

NARX Sınır Ağları Yöntemiyle 25. Güneş Aktivite Çevrimi Tahmini

Mirkan Y. Kalkan,^{1,3} A. Talat Saygıç,^{1,2} Dıaa Fawzy⁴

¹ Department of Astronomy and Space Sciences, Istanbul University, 34134, Istanbul, Türkiye

² Application and Research Center, Istanbul University, 34134, Istanbul, Türkiye

³ Institute of Graduate Studies of Sciences, Istanbul University, 34134, Istanbul, Türkiye

⁴ Faculty of Engineering, Izmir University of Economics, 35330 Izmir, Türkiye

Accepted: December 16, 2021. Revised: January 3, 2022. Received: February 8, 2022.

Özet

Güneş Aktivite Çevrimlerini (GAC) tahmin etmek; Dünya yörüngesindeki uzay araçlarının güvenliği, iletişim ağları ve genel olarak yaşam üzerindeki olumsuz etkileri nedeniyle önemli hale gelmiştir. Bu çalışmada, 25. GAC tahmini için yaklaşık 3246 adet 13 aylık ortalama Güneş Lekesi Sayısı'ndan (GLS) (Temmuz 1749 - Aralık 2019 arasında) oluşan büyük bir veri seti ile Doğrusal Olmayan Otoregresif Eksojen (NARX) sınır ağı tabanlı modeller kullanılmıştır. NARX modelleri veri seti ile Bayesian Regülasyonu kullanılarak eğitilmiştir. NARX modelinin performansı Ortalama Karekök Sapması (RMSE), Korelasyon Katsayısı (r) ve Normalize Nash-Sutcliffe Verimlilik Katsayısı (NNSE) kullanılarak hesaplanmıştır ve modelin performansının "çok iyi" (NNSE > 0.95) olduğu bulunmuştur. Modelimiz diğer benzer çalışmalardan elde edilen sonuçlarla karşılaştırılarak doğrulanmıştır ve 25. GAC için maksimum GLS ($R_{25_{maks}}$) 104,542 ve maksimum ayı Mayıs 2024 olarak tahmin edilmiştir. NARX tabanlı modellerin literatürde bildirilen diğer yöntemlere kıyasla iyi ve uyumlu tahmin sonuçları ortaya çıkardığı görülmüştür.

Abstract

Negative effects on the stability of earth's orbiting spacecrafts, telecommunication networks, and on life in general have been correlated with the solar activity cycles. This work is devoted for the development of a neural network-based models for the prediction and forecasting of forthcoming solar activity cycles. An approach is developed based on the nonlinear autoregressive exogenous (NARX) technique; we consider a long time series of observations. The prediction method is based on the nonlinear autoregressive network with exogenous inputs (NARX) with its ability to derive the underlying complex and nonlinear relationships. A big dataset of about 3246 monthly average sunspot numbers (SSN) (between July 1749 – December 2019) is used for the current study. The NARX model was trained with the data set using the Bayesian Regulation. The performance of the NARX model was evaluated using statistical parameters such as Root Mean Square Error (RMSE), Correlation Coefficient (r), and Normalized Nash-Sutcliffe Efficiency Coefficient (NNSE) and the performance of the model was found to be "very good" (NNSE > 0.95). Our models were compared and verified with other similar studies and show that the current predicted maximum SSN for the Solar Cycle 25 ($R_{25_{maks}}$) is 104.542 and date of maxima is May 2024. We conclude that our currently NARX based approaches offer good and accurate prediction results in comparison to other methods reported in the literature.

Anahtar Kelimeler: Sun: activity – Sun: sunspots – Sun: solar-terrestrial relations – Neural networks: nonlinear autoregressive exogenous models

1 Giriş


Güneş diski üzerinde gözlemlenen Güneş leke sayılarının (GLS) ölçümleri, Güneş Aktivitesi'nin 11 yıllık çevrimler halinde değiştiğini gösterir (Uwamahoro 2008). Dünya'daki yaşamı etkileyen atmosferik olayların seyri (örneğin, iklim değişiklikleri, küresel ısınma), Dünya'nın yörüngesindeki uzay araçlarının ömürleri ve Dünya'daki iletişim ağı, Güneş Aktivitesi'ndeki değişikliklerden büyük ölçüde etkilenir (Yoshida ve Yamagishi 2010). Güneş Aktivitesi'nin göstergesi olarak GLS'lerin kayıtları *Sunspot Index and Long-Term Solar Observations* (SILSO) tarafından 1749 yılına kadar uzanan ve ücretsiz olarak erişilebilen büyük bir veri seti olarak sunulmuştur. Bu çalışmada 1749 - 2019 arasındaki GLS verileri NARX sınır ağlarıyla tahmin

edilmek üzere kullanılmıştır. Süren çalışmamızın ikinci kısmında 1975 - 2019 arasında Aylık Güneş Parlama Sayısı, 10.7 cm dalgaboyundaki Güneş Radyo Akısı, Toplam Güneş Işınımı (Güneş Sabiti) ve 26. GAC için NARX tahmini yapılmaktadır. Başta Güneş lekesi olmak üzere Güneş Aktivitesi zaman serilerinin analizi ve tahmini birçok çalışmada kullanılmıştır (Balogh vd. 2014; Hathaway 2015; Petrovay 2020; Wu ve Qin 2021; Sarp ve Kılıçık 2018).

Aralık 2019'da başlayan 25. GAC'ın 2030'da bitmesi beklenmektedir. Ancak 25. GAC'ın maksimumdaki rölatif sayı ($R_{25_{maks}}$) değerinin ne kadar olacağı ve bu maksimum değerinin ne zaman gerçekleşeceği bilinmediği için bu çalışmamızda NARX yöntemiyle bu bilinmeyenleri tahmin etmeye odaklandık.

Literatürde, 24. GAC'a kıyasla $R_{25_{maks}}$ değeri için farklı tahminler bulunmuştur. Örneğin Du (2020), Ekim 2024 olarak bulunan 25. GAC maksimum zamanı ve bu zamandaki $R_{25_{maks}}$

* mirkanyusufkalkan@gmail.com



Şekil 1. NARX Sinir Ağı Model Örneği: $x(t)$; giriş verileri $y(t)$ (soldaki); hedef verileri, $1:x$; gecikme değeri, w ; ağırlıklar, b ; gürültü değeri, 10; sinir ağı adedi, $y(t)$ (sağdaki); çıkış (tahmin sonucu) verileridir (MATLAB).

değerinin 137,8 olacağı; **Sarp vd. (2018)** yaklaşık %16 ve **Li vd. (2018)** yaklaşık %45 oranla, 25. GAC'ın 24. GAC'a kıyasla daha zayıf olacağı öne sürülmüştür. Öte yandan, **Han ve Yin (2019)** tarafından, yaklaşık %45 oranla 25. GAC'ın daha güçlü aktivite davranışı göstereceği öne sürülmüştür. **Svalgaard (2020)** tarafından maksimum anında rölatif sayı 128 olarak tahmin edilmiştir.

Bu çalışmada, 25. GAC'ın maksimum değerinin ve bu değer gerçeğe zamanı tahmin etmek için NARX modelleri kullanarak bir Yapay Sinir Ağı tekniği geliştirmek amaçlanmıştır. NARX modelinden elde edilen sonuçlar farklı tekniklerden elde edilen diğer sonuçlarla da karşılaştırılmıştır.

2 Yöntem

Bu çalışma için yaklaşık 3246 kayıttan oluşan büyük bir GLS veri seti (Temmuz 1749 – Aralık 2019 arasında) kullanılmıştır. Veri setinin %70'i Bayesian Regülasyonu kapsamında sinir ağı modelinin eğitimi için kullanılmış ve uyumluluk (regresyon) değeri %99.97; test için %30'u kullanılmış ve %99.97 uyumluluk değeri ile NARX tahmin modelleri oluşturulmuştur.


NARX modeli (Şekil 1), zamana bağlı doğrusal olmayan (bire bir tekrar etmeyen) sistemlerin tahmininde kullanılan dinamik bir sinir ağıdır (**Boussada vd. 2018; Wunsch vd. 2018**). NARX modeli, sırasıyla Denklem (1) ve (2) ile verilen yapısına göre seri-parallel (açık-döngü) ve paralel (kapalı-döngü) olmak üzere iki mimari olarak ifade edilmektedir (Şekil 2). Seri-parallel yapı kullanılarak geliştirilen bir modelde, tahmin edilen çıktıyı geri beslemek yerine hedeflenen veri değerleri (\hat{y}_t) kullanılır ve paralel mimari konfigürasyonunda iken eğitim, test ve doğrulama periyodu için uygun hale gelir (Şekil 1), tahmin çıktısı girdiye geri besleme olarak uygulanır, bu da zaman serisinin (\hat{y}_{t+1}) gelecekteki değeri x_t girişinin şimdiki ve geçmiş değerlerinden ve \hat{y}_t değerinden tahmin edildiği anlamına gelir (Şekil 3).

NARX modeli şu şekilde formüle edilmiştir (**Boussada vd. 2018**):

$$\hat{y}_{t+1} = f \left(\begin{matrix} y_t, y_{t-1}, \dots, y_{t-n_y}, x_{t+1}, \\ x_t, x_{t-1}, \dots, x_{t-n_x} \end{matrix} \right) + \varepsilon_{t+1} \quad (1)$$

$$\hat{y}_{t+1} = f \left(\begin{matrix} \hat{y}_t, \hat{y}_{t-1}, \dots, \hat{y}_{t-n_y}, x_{t+1}, \\ x_t, x_{t-1}, \dots, x_{t-n_x} \end{matrix} \right) + \varepsilon_{t+1} \quad (2)$$

Denklem 1 ve 2'de $x_{t+1}, x_t, x_{t-1}, \dots, x_{t-n_x}$ kısmı NARX giriş verilerini, $y_t, y_{t-1}, \dots, y_{t-n_y}$ kısmı tahmin edilecek döneme ait gerçek verilerini, $\hat{y}_t, \hat{y}_{t-1}, \dots, \hat{y}_{t-n_y}$ kısmı Şekil 2'de gösterilen NARX içeriğindeki Seri-Paralel mimari ile yapılan tahminlerin sonuç değerlerini, \hat{y}_{t+1} ise belirtilen zamanda NARX'in tahmin sonuç değerlerini belirtir. ε_{t+1} hata terimi,



Şekil 2. NARX Sinir Ağı'nın Mimarisini (**Boussada vd. (2018)**). (TDL; Tapped Delay Line (Gecikme Uygulanmış Hat)).

n_x ve n_y gecikme mertebelerini ($n_x \geq 0; n_y \geq 0$), f ise modelin doğrusal olmayan haritalama fonksiyonunu belirtir. Haritalama fonksiyonu f bilinmemektedir ve eğitim süreci sırasında normal bir Çok Katmanlı Algılayıcı (MLP) tarafından tahmin edilmektedir (**Ahmed vd. 2019; Menezes ve Baretto 2006; Menezes ve Baretto 2008**).

Eğitim aşamasından sonra model, harici girdi verileri devreye sokularak sonraki dönemleri tahmin etmek için bir model oluşturulur. Çıkış verileri, İleri Beslemeli Sinir Ağlarına (*Feed-Forward Neural Networks*) girdi olarak tanımlanır.

Zaman serilerini analiz etmek için NARX modelini kullanmadan önce, eğitim ve test aşamasında değişen birimleri, aralıkları ve büyüklükleri hesaba katmak için girdi değerlerine bir normalizasyon tekniği uygulanır (**Ahmed vd. 2019; Guzman vd. 2017**). Normalizasyon, aşağıdaki denklemle verileri 0 ile 1 aralığına ölçekler:

$$\hat{x}_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

Burada \hat{x}_t belirli bir zamanda belirli bir x_t değeri için normalleştirilmiş değerdir, x_{\max} ve x_{\min} değerleri ise x_t 'nin en yüksek ve en düşük değerleridir.

Son aşamada, bazı istatistiksel parametreler RMSE, r , NNSE kullanılarak NARX modelinin performansı değerlendirilmiştir.

3 Bulgular

Bu çalışmada, nöron sayısı, geri bildirim sayısı, optimizasyon algoritmaları, eğitim ve test periyotları dikkate alınarak 12 ağ hesaplanmış ve değerlendirilmiştir. Daha sonra en yüksek eğitim ve test performansı doğruluğuna sahip modeller seçilmiştir. Bu ağ modelleri için en uygun parametreler; ağ modelinin fazla ya da az eğitilmesi durumunda bile her zaman daha iyi sonuçların elde edilebilmesi için deneme-yanılma yöntemiyle belirlenmiştir.

Farklı parametre kombinasyonları ile yaklaşık 12 farklı model ile 12 adet GLS değeri hesaplanmıştır. Sinir ağı modellerimiz 5 ile 35 arasında sinir sayısı ve 1'den 45'e kadar gecikme değeri aralıklarıyla oluşturulmuştur. Ayrıca farklı test, eğitim periyotları ve farklı eğitim algoritmaları uygulanmıştır ve farklı NARX modelleri Çizelge 1'de verilmiştir. Sonuçlar, modellerin çoğu için $r = 0.99$ eğitim doğruluğu ve $r = 0.98$ test doğruluğu elde edebileceğimizi göstermektedir.

3.1 Karşılaştırma

Oluşturduğumuz NARX tahmin modellerinin sonuçları ile literatürdeki 13 aylık düzeltilmiş GLS verileriyle oluşturulan tahmin modelleri sonuçlarının karşılaştırılması aşağıdaki gibi yapılmıştır.

Çizelge 1. 25. GAC Maksimum Tahmini için Oluşturulmuş NARX Modellerinin Sonuçları. Model Numarası (Mimari (Giriş sayısı, sınır sayısı, çıkış sayısı ve gecikme değeri)), $R25_{maks}$, RMSE, NNSE, r .

No	Mimari	$R25_{maks}$	RMSE	NNSE	r
1	(1-5-1-16)	203,28	19,09	0,64	0,99
2	(1-5-1-35)	142,50	21,87	0,83	0,94
3	(1-10-1-45)	104,58	18,48	0,93	0,99
4	(1-15-1-45)	93,55	13,08	0,85	0,97
6	(1-25-1-45)	110,71	7,47	0,69	0,98
7	(1-25-1-45)	113,31	5,09	0,67	0,90
10	(1-25-1-50)	106,92	6,65	0,64	0,99
12	(1-35-1-45)	159,54	17,53	0,77	0,99

Çizelge 2. 25. GAC Maksimum Tahmini için Oluşturulmuş NARX Modellerinin Tahmin Ettiği Maksimum Tarihi ve Çevrim Uzunluğu (Ay) Sonuçları. "Ay" sayısı, Aralık 2019 tarihinden itibaren geçen ay sayısı ifade eder.

No	Maks. Tarihi	Çevrim Uzunluğu	$R25_{maks}$	
No	Ay	Tarih		
1	48	Aralık 2023	132	203,28
2	57	Eylül 2024	132	142,50
3	54	Mayıs 2024	132	104,58
4	61	Şubat 2025	107	93,55
6	71	Kasım 2025	131	110,71
7	76	Nisan 2026	118	113,31
10	84	Aralık 2026	132	106,92
12	47	Aralık 2023	132	159,54

Çizelge 3. NARX Modellerimizle Uyumlu Literatürdeki Çalışmalarla Karşılaştırılması.

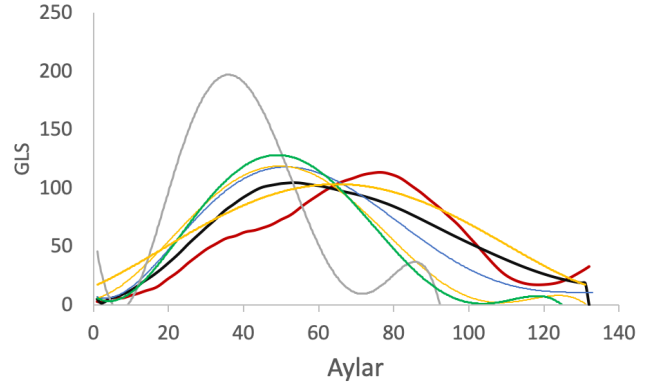
Kaynak	Kaynak $R25_{maks}$	$R25_{maks_NARX}$
Wu ve Qin (2021)	115,1	113,31 (Model7)
Sarp ve Kılçık (2018)	119,6	113,31 (Model7)
Han ve Yin (2019)	228,8	203,28 (Model1)
Helal ve Galal (2013)	118,2	113,31 (Model7)
Yoshida (2014)	115,4	113,31 (Model7)

Çizelge 2, 25. GAC maksimumu, maksimumun tahminen oluşacağı tarihi ve çevrimin tahmin edilen süresini içerir.


Modellerimizi gerçek veriler ve diğer çalışmalarla doğrulamak için bu verilerle uyumlu modeller Mode11_NARX, Mode12_NARX, Mode13_NARX ve Mode112_NARX olarak belirlenmiştir. Ancak 2019 Aralık'tan çalışmamızın yapıldığı tarihe kadar geçen 16 aylık bir süre, yaklaşık 132 ay süren ortalama bir GAC tahminleriyle karşılaştırmak için çok kısa bir zamandır. Tahminlerimiz Temmuz 1749 - Aralık 2019 arasındaki veriler kullanılarak yapılmış ve tahmin sonuçları Aralık 2019'dan çalışmanın yapıldığı zamana kadar geçen 16 ayın verileriyle de karşılaştırılmıştır.

Gerçek verilerle en uyumlu NARX modeli Mode13_NARX olarak belirlenmiştir. Bunun nedeni Şekil 4'teki son dört çevrimin (21., 22., 23., 24. Çevrimler) giderek azalması ve elde ettiğimiz 3. NARX modeli ile uyumlu olmasıdır.

Çizelge 3'te gösterildiği gibi, modellerimizden ikisi (Mode11_NARX ve Mode17_NARX) yakın zamanda literatürde yayınlanan sonuçlarla uyumludur.



Şekil 3. NARX Modellerimizle Uyumlu Literatürdeki Çalışmalarla Karşılaştırılması: Wu ve Qin (2021): İnce mavi eğri; Sarp ve Kılçık (2018): İnce turuncu eğri; Han ve Yin (2019): Kalın açık mavi eğri; Helal ve Galal (2013): Yeşil eğri; Yoshida (2014): Kalın turuncu eğri; Mode13_NARX: Siyah eğri; Mode17_NARX: Kırmızı eğri.



Şekil 4. 25. GAC için oluşturulan NARX Tahmin Modellerinin Son Dört Çevrim (21 - 24) ile Karşılaştırılması

4 Sonuç ve Tartışma

Bu çalışma, 25. GAC tahmini için NARX algoritmasına dayalı sinir ağları tahmin modellerini içermektedir. 25. GAC'ın gidışatını tahmin etmek için 12 model geliştirmiştir. Sonuçlar ile literatürdeki önceki çalışmalar karşılaştırılarak, Mode16_NARX, Mode17_NARX ve Mode110_NARX modellerimizin Wu ve Qin (2021) ($R25_{maks} = 115.1$ ve 11.06 yıl) tarafından yayınlanan sonuçlarla çok iyi uyumaktadır.

Ayrıca (Wu ve Qin 2021) 25. GAC'ın maksimum değerindeki GLS, 24. GAC'inkinden %10 oranında daha az olacağını belirtmişlerdir. Mode13_NARX'ten elde edilen sonuçlar %10,2'lik bir fark göstererek Wu ve Qin (2021)'in tahmin sonuçlarıyla uyumludur.

$R25_{maks}$ tahmini için elde edilen sonuçların Sarp vd. (2018), Sarp ve Kılçık (2018), Han ve Yin (2019), Helal ve Galal (2013), Yoshida (2014), Svalgaard (2020) belirttiği gibi 90 ile 130 arasında olduğunu belirtilmesi önemlidir. Seçilen en uyumlu model olan Mode13_NARX ile 25. GAC için maksimum GLS ($R25_{maks}$) 104,542 ve maksimumun ayı ise Mayıs 2024 olarak tahmin edilmiştir.

NARX tabanlı modellerden elde edilen değerlerin literatürde çalışılmış diğer yöntemlerle uyumlu tahmin değerleri

verdiğini ve böylece yaptığımız modellerin oldukça isabetli olduğu sonucuna varılmıştır.

Çalışmamızın devamında 25. GAC'in Gnevyshev Boşluğu'nu içerecek daha detaylı çoklu parametre modelleri ve 26. GAC için de bir maksimum rölatif sayı tahmini yapılmaktadır.

Kaynaklar

- Ahmed, U. M. R., Anwar, H., Shah, A. A., vd., 2019, Efficient Water Quality Prediction Using Supervised Machine Learning, *Water*, 11 (11), 2210.
- Balogh, A., Hudson, H., Petrovay, K., von Steiger, R., 2014, Introduction to the Solar Activity Cycle: Overview of Causes and Consequences, *Space Science Reviews*, 186, 1–15.
- Boussaada, Z., Curea, O., Remaci, A., vd., 2018 A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation, *Energies*, 11(3), 620.
- Du, Z. L., 2020, The solar cycle: predicting the peak of solar cycle 25, *Astrophys. Space Sci.*, 365(6), 134.
- Guzman, S.M., Paz, J.O., Tagert, M.L.M., 2017, The Use of NARX Neural Networks to Forecast Daily Groundwater Levels, *Water Resour Manage*, 31, 1591–1603.
- Han, Y. ve Yin, Z.Q., 2019, A Decline Phase Modeling for the Prediction of Solar Cycle 25, *Solar Physics*, 294, 107.
- Hathaway, D. H., 2015, The Solar Cycle, *Living Rev. Solar Phys.*, 12(1), 4.
- Helal, R. ve Galal, A.A., 2013, An early prediction of the maximum amplitude of the solar cycle 25, *Journal of Advanced Research*, 4, 275 – 278.
- Li, F. Y., Kong, D. F., Xie, J. L., vd., 2018, Solar cycle characteristics and their application in the prediction of cycle 25, *Journal of Atmospheric and Solar-Terrestrial Physics*, 181, 110-115.
- Menezes, J. M. P. ve Barreto, G. D. A., 2006, A New Look at Nonlinear Time Series Prediction with NARX Recurrent Neural Network, *2006 Ninth Brazilian Symposium on Neural Networks (SBRN'06)*, 160 – 165.
- Menezes, J. M. P. ve Barreto, G. D. A., 2008, Long-term time series prediction with the NARX network: An empirical evaluation, *Neurocomputing*, 71, 3335 – 3343.
- Petrovay, K., 2020, Solar Cycle Prediction, *Living Rev. Solar Phys.*, 17(1), 2.
- Sarp, V. ve Kılçık, A., 2018, Nonlinear Prediction of Solar Cycle 25, *Poster*.
- Sarp, V., Kılçık, A., Yurchyshyn, V., 2018, Prediction of the solar cycle: a non-linear approach, *Astrophys. Space Sci.*, 365(6), 2981 – 2985.
- Svalgaard, L., 2020, Prediction of Solar Cycle 25.
- Uwamahoro, J., 2008, Forecasting solar cycle 24 using neural networks, *Rhodes University, Yüksek Lisans Tezi*
- Wu, S. S. ve Qin, 2021 Predicting Sunspot Numbers for Solar Cycles 25 and 26 *arXiv, e-print, astro-ph.SR*.
- Wunsch, A., Liesch, T., Broda, S., 2018, Forecasting Groundwater Levels using Nonlinear Autoregressive Networks with Exogenous Input (NARX), *Journal of Hydrology*, 567, 743 – 758.
- Yoshida, A., 2014, Difference between even- and odd-numbered cycles in the predictability of solar activity and prediction of the amplitude of cycle 25, *Annales Geophysicae*, 32 (8), 1035–1042.
- Yoshida, A. ve Yamagishi, H., 2010, Predicting amplitude of solar cycle 24 based on a new precursor method, *Annales Geophysicae*, 28 (2), 417–425.

Access:

M22-0302: [Turkish J.A&A](#) — Vol.3, Issue 3.