, yaygın bir fark belirleme yöntemidir. En sık kullanılan hata fonksiyonları, Eşitlik 2’de verilmiştir. Birden fazla veri arasındaki ilişkiyi tespit etmek için ise korelasyon veya determinasyon katsayılarını kullanmak, yaygın bir başka yöntemdir.

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

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

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

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

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

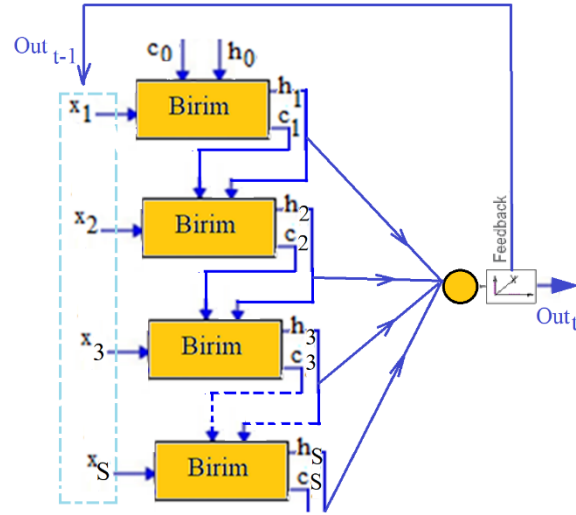
$$\text{Hata} = |p(t) - o(t)| \quad (2.f)$$

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

Burada $o(t)$ veri setindeki değerler ve $p(t)$ ise modeller tarafından tahmin edilen verilerdir. t ise zaman adıdır. R değeri korelasyon olup -1 ile 1 arasındadır, birimi yoktur. MSE hata karelerinin ortalaması, RMSE ise MSE ’nin karekökü ve MAE mutlak hatanın ortalamasıdır. ME ise ortalama hata olup veri birimindedir. ME, MAPE, RMSE ve MAE değerlerinin sıfıra yakın olması istenir. RMSE ve MAE incelenen veri ile aynı birimdeyken MAPE ise yüzde birimindedir. MSE ’nin birimi ise birim²’dir. R veya R^2 değerlerinin pozitif 1’e yakın olması, fonksiyonun tahmin ettiği değerler ile veri noktaları arasında kuvvetli bir ilişkinin olduğunu teyit etmektedir. RMSE değerinin sıfıra yakın olması da tahmindeki ortalama hata değerlerinin azlığını göstermektedir.

5. LSTM ile modelleme

Bir LSTM ağ katmanı şematik olarak Şekil 2’de verilmiş olup; $\{x\}$ girdi değişkeni kümesi, $\{h\}$ çıktı değişkeni kümesi ve $\{c\}$ hücre durumunu içeren değişkenlerdir.



Şekil 2. (a) Çalışmada kullanılan LSTM ağı topolojisi

h_t , Eşitlik 3 kullanılarak hesaplanmaktadır.

$$h_t = o_t \odot \tanh(c_t) \quad (3)$$

\odot sembolü Hadamard çarpımını (Million, 2007) temsil etmektedir. o_t çıkış kapısı olup, h_t için hücre durumunu ayarlamaktadır. c_t , Eşitlik 4 kullanılarak hesaplanmaktadır.

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (4)$$

Burada i_t giriş kapısı sayesinde, hücre durumunun güncelleme seviyesi belirlenmektedir. f_t unutma kapısı olup, hücre durumunun sıfırlama seviyesi kontrol edilebilmektedir. g_t hücre adayı olup, hücre durumuna bilgi sağlar. Bu değişkenler Eşitlik 5'te verilen bağıntılar ile hesaplanmaktadır.

$$i_t = f(W_t x_t + R_i h_{t-1} + b_i) \quad (5.a)$$

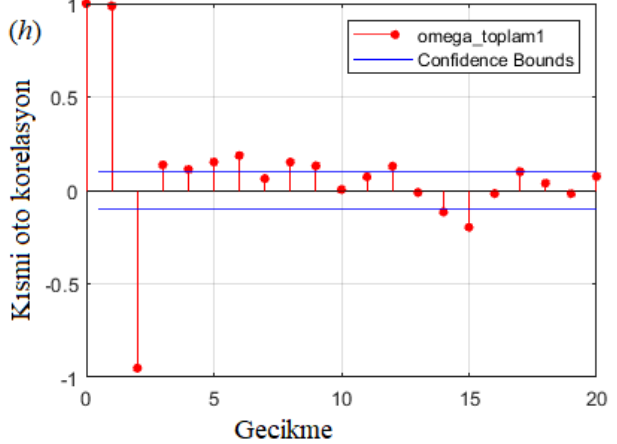
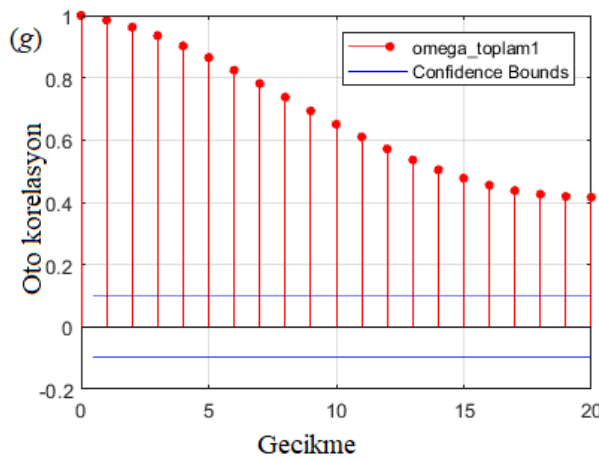
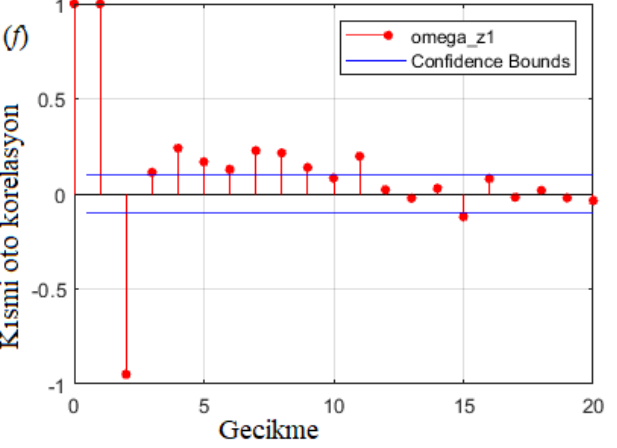
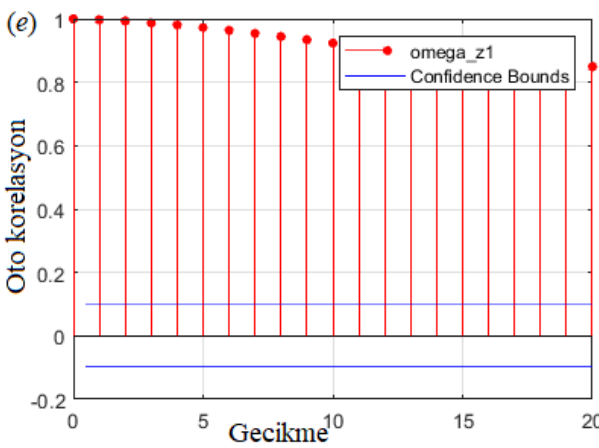
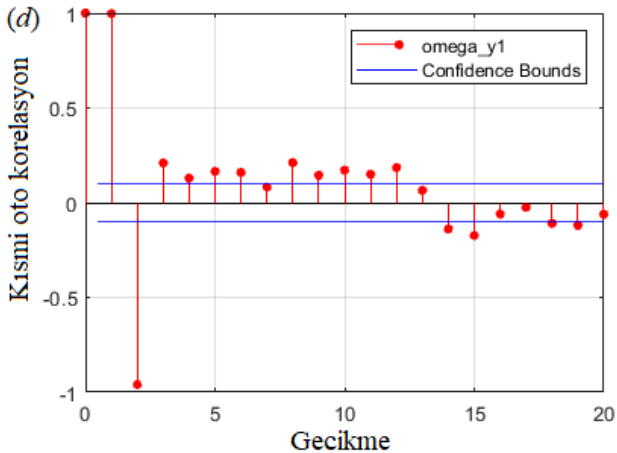

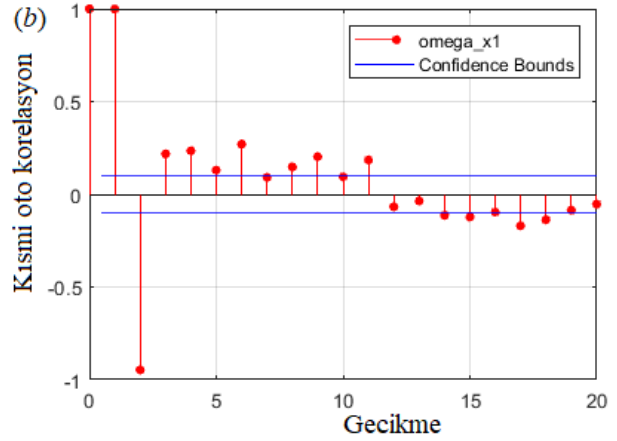
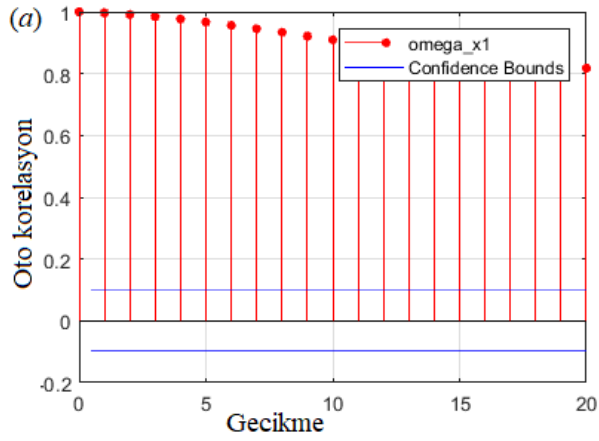
$$f_t = f(W_f x_t + R_f h_{t-1} + b_f) \quad (5.b)$$

$$o_t = f(W_o x_t + R_o h_{t-1} + b_o) \quad (5.c)$$

$$g_t = \tanh(W_g x_t + R_g h_{t-1} + b_g) \quad (5.d)$$

burada $f(t)$ ile verilen fonksiyon, sigmoid aktivasyon fonksiyonudur. W ve R sırasıyla girdi ve tekrarlayan birimin ağırlıklardır. b ise bias'tır. Hücre durumu için sigmoid ve aday için aktivasyon fonksiyonu olarak sıklıkla tanjant hiperbolik fonksiyonun kullanıldığı görülmüştür (Farzad, Mashayekhi, & Hassanpour, 2019). Toplam veri setinin ilk %60'ı eğitim için, geri kalan %40'ı ise tahmin için kullanılmıştır. Veriler yazılım içerisinde başlangıçta normalleştirilmektedir. 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. LSTM ağları, yazılım kodları kullanılarak oluşturulmuştur (Heris, 2015). IoT (nesnelerin interneti) kullanan herhangi bir donanım uygulaması bu çalışmanın kapsamı dışındadır.

Zaman gecikmelerini tespit etmek için korelogramlar kullanılmıştır (Şekil 3). Yalpalama verisi oto korelasyon ve kısmi oto korelasyon grafiklerinde değerlendirilmiştir. Her iki tip grafikten serideki verilerin rastgele olmadığı, kendi gecikmelerine bağlı olduğu 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 yakındır. İki standart sapma kadarlık oluşturulan güven sınırlarının hemen hemen dışında kalmaktadır. Bu durum iki 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, AR(2) olduğunu göstermektedir.



Şekil 3. (a) x doğrultusundaki yalpalama bileşenine ait OKF; (b) x doğrultusundaki yalpalama bileşenine ait KOKF; (c) y doğrultusundaki yalpalama bileşenine ait OKF; (d) y doğrultusundaki yalpalama bileşenine ait KOKF; (e) z doğrultusundaki yalpalama bileşenine ait OKF; (f) z doğrultusundaki yalpalama bileşenine ait KOKF; (g) yalpalamanın bileşkesine ait OKF; (h) yalpalamanın bileşkesine ait KOKF

Ağırlıklara eğitimden önce ilk değer olarak sıfır verilmiştir. Ağın derinliği 1 LSTM katmanı olarak ayarlanmıştır. Gecikme 2 olarak ayarlanmıştır. LSTM katmanına 128 gizli birim uygulanmıştır (Huang, Li, Oh, & Kang, 2023). LSTM ağının 500 (Yuan, Chen, Lei, Yuan, & Muhammad Adnan, 2018), 200 (J. Chen, Wang, & Xu, 2022), 800 iterasyon (Z. Chen, Yang, & Qiao, 2022) ile eğitildiği görülmektedir. Bu çalışmada 500 iterasyon uygulanmıştır. Hata yakınsaması olarak RMSE gözlemlenmiştir. Regresyon katmanında kayıp fonksiyonu olarak MSE kullanılmıştır. Bu çalışmada kullanılan LSTM ağına ilişkin parametreler Tablo 3'te verilmiştir.

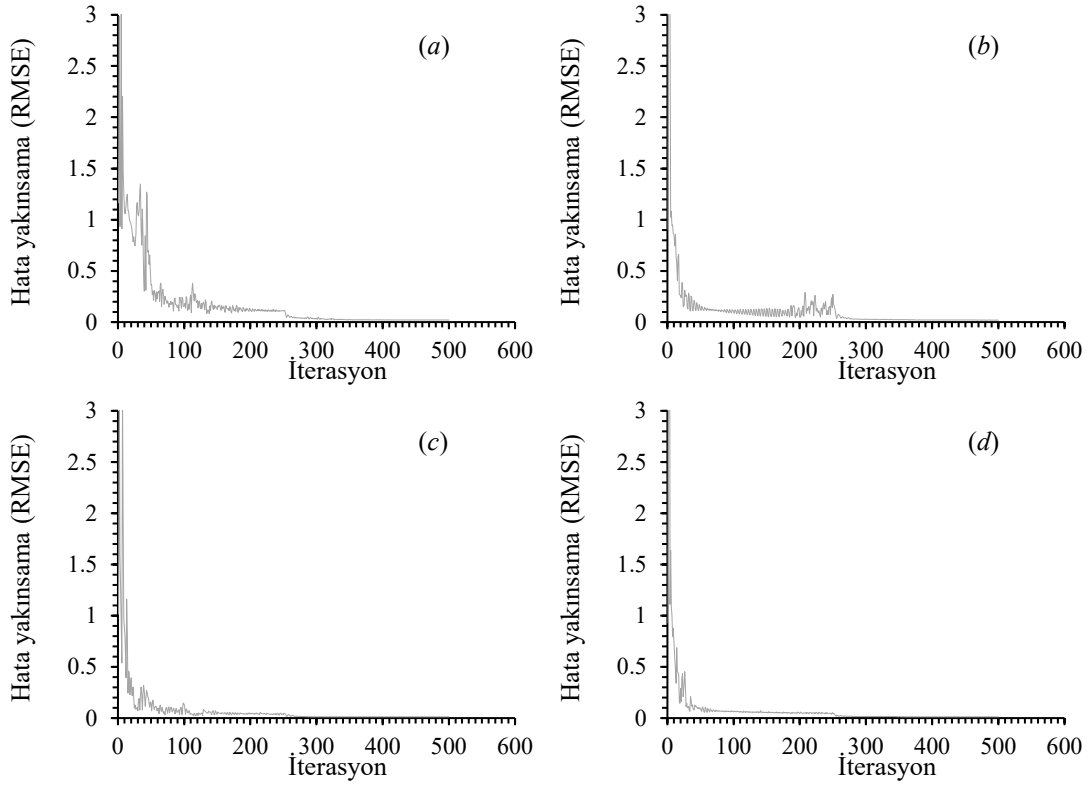
Tablo 3. LSTM ağ mimarisinin katman yapılandırması

Katman	Yapılandırma	Parametre
Dizi giriş katmanı	1 kanal	Grup boyutu = %60 eğitim, %40 tahmin. Tüm veriler normalleştirilmiştir.
Gecikme		Karıştırma: bir kez
LSTM katman(lar)ı	1 katman 128 gizli birim	2
Tam bağlantı katmanı	1 birim	Kapılarda <i>sigmoid</i> , hücre adayında ve hücre durumunda <i>tanh</i>
Çıktı	Regresyon katmanı	Yanıt sayısı = 1
Eğitim algoritması (çözücü)	ADAM	Kayıp fonksiyonu = MSE Gradyan azalma faktörü, $\beta_1 = 0.9$ Kare gradyan azalma faktörü $\beta_2 = 0.999$ Epsilon $\varepsilon = 1e - 8$
Ağırlıklar	W, R, b	İlk öğrenme oranı: 0.01. Öğrenme oranı güncellenebilir (güncelleme faktörü: 0.2, güncelleme süresi: 10 epoch)
Hesaplama âdeti	Epoch başına iterasyon=1	Ağırlık azaltma faktörü: 1e-04 Gradyan bozulma eşiği: 1 (nan veya Inf), norm esaslı eğim kırpma
		İlk değer olarak sıfır verildi.
		500 epoch

6. Sonuçlar ve Tartışma

6.1. Doğrulama


Eğitim esnasında kaydedilen RMSE hata yakınsama eğrileri Şekil 4'te verilmiştir. Hata gittikçe sifıra yaklaşmakta daha sonra da hatanın değişiminde herhangi bir sapma görülmemektedir. Bu durum ağların eğitimleri esnasında kararlılıklarını kaybetmediği anlamına gelmektedir.




Şekil 4. Ağın eğitimi sırasında hata yakınsaması **(a)** x doğrultusundaki yalpalamayı tahmin edecek ağ; **(b)** y doğrultusundaki yalpalamayı tahmin edecek ağ; **(c)** z doğrultusundaki yalpalamayı tahmin edecek ağ; **(d)** bileşke yalpalamayı tahmin edecek ağ için

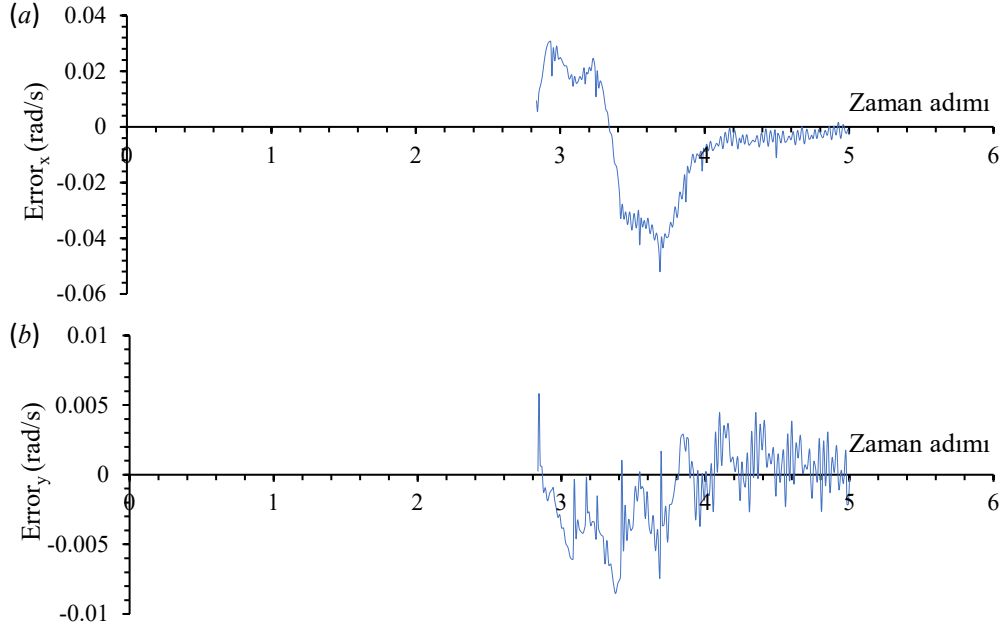
6.2. Tahmin eğrileri


Doğrulamaya ek olarak modellerinin tahmin eğrileri sırasıyla Şekil 5'te karşılaştırılmıştır. Ağlar eğitim, test ve doğrulama sırasında tahmin verilerini bilmemekteydiler. Veri kümesinin son %40'lık kısmı, eğitime başlamadan önce tahmin için ayrılmıştı. Şekil 6'da ise veri seti ile model tahmin değerleri arasındaki fark verilmiştir. Grafiklerden LSTM ağlarının hem eğri genel şeklini hem de eğrilerin sahip olduğu tepe ve çukurlukları temsil edebilme yeteneğinin yüksek olduğu görülmektedir. Bununla birlikte Ω_z modelinin tahmin verisinin tepe ve çukurluklarla eş şablonda ancak bir miktar kaymaya sahip olduğu görülmektedir.





Şekil 5. LSTM ağının (a) x doğrultusundaki; (b) y doğrultusundaki; (c) z doğrultusundaki; (d) toplam yalpalama hızı





Şekil 6. LSTM ağının tahmini ile veri seti arasındaki fark (a) x doğrultusundaki; (b) y doğrultusundaki; (c) z doğrultusundaki; (d) toplam hata

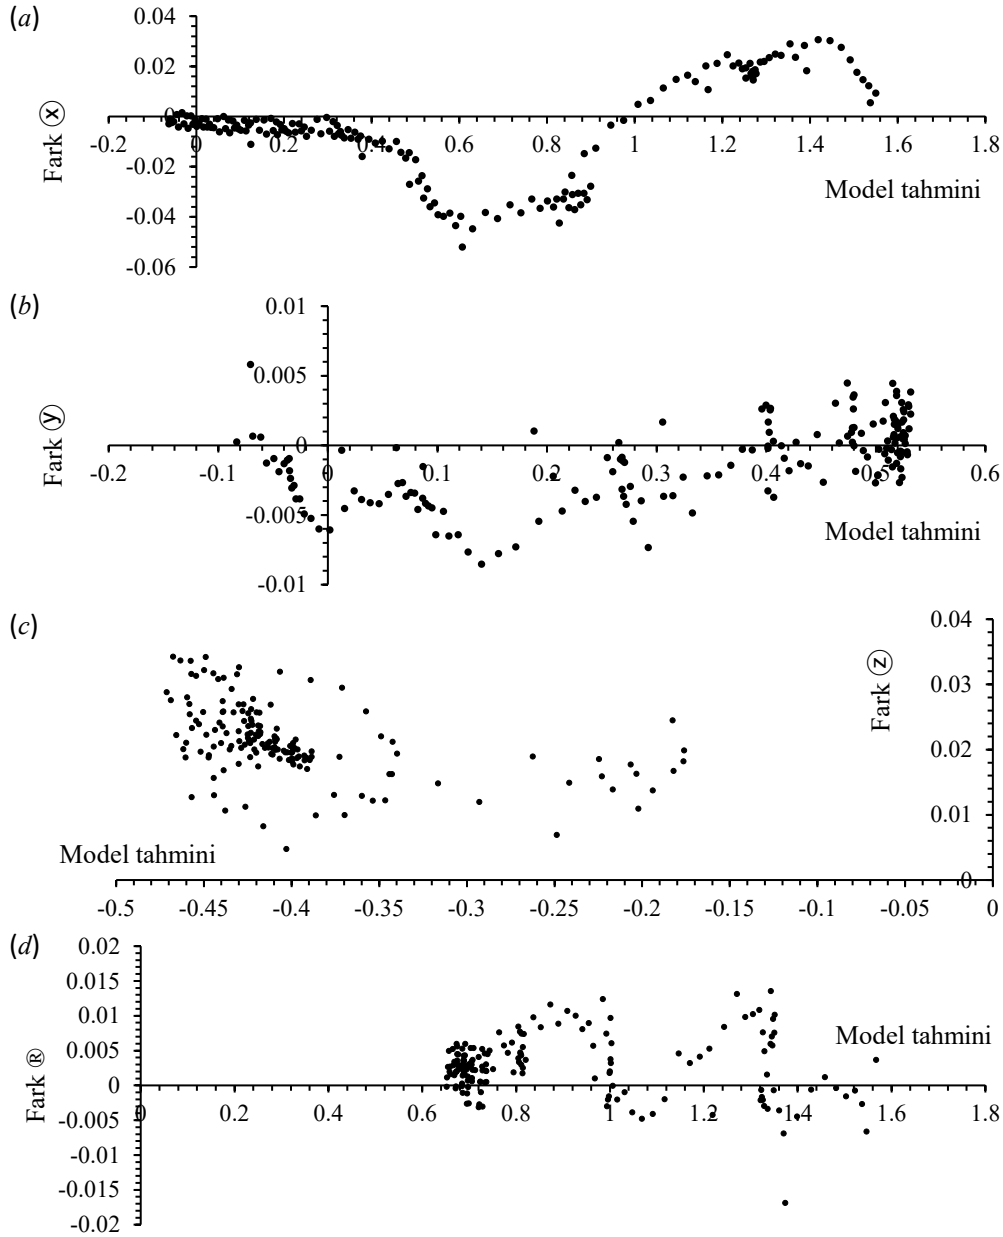
Tablo 4. LSTM ağının tahmin performans metrikleri

Yalpalama (rad/s)	MAE (birim)*	MAPE (%)	Hata (birim)	MSE (birim ²)	RMSE (birim)	Hesaplama süresi (d:s)	R
Ω_x	0.0258	1.3522	0.0175	4.0295e-04	0.0201	01:31	0.9995
Ω_y	0.0221	4.0311	0.5373	8.7878e-04	0.0296	01:23	0.9955
Ω_z	0.0180	-4.4188	0.0180	3.4928e-04	0.0187	01:12	0.9975
Ω_{toplam}	0.0041	0.4530	-0.0012	3.0245e-05	0.0055	01:18	0.9998

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

Tablo 4'te LSTM ağının tahmin performans metrikleri verilmiştir. Tüm veri için hesaplama süresi birbirlerine yakındır. 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 incelenmelidir. RMSE metriğinin en yüksek değeri, Ω_y verisinde \cong % 3 rad/s olmaktadır. Bu durum MSE, MAPE, MAE metriklerinde de benzerdir. En düşük hata ise Ω_{toplam} tahminlemede oluşmaktadır.

Şekil 7'de LSTM ağının tahminine karşın ağ ile veri seti arasındaki farkı gösteren grafikler verilmiştir. Bu grafikler tahmindeki varyansı görebilmek için faydalı grafiklerdir. Şekillerde değerlerin sabit bir varyansa sahip olduğu, sifra yakın rastgele dağıldığı görülmektedir. Sabit ve rasgele dağılım, eş varyansa işaret etmektedir. Engle's ARCH Testine göre ham veriler değişen varyans içermektedir. Bununla birlikte, LSTM modelinin sabit varyansa sahip olması göstermektedir ki, değişen varyansa sahip olan ham veriler üzerine herhangi bir ön işlem gerekliliği ortadan kalkmıştır.



Şekil 7. LSTM ağınnın tahminine karşın aradaki fark dağılımı (a) x doğrultusundaki; (b) y doğrultusundaki; (c) z doğrultusundaki; (d) bileşke yalpalama

6.3. Tartışma

Literatürde jiroskop modelleme çalışmalarının sıklıkla regresyon ve nadiren de destek vektör makinesi (SVM) ve gizli Markov modeli (HMM) ile temsil edilen istatistiksel öğrenme yöntemleri ile yapıldığı görülmüştür. 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 içinde değerlendirilmesi yapılabilmektedir. Bununla birlikte ML yöntemlerinin, diğer yöntemlere göre daha başarılı olduğu sonucu çıkarılabilmektedir. Bu hâli ile mevcut çalışmanın yalpalama tahmini konusunda özgünlük içerdiği anlaşılmaktadır.

Tablo 5. Farklı modellere ait metrikler

Yalpalama (rad/s)	Hata (birim)	RMSE (birim)	Metot
<i>Mevcut çalışma</i>	-0.0012 rad/s	0.0055 rad/s	LSTM
Shi ve ark. (2019)	--	0.0112 °C	LSTM
Shi ve ark. (2019)	--	0.0151 °C	SVM
Shi ve ark. (2019)	--	0.0135 °C	BP
Zhou ve Hu (2008)	-0.0111 rad/s	--	ARMA
Chairez vd. (2019)	13.25°	--	PD
Chairez vd. (2019)	1.3336°	--	PID
Chairez vd. (2019)	0.74515°	--	Adaptif
Chairez vd. (2019)	0.184°	--	YSA
Pan vd. (2019)	--	0.013 mrad/s	PID
Ibrahim vd. (2023)	--	2.013 pulse/s	LSTM

Ancak bu yöntemlerden önce ön işlem uygulanması gerekliliği, verinin doğasını bozmaktadır. LSTM yöntemi herhangi bir ön işlem gereksinimini ortadan kaldırmıştır. 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 et al., 2019). LSTM yöntemi diğerlerine göre en az hataya sahip olmuştur. Bu çalışmada da 0.0055 rad/s olarak tespit edilen RMSE'nin bahsi geçen çalışmadan daha az olduğu görülmektedir. Zhou ve Hu (2008) ise ARMA modeli kullanmış olup tahmindeki ME değeri -0.0111 rad/s iken bu çalışmada -0.0012 rad/s olmuştur (Zhou & Hu, 2008). Çalışmamızda korelasyon değeri 0.9998 olup bire çok yakındır. Bu durum model çıktısı ile veri seti arasındaki ilişkinin yüksek olduğuna işaret etmektedir. Montoya-Chairez vd. (2019), PD kontrol kullanarak 13.25°, PID kullanarak 1.3336°, adaptif kontrol kullanarak 0.74515° ve sinir ağı kullanarak 0.184° pozisyon hatası elde etmiştir. Tork hatası PD kontrol kullanılarak 0,036 Nm, PID kontrol kullanılarak 0,1484 Nm, MB kullanılarak 0,1769 Nm, adaptif kontrol kullanılarak 0,15108 Nm ve sinir ağı kullanılarak 0,14659 Nm'dir (Montoya-Chairez et al., 2019). Pan vd. (2019) ultrasonik bir motor tarafından tahrik edilen yeni bir tek-gimbal kontrol momenti jiroskobunun, teorik modeli ve parametreleri Ziegler-Nichols metodu ile belirlenmiş olan bir PID kontrolcü sayesinde hızdaki ortalama hatanın maksimum değerini 0.013 mrad/s bulmuştur. Bu değer bu çalışmada bulunan değerden çok ufaktır. Bunun nedeni ise jiroskobun modellenmesinde teorik model ve analitik formüllerin kullanılmış olmasıdır. Ancak sunulan kontrolör, kontrol momenti jiroskobunun yüksek kararlılığı ve yüksek hassasiyetinin temeli olan gimbalin 0,2 mrad/s ila 1,6 rad/s arasında bir kapalı döngü hız kontrolünü gerçekleştirmektedir. (Pan et al., 2019). Hibrit derin öğrenme tekniği kullanarak çevik uydu yönelim kontrol sistemi için anomali tespiti yapılabilmektedir (Ibrahim et al., 2023).

7. Sonuçlar

Jiroskop tasarımları esnasında veya kullanımda olan bir jiroskobun hasarının önceden tahmin edilmesinde uygun model kullanılması gerekmektedir. Bu çalışma kapsamında havacılık, uzay endüstrilerinde ve kara araçlarında da otonom dengeleme gerektiren alanlarda kullanılan bir mekanik jiroskopun yalpalama hızının modellenmesi amaçlanmıştır. Bu amaçla LSTM modellerinin performansları araştırılmıştır. İsbetli tahminler, bu alanda faaliyet gösteren firmalara hızlilik ve rekabet gücü katması açısından öneme sahiptir. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Bir katmanlı, 128 adet gizli hücreye sahip, regresyon esaslı bir LSTM ağı kullanılmıştır. Eğitim için ADAM çözücüsü, kapılarda *sigmoid*, hücre adayında ve hücre durumunda *tanh* aktivasyon fonksiyonları kullanılmıştır. Eğitim için 500 iterasyon yaptırılmıştır. RMSE değeri 0.0055 rad/s iken ME değeri -0.0012 rad/s ve *R* değeri ise 0.9998 olup model çıktısı ile veri seti arasında yüksek ilişki mevcuttur.
- Jiroskop yalpalama hızının tahmini işleminde, LSTM ağı hem eğri genel şeklini hem de eğrilerin sahip olduğu tepe ve çukurlukları temsil edebilme yeteneği yüksektir.

Teşekkür

Rijit dinamik simülasyonları için kullanılan Ansys®'in eğitsel amaçlı kullanım imkânını sağlayan Karadeniz Teknik Üniversitesi'ne, Dr. Mehmet Seyhan'a teşekkür ederim.

Rekabetçi Menfaat Beyanı

Yazar(lar) rakip bir finansal çıkar beyan etmemektedir.

Finansman Kaynakları

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

Referanslar

- Abbas, H. S., Ali, A., Hashemi, S. M., & Werner, H. (2014). LPV state-feedback control of a control moment gyroscope. *Control Engineering Practice*, 24, 129-137. doi: 10.1016/j.conengprac.2013.05.008
- 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.
- 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.
- Aranovskiy, S., Ryadchikov, I., Mikhalkov, N., Kazakov, D., Simulin, A., & Sokolov, D. (2021). *Scissored pair control moment gyroscope inverted pendulum*. Paper presented at the 14TH international symposium intelligent systems.
- Chen, J., Wang, X., & Xu, X. (2022). GC-LSTM: graph convolution embedded LSTM for dynamic network link prediction. *Applied Intelligence*, 52(7), 7513-7528. doi: 10.1007/s10489-021-02518-9
- Chen, X. (2003, 14-17 Dec. 2003). *Modeling random gyro drift by time series neural networks and by traditional method*. Paper presented at the International Conference on Neural Networks and Signal Processing, 2003. Proceedings of the 2003.
- Chen, X. (2004, 2004//). *Modeling Temperature Drift of FOG by Improved BP Algorithm and by Gauss-Newton Algorithm*. Paper presented at the Advances in Neural Networks - ISNN 2004, Berlin, Heidelberg.
- Chen, Z., Yang, C., & Qiao, J. (2022). The optimal design and application of LSTM neural network based on the hybrid coding PSO algorithm. *The Journal of Supercomputing*, 78(5), 7227-7259. doi: 10.1007/s11227-021-04142-3
- 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
- Farzad, A., Mashayekhi, H., & Hassanpour, H. (2019). A comparative performance analysis of different activation functions in LSTM networks for classification. *Neural Computing and Applications*, 31, 2507-2521. doi: 10.1007/s00521-017-3210-6
- He, J. R., & Zhao, M. G. (2015). *Control System Design of Self-balanced Bicycles by Control Moment Gyroscope*. Paper presented at the Proceedings of the 2015 Chinese Intelligent Automation Conference: Intelligent Technology and Systems.
- 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).
- Heris, M. K. (2015). Time-series prediction using ANFIS. *The Yarpiz Project, Fuzzy Systems*.
- HosseinTabari, Kisi, O., Ezani, A., & Talae, 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, J., Li, J., Oh, J., & Kang, H. (2023). LSTM with spatiotemporal attention for IoT-based wireless sensor collected hydrological time-series forecasting. *International Journal of Machine Learning and Cybernetics*. doi: 10.1007/s13042-023-01836-3
- 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/10.2514/2.511.1011280>. doi: 10.2514/1.1011280
- 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
- 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
- Li, Y., Hu, Q., & Shao, X. (2022). Neural network-based fault diagnosis for spacecraft with single-gimbal control moment gyros. *Chinese Journal of Aeronautics*, 35(7), 261-273. doi: <https://doi.org/10.1016/j.cja.2021.11.020>
- Miao, J., Li, X., & Ye, J. (2015, 21-23 Oct. 2015). *Predicting research of mechanical gyroscope life based on wavelet support vector*. Paper presented at the 2015 First International Conference on Reliability Systems Engineering (ICRSE).

- Million, E. (2007). The Hadamard product. In R. A. Beezer (Ed.), *Linear Algebra* (pp. 1-7). Rob Beezer's Home Page: Buzzard.
- 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
- Nl, C. (2023). Gyroscope physics. *Cleonis*, 1(1), 1.
- Osman, M. O. M., Sankar, S., & Dukkupati, 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
- 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
- Song, H., Hu, S.-L., & Zhou, K.-Y. (2017). Review on Development of Fault Diagnosis for Gyroscope. *ITM Web Conf.*, 11, 07001. doi: 10.1051/itmconf/20171107001
- 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
- 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
- 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
- Xudong, Y., Pengfei, Z., Yuanping, X., & Xingwu, L. (2013). Forecasting method for axial ring laser gyroscope drifts in single-axis rotation inertial navigation system. *High Power Laser and Particle Beams*, 25(04), 847-852. doi: 10.3788/HPLPB20132504.0847
- Yuan, X., Chen, C., Lei, X., Yuan, Y., & Muhammad Adnan, R. (2018). Monthly runoff forecasting based on LSTM-ALO model. *Stochastic Environmental Research and Risk Assessment*, 32(8), 2199-2212. doi: 10.1007/s00477-018-1560-y
- 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
- Zhu, R., Zhang, Y., & Bo, Q. (2000). Identification of temperature drift for FOG using RBF neural networks. 34, 222-225.