T.C.
İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yüksek Lisans Tezi

25. GÜNEŞ ÇEVRİMİ İÇİN DOĞRUSAL OLMAYAN OTOREGRESİF DIŞSAL MODELLER (NARX) KULLANILARAK GÜNEŞ AKTİVİTESİ TAHMİNİ

Mirkan Yusuf KALKAN

Astronomi ve Uzay Bilimleri Anabilim Dalı

Astronomi ve Uzay Bilimleri Programı

DANIŞMAN
Prof. Dr. Ahmet Talât SAYGAÇ

II. DANIŞMAN
Prof. Dr. Diaa GADELMAVLA

Haziran, 2022

İSTANBUL

Bu çalışma, 14.06.2022 tarihinde aşağıdaki jüri tarafından Astronomi ve Uzay Bilimleri Anabilim Dalı, Astronomi ve Uzay Bilimleri Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Prof. Dr. Ahmet Talât SAYGAÇ (Danışman)
İstanbul Üniversitesi
Fen Fakültesi

Prof. Dr. Kâzım Yavuz EKŞİ
İstanbul Teknik Üniversitesi
Fen-Edebiyat Fakültesi

Doç. Dr. Zahide Funda BOSTANCI GÜVER
İstanbul Üniversitesi
Fen Fakültesi

İntihal Programı Beyanı

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi'nin abonesi olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Proje Destekleri

Bu tez, İstanbul Üniversitesi Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin ..... numaralı projesi ile desteklenmiştir.
Bu tez, ... numaralı ..... projesi ile desteklenmiştir.

Tezden Üretilmiş Yayınların Künye Bilgileri

Kalkan, M. Y., Saygaç, A. T., Fawzy, D. E., 2022, NARX Sinir Ağları Yöntemiyle 25. Güneş Aktivite Çevrimi Tahmini, *Turkish Journal of Astronomy and Astrophysics,* 3 (3), 57 - 60. (Astrofizikte Güncel Lisansüstü Çalışmalar Çalıştayı Bildirisi, 22 Ekim – 26 Kasım, İzmir, Ege Üniversitesi)

Kalkan, M. Y., Saygaç, A. T., Fawzy, D. E., 2022, Multi-Parameter Neural Network Prediction for Solar Cycles 25 and 26, *MNRAS* (1 Haziran 2022 yayına gönderilmek üzere hazırlık aşamasında).

ÖNSÖZ

Lisansüstü eğitimim ve tez sürecim boyunca büyük emeğin ve fedakârlığın sahibi, bilgi birikimi ve tecrübesiyle bana daima yol gösteren, bana gerekli imkânları sunarak araştırmalarım sırasında önerilerini esirgemeyen, yakınlığıyla her zaman cesaretlendiren ve destekleyen sevgili danışmanım sayın Prof. Dr. Ahmet Talât SAYGAÇ'a ve ikinci danışmanım sayın Prof. Dr. Diaa GADELMAVLA'ya,

İstanbul Üniversitesi, Fen Fakültesi, Astronomi ve Uzay Bilimleri Bölümü'nün sağlamış olduğu bilimsel ortam için Bölüm Başkanlığına, lisans ve yüksek lisans eğitimim boyunca emeği geçen tüm hocalarıma,

Tüm hayatım ve eğitimim boyunca benim yanımda olan, bana güvenerek cesaretlendiren,

amaçlarımın peşinden gitmem için beni her daim destekleyen ve gerçekleştirebilmem için

maddi ve manevi desteklerini hiçbir zaman esirgemeyen, sonsuz emek ve fedakarlığın sahibi,

sevgili annem Nurdoğan KALKAN ve sevgili babam Hüseyin KALKAN'a,

Sonsuz teşekkürlerimi sunarım.

Haziran 2022 Mirkan Yusuf KALKAN

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **vii**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiii**
SUMMARY ..... **xv**
1. GİRİŞ **1**
2. GENEL KISIMLAR **3**
2.1. GÜNEŞ 3
2.1.1. Güneş'in Fiziksel Özellikleri ve Kimyasal Bileşimi 3
2.1.2. Güneş'in İç Yapısı 4
2.1.2.1. Çekirdek *5*
2.1.2.2. Işınım (Radyasyon) Bölgesi *5*
2.1.2.3. Geçiş Bölgesi (Tachocline) *6*
2.1.2.4. Taşınım (Konveksiyon) Bölgesi *6*
2.1.3. Güneş Atmosferi 7
2.1.3.1. Işıkküre (Fotosfer) *7*
2.1.3.2. Renkküre (Kromosfer) *8*
2.1.3.3. Geçiş Bölgesi *8*
2.1.3.4. Taçküre (Korona) *9*
2.2. GÜNEŞ ÇEVRİMİ 9
2.3. GÜNEŞ AKTİVİTESİ 11
2.3.1. Güneş Lekeleri 11
2.3.2. Güneş Parlamaları 12
2.3.3. 10.7 cm Dalgaboyunda Güneş Radyo Akısı 15
2.3.4. Toplam Güneş Işınımı 16
2.4. UZAY HAVASI 16
3. MALZEME VE YÖNTEM **21**
3.1. MALZEME 21

3.2. YÖNTEM.....22
3.2.1. Yapay Sinir Ağları.....22
3.2.2. İleri Beslemeli Sinir Ağları.....24
3.2.3. Doğrusal Olmayan Otoregresif Dışsal Model (NARX).....25
3.3. MATLAB.....28
4. BULGULAR.....37
4.1. GLS VERİLERİNDEN OLUŞTURULAN NARX TAHMİN SONUÇLARI.....37
4.2. DİĞER GÜNEŞ AKTİVİTESİ PARAMETRELERİNDEN OLUŞTURULAN NARX TAHMİN SONUÇLARI.....39
4.3. YER MANYETİK İNDİSLE (AP) OLUŞTURULAN NARX TAHMİN SONUÇLARI.....45
5. TARTIŞMA VE SONUÇ.....48
KAYNAKLAR.....55
EKLER.....64
Ek 1.: Literatürdeki çeşitli tahmin yöntemleriyle elde edilen sonuçlar ile tez çalışmasında oluşturulan NARX modellerinin sonuçların karşılaştırılması (GLS cinsinden).....64
Ek 2.: NASA'nın 25. Güneş Çevrimi için GLS, Ap ve $F_{10.7}$ parametreleriyle yaptığı 9 Mayıs 2022 tarihine ait tahmin sonuçları (Tezin tamamlandığı Haziran 2022'de alınan değerler (www.nasa.gov/msfcsolar).....68
Ek 2. Devamı: NASA'nın 25. Güneş Çevrimi için GLS, Ap ve $F_{10.7}$ parametreleriyle yaptığı 9 Mayıs 2022 tarihine ait tahmin sonuçları (Tezin tamamlandığı Haziran 2022'de alınan değerler (www.nasa.gov/msfcsolar).....69
Ek 3.: 21 – 23. Güneş Çevrimlerinin verileriyle 24. Güneş Çevriminin NARX ile tahmini (Model24NARX:). 24. Güneş Çevriminin gerçek değerlerine yakın maksimum değerleri elde edilmiştir.....69
ÖZGEÇMİŞ.....71

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Güneş atmosfer katmanlarının sıcaklık değişimleri.....7

Şekil 2.2: Tamamen sakin Güneş'in birleştirilmiş fotosfer ve kromosfer görüntüsündeki hali. 14

Şekil 2.3: Güneş lekelerinin Güneş Çevriminin maksimum ve minimum evresinde görünür bölgedeki görüntüsü (üstte). Güneş parlamalarının Güneş Çevriminin maksimum ve minimum evresinde morötesi bölgedeki görüntüsü (altta). 15

Şekil 2.4: Güneş rüzgârlarından etkilenebilecek en önemli uydulardan biri: Uluslararası Uzay İstasyonu, 2010 yılında Uzay Mekiği Atlantis'in çıkış yapan ekibi tarafından fotoğraflandığı gibi, Dünya'nın yörüngesinde görülüyor. (Fotoğraf Kaynağı: NASA).....17

Şekil 2.5: 1750 – 2019 yılları aralığında yaklaşık 11 yıllık Güneş Leke Çevrimleri. Bu diyagram, leke sayısı tutarlı bir ölçekte kaydedilmeye başladığından beri Güneş lekesi sayısının zamanla nasıl değiştiğini göstermektedir. (Fotoğraf Kaynağı: NASA/ARC).....19

Şekil 3.1: Basit sinir ağı modeli, McCulloch ve Pitts (1943); (Courgeau ve diğ., 2016). 23

Şekil 3.2: Temel FFNN Model Diyagramı; Girdi verileri: Sinir ağlarının eğitilmesinde kullanılacak verilerin giriş katmanı, Gizli Katman(lar): Sinir ağlarının eğitildiği katman (Burada gösterilen ağırlıklar (*w*): Bir sinir hücresine gelen bilginin önemini ve sinir hücresinin üzerindeki etkisini gösteren faktördür (Öztemel, 2006), eşik değeri (*b*): Bir sinir ağında hiçbir girdi gerektirmeyip, net bir sonucun elde edilmesini sağlayan bir ek ağırlık kümesidir (Tezbaşaran ve Gelbal, 2018), Dikdörtgen içerisinde bir grafik şeklinde gösterilmiş bölüm olan Aktivasyon Fonksiyonu: Bir sinir hücresine gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur (Öztemel, 2006), Çıktı Katmanı: Bir sinir ağına gelen bir problemin gizli katman(lar) içerisinde işlenip bu problemin çözümünün çıktılarını düzenleyen katmandır, Çıktı Verileri: Sinir ağlarında işlenmiş verilerin bulunduğu kümedir. 25

Şekil 3.3: NARX Sinir Ağı Model Örneği: *x(t)*; giriş verileri *y(t)* (soldaki); hedef verileri, 1:*x*; gecikme değeri, *w*; ağırlıklar, *b*; gürültü değerleri, aktivasyon fonksiyonu (matematiksel fonksiyon içeren mavi blok), 10; sinir ağı adedi, *y(t)* (sağdaki); çıkış (tahmin sonucu) verileridir (MATLAB). 26

Şekil 3.4: NARX Sinir Ağının Mimarisi (Boussada ve diğ., 2018). (TDL; Tapped Delay Line -Gecikme Uygulanmış Hat). 27

Şekil 3.5: MATLAB'ın içerisindeki "Çalışma Alanı" ekranında giriş ve hedef verilerinin programa tanımlanması. "Value" bölümü veri matrisinin boyutlarını gösterir. Burada 'double' matristeki sayıların çift kat duyarlılık (*double precision*) ile tanımlandığını ifade eder. Bu format MATLAB yazılımı için varsayılandır. 29

Şekil 3.6: MATLAB yazılımı içerisindeki "Uygulamalar (Apps)" bölümünden "Neural Net Time Series" ve sonrasında "Nonlinear Autoregressive with External (Exogenous) Input (NARX) seçilir. Böylece NARX sinir ağları çalıştırılır. 30

Şekil 3.7: MATLAB yazılımı içerisinde giriş ve hedef verilerinin sinir ağlarına tanımlanması.....30

Şekil 3.8: MATLAB yazılımı içerisinde giriş verilerinin yüzde kaç öğrenme (training), onaylama (validation) ve test için kullanılacağının belirlenmesi. 31

Şekil 3.9: MATLAB yazılımı içerisinde tahmin yapacak yapay sinir hücresi sayısı ve gecikme parametresinin belirlenmesi. 31

Şekil 3.10: MATLAB yazılımı içerisinde öğrenme algoritmasının belirlenmesi. Bu tez çalışmasında Bayesyen Düzeltme seçilmiştir. Bunun nedeni ise Bayesyen Düzeltmenin istatistiksel hatayı (Ortalama Kare Hatası: MSE) en aza indirmek için tekrarlamaya devam etmesidir. Bu da hassas tahminlerin yapılması için tercih edilen yöntemlerdendir. 32

Şekil 3.11: MATLAB yazılımı içerisinde NARX öğrenme arayüzü. Burada MATLAB'ın yaptığı işlemler kontrol edilir (Basit Tahmin). 32

Şekil 3.12: MATLAB yazılımında NARX tahmin sonuçlarının gösterildiği arayüz. 33

Şekil 3.13: MATLAB yazılımında "Advanced Script" arayüzü: Bu kısımda NARX sinir ağının kodlarına erişilir. Ayrıntılı değişiklikler yapılabilmesi için bu kısma başvurulur. Bu aşamadan önceki tüm aşamalar NARX kodlarına erişilebilmek için uygulanır, bundan sonraki aşamalar ise asıl tahmin sürecinin uygulanması olacaktır. 33

Şekil 3.14: NARX'in temel parametrelerinin (yapay sinir hücresi sayısı ve gecikme katsayısı) ayarlanması. 33

Şekil 3.15: Verilerin NARX sinir ağına ne kadar (net.divideParam.xxxxRatio), hangi işlevle (dividerand: rastgele) ve neye bağlı (net.divideMode = 'time': zamana bağlı) dağıtılacağının ayarlanması 34

Şekil 3.16: *knownOutputTimesteps* ve *predictOutputTimesteps* işlevleri ile ileriye dönük tahmin edilecek veri sayısı belirlenmesi. 34

Şekil 3.17: Nihayer "Run" komutu ile tahmin gerçekleşitirecek script dosyasının çalıştırılması. 34

Şekil 3.18: MATLAB yazılımında NARX öğrenme arayüzü. Asıl tahmin yapılan aşamadır. 35

Şekil 3.19: NARX tahmin dosyaları. *y2,* tahmin sonucudur**.**.....35

Şekil 3.20: NARX tahmin sonuçlarının öğrenme ve test ilişki analizi. Bu tahmin sonuçlarının öğrenme – hedef ve test – hedef verilerinin ilişkilerinin oranı grafikle beraber ondalık olarak verilmiştir. 36

Şekil 3.21: NARX tahmin sonucu örneği. Bu örnek tahminde gelecekteki 5 veri tahmin edilmiştir. NARX sinir ağlarına veriler normalize edilerek tanımlandığı için sonuçlar da 0 ile 1 arasında çıkmaktadır. Bunun için normalizasyonu tersine çeviren işlemi (Denklem 3.6) uygulanmalıdır.....36

Şekil 4.1: 25. Güneş Çevriminde GLS değeri için 12 NARX modelinin karşılaştırılması (0-sıfır; Ocak 2020 tarihine denk gelmektedir). 38

Şekil 4.2: SSN_NARX I. ve II. Maksimum tahmin sonuçları ve Gnevyshev Boşluğu. 39

Şekil 4.3: 25. Güneş Çevrimi için GLS, POS, $F_{10.7}$, TGI parametreleriyle ayrı ayrı oluşturulmuş NARX tahmin modellerinin sonuçlarının ortalaması. 40

Şekil 4.4: 21.'den 25.'ye kadar olan Güneş Çevrimleri için Güneş Aktivitesi (25. Çevrim için tahmini) değişimleri (Mavi eğriler: GLS, Turuncu Eğriler: POS, Yeşil Eğriler: $F_{10.7}$, Kırmızı Eğriler: TGI). 42

Şekil 4.5: 25. Güneş Çevrimi için NARX modelleri sonuçlarının karşılaştırılması (Mavi eğri: GLS, Turuncu Eğri: POS, Yeşil eğri: $F_{10.7}$, Kırmızı Eğri: TGI) (Yüksek Düzgünleştirme uygulanmıştır). 43

Şekil 4.6: 25. Güneş Çevrimi için NARX modelleri sonuçlarının karşılaştırılması (Mavi eğri: GLS, Turuncu Eğri: POS, Yeşil eğri: $F_{10.7}$, Kırmızı Eğri: TGI) (Düşük Düzgünleştirme uygulanmıştır).. 44

Şekil 4.7: Ap yer manyetik indisi için oluşturulmuş NARX modelinin tahmin sonucu;. AP_NARX: I. Maksimum 13,77 nT (May 2023), II. Maksimum 15,01 (Kasım 2028).....46

Şekil 4.8: NARX tahmin modellerinin sonuçlarının ortalaması ile Ap değeri için tahmin edilen sonuç değerlerinin karşılaştırılması; Tarihsel olarak Ortalama GA (Mavi) değerinin I. Maksimum tarihi ve Ap değerinin (Turuncu) I. Maksimum tarihi ortak (Mayıs 2023), fakat Ortalama GA değerinin II. Maksimum tarihi ve Ap değerinin II. Maksimum tarihi arasında yaklaşık 3 yıllık bir gecikme gözlenmektedir. 46

Şekil 4.9: Ap yer manyetik indisi için oluşturulmuş NARX modelinin sonuçlarına düzgünleştirme işlemi uygulanmış hali. 47

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Güneş'in fiziksel özellikleri (Franknoi ve diğ., 2017) 3

Tablo 2.2: Güneş atmosferindeki atomların bolluk oranları (Franknoi ve diğ., 2017). 4

Tablo 4.1: Yapılan 12 NARX modeli arasında, hata analizi kriterlerine (*r*, RMSE ve NNSE) göre seçilen modeller. 37

Tablo 4.2: 25. Güneş Çevrimi için GLS (Model3_NARX baz alınarak yeniden oluşturulmuş), POS, TGI ve $F_{10.7}$ parametrelerine ait NARX tahmin modellerinin sonuçları. GLS (SSN_NARX) için Güneş lekesi miktarı, POS (FLARE_NARX) için parlama miktarı, TGI (TSI_NARX) için W/m^2, $F_{10.7}$ (RADIO_NARX) için 1 Güneş Akı Birimi (sfu) = $10^{-22}Js^{-1}m^{-2}Hz^{-1}$ birimleri kullanılmaktadır. 40

Tablo 4.3: 25. Güneş Çevrimi için GLS (Model3_NARX baz alınarak yeniden oluşturulmuş), POS, TGI ve $F_{10.7}$ parametrelerine ait NARX tahmin modellerinin Düşük ve Yüksek Düzgünleştirme işlevi uygulanmış sonuçları. GLS (SSN_NARX) için Güneş lekesi miktarı, POS (FLARE_NARX) için parlama miktarı, TGI (TSI_NARX) için W/m^2, $F_{10.7}$ (RADIO_NARX) için 1 Güneş Akı Birimi (sfu) = $10^{-22}Js^{-1}m^{-2}Hz^{-1}$ birimleri kullanılmaktadır (Orijinal: Sinir ağlarına herhangi bir şekilde düzgünleştirme işlevi uygulanmamış hali; Ort. (Yüksek): Yüksek düzgünleştirme işlevi uygulanmasından dolayı elde edilen ortalama değer; Ort. (Düşük): Düşük düzgünleştirme işlevi uygulanmasından dolayı elde edilen ortalama değer. 41

Tablo 4.4: Ap için NARX tahmin sonuçlarının ham hali, 40 nokta ile düzgünleştirilmiş sonuçlar ve istatistiksel hata değerleri (*r*, RMSE ve NNSE).....45

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

$M_{\oplus}$: Dünya Kütlesi
$(x)^m$: Kadir
^{14}C : Karbon (14) molekülü
Å : Ångström
Ap : Yermanyetik İndis
B : Manyetik Alan
cm : Santimetre
dk : Dakika
f : Tekil leke sayısı
g : Gram
g **(1.1. denklemi)**: Leke grubu sayısı
g/cm^3 : Yoğunluk
GHz : Giga Hertz
Hz : Hertz
J : Joule
k : Gözlem koşullarına bağlı standardizasyon faktörü
K : Kelvin
km : Kilometre
m : Metre
m/s^2 : İvme
nT : Nano Tesla
R : Güneş Lekeleri Rölatif Sayısı
r : Pearson İlişki Katsayısı
s : Saniye
W : Watt
W/m^2 : Akı

Kısaltmalar	Açıklama
$F_{10.7}$	: 10.7 cm Güneş Radyo Akısı
FFNN	: İleri Beslemeli Sinir Ağları
GLS	: Güneş Leke Sayısı
KKA	: Koronal Kütle Atımları
MATLAB	: **MAT**rix **LAB**oratory (Matris Laboratuvarı) Yazılımı
MLP	: Çok Katmanlı Algılayıcı
NAR	: Doğrusal Olmayan Otoregresif Model
NARX	: Doğrusal Olmayan Otoregresif Dışsal Model
NASA	: Amerika Ulusal Havacılık ve Uzay Dairesi
NNSE	: Normalize Nash-Sutcliffe Etkinlik Katsayısı
p-p	: proton – proton zinciri
POS	: Parlama Oluşum Sıklığı (Aylık Parlama Sayısı)
RMSE	: Ortalama Karekök Hatası
sfu	: Güneş Akı Birimi
TDL	: Gecikme Uygulanmış Hat
TGI	: Toplam Güneş Işınımı
YSA	: Yapay Sinir Ağı

ÖZET

YÜKSEK LİSANS TEZİ

25. GÜNEŞ ÇEVRİMİ İÇİN DOĞRUSAL OLMAYAN OTOREGRESİF DIŞSAL MODELLER (NARX) KULLANILARAK GÜNEŞ AKTİVİTESİ TAHMİNİ

Mirkan Yusuf KALKAN

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Astronomi ve Uzay Bilimleri Anabilim Dalı

Danışman : Prof. Dr. Ahmet Talât SAYGAÇ

II. Danışman : Prof. Dr. Diaa GADELMAVLA

Güneş bize en yakın yıldız olduğundan yıldızların ışınım mekanizmasını anlayabilmek için en iyi laboratuvardır. Bu doğal laboratuvar, farklı koşullar altında incelendiğinde aslında birbirine bağlı birçok parametrenin (Güneş Leke Sayısı, Parlama Oluşum Sıklığı, 10.7 cm Güneş Radyo Akısı, Toplam Güneş Işınımı) yaklaşık 11 yıllık dönemler halinde değiştiği görülmektedir. Güneş Aktivitesinin bu değişimi 1700'lü yıllardan beri takip edilen Güneş Çevrimleridir. İçerisinde bulunduğumuz 25. Güneş Çevriminin takibi ve tahmin edilmesi önümüzdeki yaklaşık 11 yıllık sürecin Dünya üzerindeki günlük yaşamı ve Dünya atmosferi dışındaki uydular ve uzay istasyonları başta olmak üzere, uzay araçlarının üzerinde olası zararların da önlenebilmesi için bilimsel olarak araştırmacılar tarafından takip edilecek önemdedir. Son yıllarda gelişen ve insan sinir sistemi temel alınmış yapay sinir ağları, birçok alanda sınıflama ve tahmin uygulamalarında kullanılmaktadır.

Güneş aktivitesinin gelecekteki davranışını tahmin etme yeteneği, Dünya üzerindeki etkisi nedeniyle son derece önemli hale gelmektedir. Bir sonraki güneş çevriminin hem genliği hem de zamanlaması ile ilgili tahminler, Uzay Hava Durumunun çeşitli sonuçlarını tahmin etmede yardımcı olmaktadır. Güneş aktivitesi tahmini alanında çeşitli tahmin teknikleri uygulanmış ve değişen derecelerde başarılar elde edilmiştir. Bu tekniklerden bir tanesi ise sinir ağları yöntemidir. Bu tezde, çeşitli sinir ağı tabanlı modeller oluşturulmuş ve uyumluluğu en iyi olan modeller, Güneş Çevriminin şeklini ve maksimum değerleri tahmin etmek için kullanılmıştır. Tez çalışmasında Güneş Aktivitesi (Güneş Leke Sayısı (GLS), Güneş Parlama Sayısı (POS; C, M ve X X-ışını sınıflarında), Toplam Güneş Işınımı (TGI), 10.7 cm Güneş Radyo Akısı ($F_{10.7}$)) ve Yermanyetik İndis (Ap) verilerinin aylık ortalamaları kullanılarak ve 0 – 1 arasında basit normalizasyon işlemi yapılarak sinir ağları tahmin tekniklerinden "Doğrusal Olmayan Otoregresif Dışsal Model (NARX - *Nonlinear AutoRegressive eXogenous)*" ile 25. Güneş Çevrimi için sayılan her bir parametrenin tahmin işlemi yapılmıştır. Bu parametrelerin beraber kullanılma amacı sadece Güneş'in durum takibi için değil Güneş – Dünya Etkileşimi (Uzay Havası - *Space Weather*) kapsamında uzay araçlarının tasarımı, haberleşme ağının güvenliği ve iklim olaylarına etkisini tahminler ışığında incelemektir. Geliştirilen sinir ağı modelleriyle, son 4 Güneş Çevrimi (21 – 24. Çevrimler) sırasında gözlemlenen parametrelerin zamana bağlı davranışı incelenmiştir. Bu tez çalışmasında, 25. Güneş Çevriminde GLS maksimum değeri ve tarihi: Model3_NARX kodlu model ile 104,58 (Mayıs 2024), Model7_NARX kodlu model ile 113,31 (Nisan 2026) ve SSN_NARX kodlu model ile I. Maksimum 96,18 (Mayıs 2023), II. Maksimum 114,1 (Temmuz 2025) olarak iki tepeli (Gnevyshev Boşluğuna sahip) tahmin edilmiştir.

Haziran 2022, 88 sayfa.

Anahtar kelimeler: Güneş Aktivitesi – Güneş Çevrimi – Yapay Sinir Ağları

SUMMARY

M.Sc. THESIS

SOLAR ACTIVITY PREDICTION WITH NONLINEAR AUTOREGRESSIVE EXOGENOUS MODELS FOR SOLAR CYCLE 25

Mirkan Yusuf KALKAN

İstanbul University

Institute of Graduate Studies in Sciences

Department of Astronomy and Space Sciences

Supervisor : Prof. Dr. Ahmet Talât SAYGAÇ

Co-Supervisor : Prof. Dr. Diaa GADELMAVLA

Since the Sun is the closest star to us, it is the best laboratory to understand the radiation mechanism of stars. When this natural laboratory is examined under different conditions, it is seen that many interconnected parameters actually occur in periods of about 11 years. This variation of Solar Activity is the Solar Cycle that have been followed since the 1700s. The monitoring and predicting of the Solar Cycle 25 we are in is being scientifically examined by researchers in order to prevent possible damage to the daily life on Earth and satellites outside the Earth's atmosphere, space stations and spacecraft for the next 11 years. Artificial neural networks, which have developed in recent years and are based on the human nervous system, are used in classification and prediction applications in many fields.

The ability to predict the future behavior of Solar Activity becomes extremely important because of its impact on Earth. Predictions of both the amplitude and timing of the next Solar Cycle are helpful in predicting the various consequences of Space Weather. Various prediction techniques have been applied in the field of Solar Activity prediction, with varying degrees of success. One of these techniques is the neural network method. In this thesis, various neural network-based models are constructed and the best-fit models are used to predict the shape and maximum values of the Solar Cycle 25. In the thesis study, monthly Solar Activity (Solar Spot Number (GLS), Solar Flare Number (C, M and X X-ray classes), Total Solar Irradiance (Solar Constant Variation), 10.7 cm Solar Radio Flux) and Geomagnetic Index (Ap) data each parameter counted for the Solar Cycle 25 has been predicted with the "Nonlinear Autoregressive Exogenous Model (NARX - Nonlinear AutoRegressive eXogenous)" neural network technique by using the averages and performing simple normalization between 0 and 1. The purpose of using these parameters together is not only to monitor the situation of the Sun, but also to examine the design of spacecraft, the security of the communication network and its effect on climate events within the scope of Sun-Earth Interactions (Space Weather) in the light of our predictions. With the developed neural network models, the time dependent behavior of the counted parameters observed during the last 4 Solar Cycles (Cycles 21 - 24) was investigated. In this thesis, the SSN maximum value (date) in the Solar Cycle 25 is: 104.58 (May 2024) with the model code Model3_NARX, 113.31 (April 2026) with the model code Model7_NARX and 114.1 (July 2025) with the model code SSN_NARX has been predicted.

June 2022, 88 pages.

Keywords: Solar Activity – Solar Cycle – Artificial Neural Network

1. GİRİŞ

Güneş Sistemi'nin yaklaşık kütle merkezinde bulunan Güneş, Dünya'nın enerji kaynağı olan en yakın yıldızdır. Güneş tüm yıldızlar gibi kendi gücüyle parlayan, merkezi aşırı derecede sıcak, büyük ölçüde iyonize gazdan oluşan devasa bir küresel yapıya sahiptir. Güneş, çapı boyunca 109 Dünya yan yana sığdırılabilir ve 1.3 milyon Dünya'yı içine alacak kadar hacime sahiptir. İnsanlar gökyüzünü merak etmeye başladığından beri Güneş, tarlalarda ekin ekme zamanından uyku saatlerini ayarlamaya kadar günlük yaşamı şekillendirmiştir. Ayrıca hava durumu ve iklim gibi atmosfer ile ilgili süreçlerin de gidişatını etkilemiştir. Bilim ve teknoloji geliştikçe bilim insanları Güneş üzerine merakını daha da arttırmış ve fizik, kimya gibi temel bilimler çatısı altında Güneş'in enerji üretme mekanizmasını hem atmosfer gözlemleriyle hem de teorik yaklaşımlarla anlamaya çalışmıştır. Günümüzde yer tabanlı gözlemevleri ve uydularla, fotosferden koronaya kadar Güneş'in atmosferinin her bir katmanı ayrıntılı bir şekilde incelenmektedir. Bu katmanlardaki karmaşık fiziksel olayların gidişatını, gözlemsel imkânı olmayan Güneş'in içyapısında çekirdekte gerçekleşen nükleer tepkimelerden üretilen enerjinin, yüzeyine (fotosfer) kadar her bir içyapı katmanında ne tür durumlarla karşılaşabileceği teorik yaklaşımlarla incelenmiş ve incelenmektedir.

Güneş, devasa bir plazma küresidir (yaklaşık olarak küredir; fakat plazma yapısından ve ekvator – kutuplar arasındaki hız farkından dolayı tam küresel olarak tanımlanmamaktadır). Güneş'in içyapısında plazma basıncı manyetik basıncı aşar dolayısıyla plazma kinetik enerjisi de manyetik enerjiyi aşar. Plazmanın bu hareketi manyetik alanı kontrol eder. Manyetik alan, plazma akışları tarafından taşınır ve dönüştürülür (Hathaway 2015). Bu tip fiziksel olayların sonuçları atmosferin her katmanında farklı sonuçlar olarak gözlenir. Plazma basıncının ve manyetik alan arasındaki denge değişimlerinden dolayı oluşan sonuçların atmosferdeki konumu "aktif bölge" olarak adlandırılır. Güneş'in aktif bölgelerindeki olayların zamana bağlı olarak sıklığının ve şiddetinin değişimi "Güneş Aktivitesi" olarak tanımlanır. 1700'lü yıllardan beri Güneş Aktivitesinin yaklaşık 11 yıllık bir değişim gösterdiği gözlenmiştir ve "Güneş Aktivite Çevrimi" olarak tanımlanmıştır.

Güneş Aktivite Çevrimlerinin gelecekteki davranışını tahmin etme yeteneği, Dünya üzerindeki etkisi nedeniyle son derece önemli hale gelmiştir. Güneş Aktivitesini oluşturan olayların sıklığı

ve şiddetinin değişimi yeryüzündeki yaşamı olumsuz olarak etkilemektedir. Bu duruma bağlı olarak aktif bölge olaylarını takip ve tahmin etmek teknolojinin ilerlemesiyle alınacak önlemlerin de üretilmesinde önemli bir rol oynamaktadır. Bununla birlikte yörüngedeki binlerce uydu, Uluslararası Uzay İstasyonu'nda uzun süreli görev yapan astronotlar, cep telefonu, GPS ve kablosuz iletişim kullanan milyonlarca insan için artık büyük güneş fırtınalarının ne zaman olacağını ve Dünya'yı ne kadar güçlü bir şekilde etkileyeceğini tahmin etmeye çalışmak üzerine yapılan yatırımlar çok önemli hale gelmiştir (Franknoi ve diğ, 2017). Güneş Aktivite Çevrimi tahminlerinde kullanılan yöntemler günden güne çeşitlenmekte ve geliştirilmektedir.

McCulloch ve Pitts (1943) tarafından ileri sürülen insan sinir sistemi örnek alınarak geliştirilmiş sinir ağları aracılığıyla tahmin yönteminin, Güneş Aktivite Çevrimi için de kullanılabilirliği literatürdeki birçok çalışmada görülebilmektedir. Zamana bağlı karmaşık olayları tahmin etmede kullanılabilme amaçlı geliştirilmiş Doğrusal Olmayan Otoregresif Dışsal (*NARX*) sinir ağları, tahmin işlemini yapacak sinir hücrelerinin sayısı ve gecikme değeri gibi tahmin şartları uygun bir şekilde ayarlandığında, duyarlı tahminler çıkarılabilmektedir.

Bu tezin Genel Kısımlarının ilk bölümünde Güneş'in içyapısı ve atmosferi, ikinci bölümünde Güneş Çevrimleri, üçüncü bölümünde tahminlerde kullanılan Güneş Aktivitesinin bileşenleri ve son bölümünde Güneş – Dünya etkileşimlerinin açıklandığı Uzay Havası ele alınmıştır. Malzeme ve yöntem bölümünde ilk olarak Yapay Sinir Ağları başlığı altında basitten karmaşığa İleri Beslemeli Sinir Ağları (FFNN), Doğrusal Olmayan Otoregresif Model (NAR) ve Doğrusal Olmayan Otoregresif Dışsal Model (NARX) tanıtılmıştır. Sonraki bölümde tez çalışmasında kullanılan MATLAB yazılımı hakkında özet bir bilgi verilmiştir ve bu yazılım ile NARX sinir ağları ile tahmininde kullanılacak verilerin nasıl işleme hazırlandığı açıklanmıştır. Bulgular bölümünde, ilk olarak Güneş Leke Verilerinden oluşturulan tek parametreli NARX tahmin modelleri, Tüm Güneş Aktivitesi verilerinden (GLS, POS, TGI, $F_{10.7}$) oluşturulan çoklu parametreli NARX tahmin modelleri ve Jeomanyetik İndis Verileri eklenerek daha çok parametreli NARX tahmin modellerinin sonuçları güncel ve gerçek verilerle karşılaştırlarak bu yöntemlerin doğruluğu ve güvenilirliği tartışılmıştır.

2. GENEL KISIMLAR

2.1.GÜNEŞ

2.1.1. Güneş'in Fiziksel Özellikleri ve Kimyasal Bileşimi

Tablo 2.1: Güneş'in fiziksel özellikleri (Franknoi ve diğ., 2017)

Kütle	1.99 x 10^{33} g (333.400 $M_{\oplus}$)
Yarıçap	7 x 10^{9} m
Yoğunluk	1,41 g/cm^3
Görünen Parlaklık	-26 ^{m},74
Mutlak Parlaklık	4 ^{m},83
Dünya'ya Uzaklık	1,49 x 10^{11}m
Kendi Ekseni Etrafında Dönüş Süresi	24 gün 16 saat (ekvatorda)
Tayf Sınıfı	G2V
Yüzey Çekim İvmesi	273 m/s^2
Yüzey Sıcaklığı	5800 K
Işınım Gücü	3,8 x 10^{26} W
Toplam Güneş Işınımı (Ortalama)	1370 W/m^2

Güneş, sayıca %92 oranında, kütlece %73,4 oranında Hidrojen elementinden oluşur. Geriye kalan oranda ise çoğunluk olarak Helyum elementi ve çok az bir oranda Güneş'in oluştuğu bulutsudan kaynaklanan ağır elementleri içerir (Franknoi ve diğ., 2017).

Tablo 2.2: Güneş atmosferindeki atomların bolluk oranları (Franknoi ve diğ., 2017).

Element	Yüzdelik Atom Sayısı	Yüzdelik Kütle
Hidrojen	92	73,4
Helyum	7,8	25
Oksijen	0,06	0,8
Karbon	0,02	0,2
Demir	0,003	0,14
Kükürt	0,002	0,05
Neon	0,01	0,16
Azot	0,008	0,09
Silisyum	0,004	0,09
Magnezyum	0,003	0,06

2.1.2. Güneş'in İç Yapısı

Güneş, çekirdeğinde Hidrojen atomlarını Helyum atomlarına dönüştürürken kütlenin bir kısmı her saniyede 4 milyon ton kütleden 4 x 10^{26} J kadar enerji açığa çıkartır. Bu dönüşüm için gerçekleşen çekirdek tepkimesi yani proton – proton (p - p) zinciri tepkimeleri şöyledir:

$$\begin{aligned} p + p &\rightarrow {}^{2}He + e^{+} + \upsilon_e \\ {}^{2}He + p &\rightarrow {}^{3}He + \gamma \\ {}^{3}He + {}^{3}He &\rightarrow {}^{4}He + p + p \end{aligned} \qquad (2.1)$$

Bu enerjinin Güneş çekirdeğinden dışarıya taşınması, Güneş'in iç dinamikleriyle birleşerek, Güneş aktivitesinde, nihayetinde gezegenlerarası alanda ve en önemlisi Dünya'nın ikliminde değişimler yaratır. Güneş'in içyapısında farklı bölgeler, belirli zaman ölçeklerinde birçok farklı "uzay havası" *(Space Weather)* olayının oluşması için bir araya gelerek enerji taşınımı sürecinde büyük rol oynar (Strong ve diğ., 2012). Genelde bu Güneş enerjisinin taşınımı; iletim, ışınım ve konveksiyon olarak üç farklı şekilde gerçekleşir. İletim, yoğun enerjili iç bölgelerde seyrek gerçekleşir; fakat Güneş atmosferi için önemli bir taşınım şeklidir. Güneş'in iç bölgesinde konveksiyon ile taşınım için uygun koşullar yüzeye daha yakın bölgelerde sağlanır; ancak ışınım ile taşınma Güneş'in iç bölgelerinde baskın bir rol oynar.

2.1.2.1. Çekirdek

Çekirdek, Güneş kütlesinin yaklaşık yarısı ve enerji üretiminin %98'i ve yarıçapının % 25'i kadarını oluşturan nükleer füzyonun meydana geldiği bölgedir (Strong ve diğ., 2012). Güneş merkezinden uzaklaştıkça, sıcaklık ve yoğunluk kütleçekimine bağlı olarak azalır, böylece enerji taşınımının hızı düşer (Stromgrew, 1968). Kütleçekimi ve basınç kuvvetleri çekirdeği *hidrostatik* dengede tutar. Çekirdekte gerçekleşen *füzyon* tepkimesinin hızı hem yoğunluk hem de sıcaklık ile doğru orantılıdır. Füzyon tepkimelerinin artışı, sıcaklığın yükselmesine ve çekirdeğin genişlemesine neden olur. Çekirdeğin genişlemesi ortamın yoğunluğunu azaltır ve füzyon tepkimelerinin hızını düşürür. Böylece Güneş doğal olarak oluşan, kendi kendini düzenleyen bir füzyon reaktörüdür (Strong ve diğ., 2012). Bu füzyon tepkimelerinden nötrinolar ve elektromanyetik ışınım (gama ışınımı) açığa çıkar. Gama ışını fotonları çekirdek ortamında rastgele yönde saçılır, soğrulur veya tekrar yayınlanarak Güneş'in yüzeyine ulaşır. Bu olay yaklaşık 30 milyon yılda gerçekleşir (Stix, 2003; Strong ve diğ., 2012). Bu bölgede sıcaklık yaklaşık 15 milyon K kadardır.

2.1.2.2. Işınım (Radyasyon) Bölgesi

Çekirdeğin üzerinde, enerjiyi aktarmanın radyasyon yoluyla gerçekleşmesinden dolayı radyasyon bölgesi olarak bilinen bir bölge bulunur. Bu bölge Güneş yüzeyine olan uzaklığın yaklaşık %25'inden başlar ve yüzeye giden yolun yaklaşık %70'ine kadar uzanır. Çekirdekte üretilen ışık, radyasyon bölgesinden çok yavaş taşınır. Çünkü bu bölgedeki maddenin yoğunluğu, bir fotonun bir parçacıkla karşılaşmadan çok uzağa gidememesine, çok fazla yön değiştirmesine ve bir miktar enerji kaybetmesine neden olur (Franknoi ve diğ., 2017). Yüzeye

doğru gittikçe Güneş plazmasının basıncı hidrostatik denge korunma şartıyla azalır ve ortam sıcaklığı 10 milyon K'den 2 milyon K değerine kadar düşer. Bu sıcaklık daha ağır elementlerin bazıları için iyonlaşamayacak kadar düşüktür (Strong ve diğ., 2012).

2.1.2.3. Geçiş Bölgesi (Tachocline)

Tachocline, konveksiyon bölgesinin altında Coriolis, basınç, kaldırma kuvveti ve Lorentz kuvvetleri etkisinde oluşan katmandır. 1980'li yılların sonlarında keşfedilen bu katman, konveksiyon bölgesi ile radyasyon bölgesi arasında Güneş Dinamosunda temel bir rol oynadığı düşünülmektedir (Garaud 2020).

Varlığı 30 yıldan fazla bir süredir bilinmesine rağmen, henüz tutarlı bir model oluşturulamamıştır. Bazı modeller düzenli ters rotasyonlu iki kutuplu manyetik alanlar oluştursa da (Käpylä ve diğ., 2012; Passos ve Charbonneau, 2014; Strugarek ve diğ., 2017) genellikle Tachocline kaynaklı olduğuna inanılan Güneş lekeleri ve manyetik çıkıntılar oluşturan manyetik akı tüpleri gibi Güneş dinamosunu karakterize eden daha küçük özelliklerden yoksundurlar (Parker 1955; Wood ve Brummel 2018).

Tachocline'nın en dikkat çekici ve şaşırtıcı özelliği, kalınlığının helyosismolojik tekniklerle Güneş yarıçapının % 4'ünden daha az olduğu saptanmıştır (Basu ve Antia 2003). Tachocline, mevcut inversiyon (sıkışma) teknikleriyle çözümlenemeyecek kadar incedir (Kosovichev 1996; Schou ve diğ., 1998, Antia ve diğ., 1998), dolayısıyla daha önceki çalışmalarda olduğu gibi (Antia ve diğ., 1998; Antia ve Basu, 2011) bu katmanın özellikleri ve zamanla değişimlerini belirlemek için daha iyi modeller oluşturulması gerekmektedir. Bu nedenle bir tachocline modelinin benimsenmesi için farklı parametrelerle yapılan hesaplamalarla gözlemlerin karşılaştırılabilir derecede uyumlu olması gerekir. (Antia ve Basu, 2019).

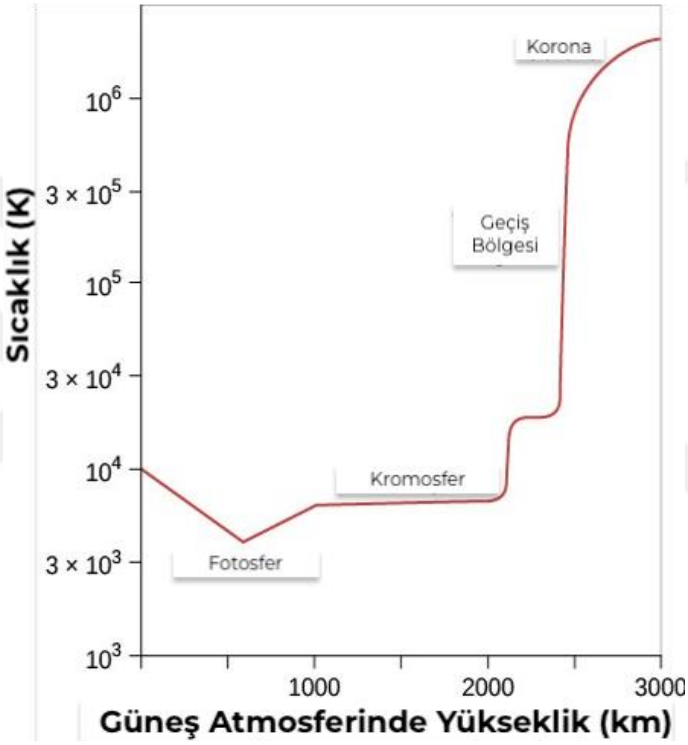
2.1.2.4. Taşınım (Konveksiyon) Bölgesi

Taşınım bölgesi 0,7 – 1 Güneş yarıçapı arasında yer alır. Konveksiyon bölgesi, yüzeye yakın değişim katmanının (fotosfer) altında rotasyonel halde kısıtlanmıştır (Vasil ve diğ., 2020). Ağır elementlerin iyonları, fotonları daha kolay soğurur ve bu sayede ortamın geçirgenliği artar. Bu durum ortamın sıcaklığının artmasına ve plazmanın genişlemesine sebep olur. Bu katmanda, ortamın yoğunluğunun azalması sebebiyle enerjisi görünür bölgeye kadar düşen fotonların daha üst katmanlara taşınmasına neden olur ve ortamın geçirgenliği azalır. Bu durum ortamın

sıcaklığını 5800 K'e kadar azaltır; böylece ortam daha yoğun hale gelir ve yavaşça daha aşağı bölgelere düşer. Burada konvektif bir taşınım baskındır. Bu taşınım konveksiyon hücreleri tarafından gerçekleşir ve en küçük boyutlu hücreler yaklaşık 1000 km kadardır (Strong ve diğ., 2012).

2.1.3. Güneş Atmosferi

2.1.3.1. Işıkküre (Fotosfer)



Şekil 2.1: Güneş atmosfer katmanlarının sıcaklık değişimleri

Işıkküre (Fotosfer), alt sınırı ışık geçirgenliğinin minimum (opasitenin en yüksek) olduğu, üst sınırında renkküre (kromosfer) bulunan atmosferin en alt katmanıdır. İsminin kaynağı Yunanca'da "*phos*" veya "*photos*" (ışık) ve "*spheria*" (küre) kelimelerinin birleşmesinden gelmektedir. Etkin sıcaklığı ortalama 5878 K'dir. Fotosferden çıkan enerjinin kaynağı Güneş'in iç katmanlarından gelmektedir. Fotosferin kalınlığı yaklaşık 400 km olarak ölçülmüştür ve Güneş'in görünen çapından söz edildiğinde fotosferin çevrelediği kürenin çapı anlamına gelmektedir.

Teleskoplarla yapılan optik Güneş gözlemlerinde koyu benekli, kaynayan ve küresele yakın bir yapı görülmektedir. Bu kaynama görüntüsü, aslında Güneş fotosferinde "bulgurlanma" (*granulation*) adlı bir olaydan kaynaklanmaktadır. 700 ile 1000 km çapa

sahip ve ömürleri 5 ile 10 dk arasında olan granüllerin, çevresinde daha karanlık yani daha soğuk bölgeler bulunmaktadır. Daha büyükleri, ömürleri 24 saat kadar olan süpergranüller ise yaklaşık 35.000 km çapındadır (Franknoi ve diğ., 2017).

Granüllerin hareketleri, hemen üzerindeki gazların spektrumundaki Doppler kaymaları ile incelenebilir. Parlak granüller, fotosferin altından saniyede 2 ila 3 kilometre hızla yükselen daha sıcak gaz sütunlarıdır. Bu yükselen gaz fotosfere ulaştığında yayılır, soğur ve tekrar granüller arasındaki daha karanlık bölgelere geri döner. Ölçümler, granüllerin merkezlerinin, granüller arası bölgelerden 50 ila 100 K daha sıcak olduğunu göstermektedir. (Franknoi ve diğ., 2017).

2.1.3.2. Renkküre (Kromosfer)

Bu yüzyıla kadar kromosfer, ancak Tam Güneş Tutulması sırasında fotosfer, Ay tarafından örtülebildiğinde görülebiliyordu. On yedinci yüzyılda, birkaç gözlemci, Güneş'in fotosferin örtülmesinden kısa bir süre sonra, Güneş'in kenarında kendilerine dar kırmızı bir "çizgi" veya "püskül" gibi görünen kısmı tanımladılar. Yunanca "renkli küre" anlamına gelen kromosfer adı bu kırmızı çizgiye verildi**.** Tutulmalar sırasında yapılan gözlemler, kromosferin yaklaşık 2000 ila 3000 km kalınlığında olduğunu ve bu katmanın ayrı dalgaboylarında ışık yayan sıcak gazlardan oluştuğunu göstermektedir. Kromosferin kırmızımsı rengi, tayfın görünür kısmındaki en güçlü emisyon çizgilerinden Güneş'in hakim bileşeni Hidrojen elementine ait Hidrojen-alfa çizgisinden kaynaklanır.

Kromosferin sıcaklığı yaklaşık 10.000 K'dir. Bu, kromosferin fotosferden daha sıcak olduğu anlamına gelir ki; bu şaşırtıcıdır. Bilinen tüm durumlarda, ısı kaynağından uzaklaştıkça sıcaklık düşer. Fakat kromosfer Güneş'in merkezinden fotosferden daha uzakta olmasına rağmen bu durumun tam tersini göstermektedir. (Franknoi ve diğ., 2017).

2.1.3.3. Geçiş Bölgesi

Sıcaklıktaki artış kromosfer ile durmaz. Yukarısında, sıcaklığın 10.000 K'den (kromosfer) yaklaşık 1 milyon K'e kadar değiştiği bir bölge bulunur. Güneş'in hızlı sıcaklık artışının meydana geldiği bu kısmına geçiş bölgesi denir. Bu katman sadece birkaç on kilometre kalınlığındadır. Buna rağmen, bu bölge koronal ısıtma problemini incelemek için büyük bir değere sahiptir. Bu katman koronanın alt sınırını oluşturur. Nihayetinde koronayı

ısıtan ve Güneş rüzgârını hızlandıran tüm enerji bu ince katmanı geçmek zorundadır. Bu nedenle geçiş bölgesinin yapısı ve dinamikleri korona fiziği hakkında da bilgi içerir. Geçiş bölgesinin (manyetik) yapısını ortaya çıkarmak, koronal ısıtmayı anlamanın en önemli yöntemlerinden biridir (Peter, 2001).

Uzun bir süre boyunca, gökbilimciler gerçekten de Güneş'i bu şekilde düşündüler. Ancak, bu katman fikri (fotosfer, kromosfer, geçiş bölgesi, korona) Güneş için varsayılan modeli oldukça iyi tanımlarken, buradaki durum Güneş atmosferinin sıcak ve soğuk bölgelerin birbirine karıştığı gerçeğinden daha karmaşıktır (Franknoi ve diğ., 2017). Başka bir deyişle Güneş atmosferinin katmanları arasında kesin sınırlar yoktur.

2.1.3.4.Taçküre (Korona)

Güneş atmosferinin en dış kısmına korona denir. Kromosfer gibi, korona da ilk olarak tam tutulmalar sırasında gözlendi. Kromosferden farklı olarak, korona yüzyıllardır bilinmektedir: Romalı tarihçi Plutarch tarafından atıfta bulunulmuştur ve Kepler tarafından ayrıntılı olarak tartışılmıştır. Korona, milyonlarca kilometrelere kadar uzanır ve dolunayın yaklaşık yarısı kadar ışık yayar. Bir tutulma gerçekleşene kadar bu ışığı görmememizin nedeni, fotosferin çok güçlü parlaklığa sahip olmasıdır. Parlak şehir ışıklarının zayıf yıldız ışığını görmeyi zorlaştırması gibi, fotosferden gelen yoğun ışık da koronadan gelen zayıf ışığı gizler. Koronayı Dünya'dan görmek için en iyi zaman tam güneş tutulması sırasında olsa da, yörüngedeki uzay aracından kolayca gözlemlenebilir. Daha parlak kısımları artık, Güneş'in parlamasını bir örtücü diskle (Güneş'in hemen önünde olacak şekilde tutulan dairesel bir malzeme parçası) görüntüden uzaklaştıran özel bir aletle (koronograf) fotoğraflanabilir. (Franknoi ve diğ., 2017).

2.2.GÜNEŞ ÇEVRİMİ

11 yıllık döngüsel değişim gösteren güneş lekelerinin bir ölçüsü, güneş aktivitesinin ortak bir göstergesini temsil eder. Güneş Çevrimi olarak bilinen güneş lekelerinin bu döngüsel varyasyonu, ilk olarak 1843'te Samuel Heinrich Schwabe tarafından uzun süreli gözlemleri yoluyla keşfedildi. (Uwamahoro, 2008)

Güneş'in küresel manyetik alanının, Güneş'in içyapısı ve atmosferinde periyodik olarak üretilen manyetik alanların toplamının bir dinamo gibi işlemesi sonucunda oluştuğu kabul

edilir. Bu manyetik alanla ilişkili olan ve genellikle 11 yıllık periyodik değişimler halinde görülen Güneş Çevrimleri, bir fotonun Güneş'in merkezinden atmosferine kadar yolculuğu hakkında bilgi verir. Güneş aktivite çevrimini oluşturan birçok bileşenin (Başlıca; Güneş lekeleri, Güneş parlamaları, filamentler vs.) şiddeti, oluşma frekansı ne kadar farklı bir seyir izlese de hepsinin ortak periyodu yine yaklaşık 11 yıl kadardır. Güneş Çevrimi kavramının temelleri başlangıçta 1800'lü yıllarda Güneş lekelerinin sayılarının günlük olarak takibi ile başlamıştır. Sonrasında gözlem teknikleri ve teknolojisi geliştikçe Güneş'in üzerinde gerçekleşen olayların şiddetleri ve sıklıkları da takip edilerek yeni bileşenler eklenmiştir. Son yıllarda Güneş Çevrimini anlamak, Güneş'te gerçekleşen olayların Dünya'ya potansiyel olarak zarar verebilecek etkilerinin olacağı kabul edildikten sonra bilimsel bir ilgiden çok bir ihtiyaç haline gelmiştir (Balogh ve diğ., 2015). Bu yüzden içerisinde bulunulan Güneş Çevrimi dâhil sonraki çevrimlerin de tahmini önem kazanmaktadır. Bu tahminlerin gözlemlerden elde edilmiş geniş bir veri ağı ve elde edilen sonuçların çeşitli istatistiksel yöntemlerle test edilerek güvenilirliği yüksek derecede olması kaydıyla uygulanması gerekmektedir. Çoklu çevrim verilerinin olması ve bu veriler arasında bir ilişki kurulması durumunda, tahmin edilecek çevrimin periyodu ve maksimum leke sayısı (çevrim maksimumu) tayin edilebilir.

Güneş Çevrimi hakkında söz eden ilk kişi olan Christian Horrebow 1776 yılına ait günlüğünde; Güneş lekelerinin oluşumlarının değişiminin periyodik olarak gerçekleştiği düşüncesinde olsa da lekelerin gözlem sayısının yetersizliğinden dolayı kesin bir düzen görülemediğini belirtmiştir (Wolf, 1877). Ancak Horrebow, bu olası periyodik değişimden bahsetse de Güneş Çevrimi, 1844 yılında Heinrich Schwabe'nin *Astronomische Nachricten'*deki yayınında Güneş lekelerinin ve lekesiz günlerin yaklaşık 10 yıllık bir çevrim davranışı gösterdiğini belirtmesine kadar tam olarak keşfedilememiştir (Hathaway, 2015).

Her Güneş Çevriminin kendine has özellikleri bulunur. Çevrimlerin periyodu ve genliği gibi özellikler belirlemek, çevrime ait minimum tarihlerinin belirlenmesine bağlıdır. Sık kullanılan bir yöntem olan 13 aylık düzeltilmiş ortalama Güneş leke sayısı ile bu tarihler belirlenir. Bu yöntemin kullanılma sebebi ise ilgili ayın diğer aylarla bağlantısının da devreye sokulmasıdır. Fakat maksimum ve minimum tarihleri diğer aktivite parametreleri dikkate alındığında değişiklik gösterebilir (Hathaway, 2015). Örneğin bir çevrimin

maksimumu ile minimumu arasındaki ışıma gücü değeri (TGI) % 0,07 kadar değişmektedir (Ökten ve Gültekin Annak, 2020).

Çevrim periyodu, çevrimin başlangıç minimumundan bitiş minimumuna kadar geçen süre olarak tanımlanır. Bununla birlikte bir çevrimin periyodu kendisinden önceki çevrimin davranışına bağlıdır. Hathaway (2015)'e göre 1. den 22. ye kadar çevrimlerin ortalaması 131,7 aylıktır ve bu değer neredeyse 11 yıla karşılık gelir.

Çevrim minimumundan maksimuma geçen süre neredeyse her zaman maksimumdan minimuma geçen süreden daha kısadır ve bir çevrimde minimumdan maksimuma yükselmesi yaklaşık 48 ay (4 yıl) ve maksimumdan minimuma düşüş yaklaşık 84 ay (7 yıl) sürer (Hathaway, 2015).

Güneş'teki çevrimsel manyetik aktivite zamanla düşüşe ve yükselişe geçebilir; ancak bu değişimin uzun vadeli bir tahminle anlamlı olabilmesi, Güneş aktivitesinin kaotik olmasından dolayı zordur. ^{14}C verilerinden, binlerce yıl öncesine dayanan Güneş aktivitesi verileri türetilmiştir. Bu verilerden 11 yıllık Schwabe Çevrimi, 22 yıllık Hale Çevrimi, 205 yıllık de Vries / Suess Çevrimi, 88 yıllık Gleissberg Çevrimi, 600-700 yıllık çevrimler, 2300 yıllık Hallstatt çevrimleri gibi değişimler tespit edilmiştir (Beer, 2000; Usoskin ve diğ., 2003).

2.3.GÜNEŞ AKTİVİTESİ

2.3.1. Güneş Lekeleri

Güneş lekeleri, güneş yüzeyinde gözlenen koyu lekelerdir. İlk Avrupa gözlemleri, teleskopun icadından kısa bir süre sonra 1610'da Galileo tarafından yapılmıştır. Güneş lekesi sayısı (GLS), 1848'de İsviçreli astronom Rudolf Wolf tarafından tanıtıldı ve 1700'e kadar güneş lekelerinin sayısındaki 11 yıllık çevrimin belirgin varlığını yeniden yapılandırıldı (Lang, 2001).

Güneş lekeleri, Güneş'in içyapısındaki yoğun manyetik alanlar sonucu oluşmakta ve Güneş yüzeyinde görünmektedir. Bu, birkaç günden birkaç aya kadar yaşayan geçici yapılardır. Güneş lekelerinin iki kısmı vardır: Birincisi, manyetik alanın Güneş yüzeyine

dikey olduğu merkezdeki en karanlık kısım olan gölge *(umbra)*; ikincisi, manyetik alanın daha eğimli olduğu gölgeden daha hafif olan yarı gölgedir *(penumbra)*.

GLS, genellikle Uluslararası Güneş Lekesi Numarası (ISSN) olarak adlandırılır ve Conway ve diğ., (1998)'e göre aşağıdaki denklemle tanımlanır:

$$R = k\,(10\,g + f) \qquad (2.2)$$

Burada $\boldsymbol{f}$ tekil lekelerin sayısıdır, $\boldsymbol{g}$, lekelerin oluşturduğu grup sayısıdır ve $\boldsymbol{k}$, gözlem koşullarına bağlı olarak bir standardizasyon faktörüdür. Leke sayısı ortalama 11 yıllık bir süreye göre değişmektedir. Bir çevrimden diğerine, GLS genliğinde de değişimler gözlemlenmektedir.

Güneş lekelerinin modern anlayışı, güneş lekesi çevriminin Güneş'in manyetik yapısı ile yakından ilişkili olmasıdır. 1908'de Amerikalı gökbilimci G. E. Hale, Güneşin çift kutuplu manyetik alanının her 11 yılda bir tersine döndüğü 22 yıllık bir güneş manyetik döngüsü önerdi. Bu nedenle, modelleme amacıyla en az 22 yıllık veri gereklidir.

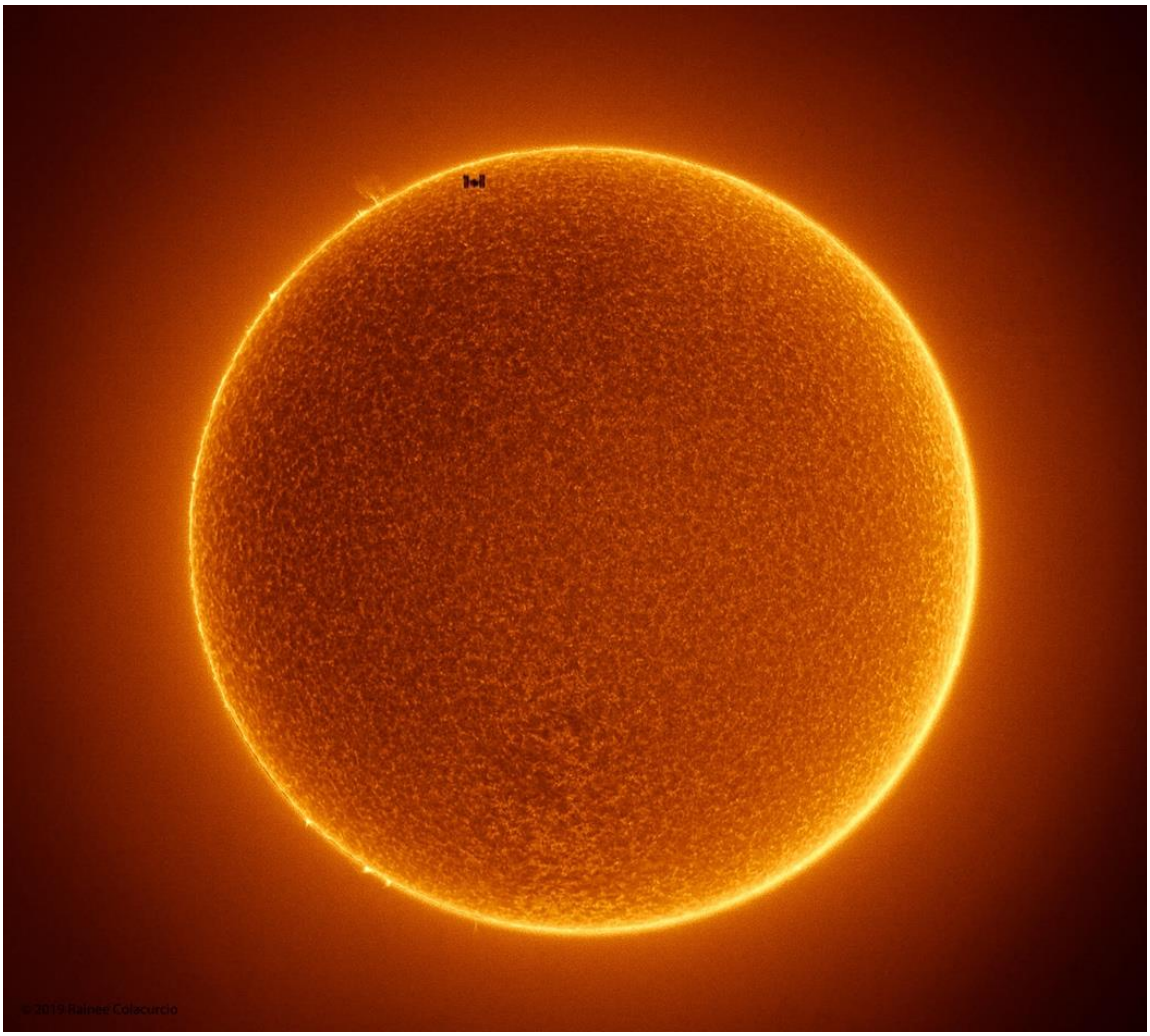
2.3.2. Güneş Parlamaları

Güneş parlaması, güneş yüzeyinde kısa zaman aralığında görülen, güneş lekelerinin yakınında serbest manyetik enerjinin aniden salınmasından kaynaklanan yapılardır. Radyasyon, uzun radyo dalgaboyundan optik emisyona, X-ışınlarına ve kısa dalgaboyundaki gama ışınlarına kadar neredeyse tüm elektromanyetik spektrumda yayılır. Bir parlama sırasında açığa çıkan enerji tipik olarak saniyede 10^{20} J mertebesindedir. Büyük parlamalar 10^{25} J'e kadar enerji yayabilir (Fletcher ve diğ., 2012). Fotosfer, kromosfer ve korona, Dünya atmosferinin yakın çevresini etkilerler. Güneş parlamaları iki farklı şekilde sınıflandırılır: birincisi Hα ve ikincisi 1 ila 8 Å pik akısına (W/m^2) göre A, B, C, M veya X şeklinde oluşturulmuş X-ışını sınıflandırmasıdır. İlk güneş parlaması, 1859 yılında Carrington ve Hodgson tarafından görünür bölge dalgaboylarında gözlendi. Bu parlama en büyük jeomanyetik fırtınaya (B = 1760 nT) neden oldu ve telgraf sistemine zarar verdi (Loomis, 1861; Tsurutani ve diğ., 2003).

Lee ve diğ., (2012) bu kategorilerdeki parlama oluşum oranı ve olasılığının güneş lekesi grup alanı ile arttığını bulmuşlardır. Koronal kütle atımları, uzay havası ve Dünya ortamı

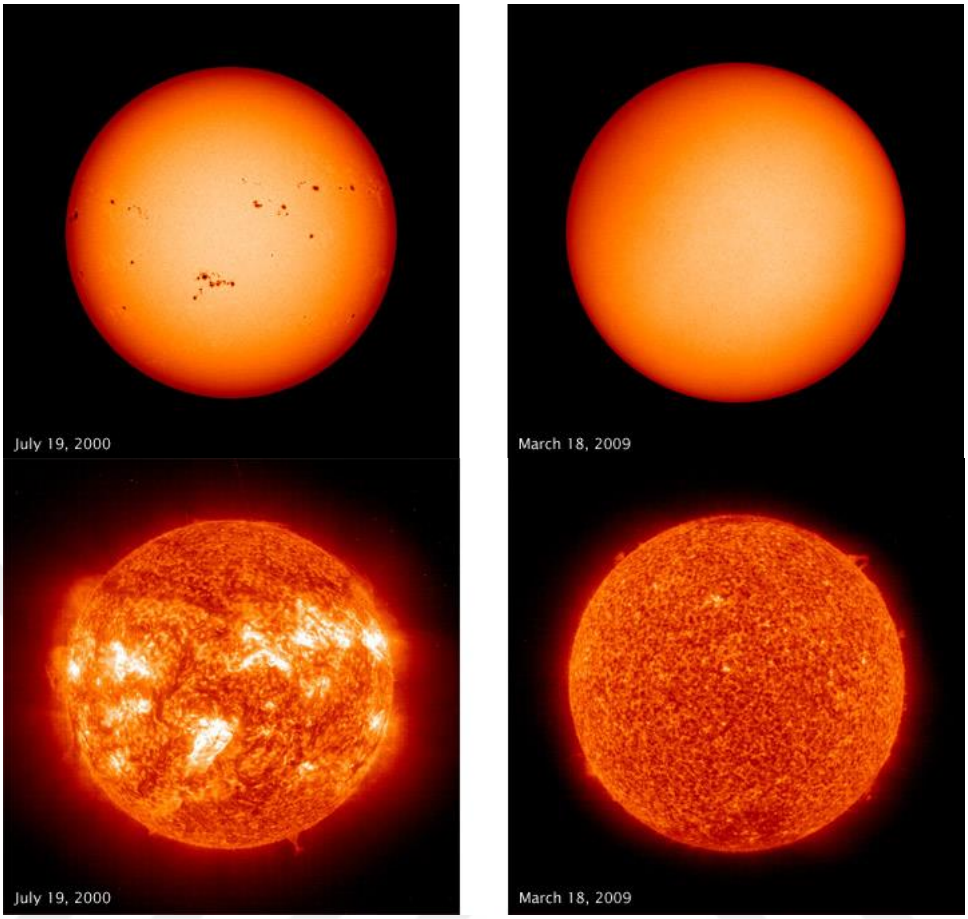
için en önemli etkenlerdir. Buna ek olarak, güneş parlamaları, Güneş kaynaklı yüksek enerjili parçacıklar (SEP), jeomanyetik fırtınaları oluşturur.

Parlama Oluşma Sıklığı (POS), Güneş atmosferinde kısa süreli oluşan parlamaların anlık verilerinden aylık bir ortalama olarak hesaplanan değeridir. Güneş parlamaları, Güneş Çevrimi süresince oluşma sıklığının değişimi düzensizdir. Bu yüzden daha genel bir takip için aylık oluşum ortalaması alınması gerekmektedir. Oluşturulan bu parametre ile daha düzenli gerçekleşen diğer Güneş Aktivitesi parametreleriyle beraber değerlendirilebilir ve hatta Güneş Çevrimi tahminlerinde kullanılabilir.



Şekil 2.2: Tamamen sakin Güneş'in birleştirilmiş fotosfer ve kromosfer görüntüsündeki hali.

https://apod.nasa.gov/apod/image/1907/SpotlessSunIss_Colacurcio_2048.jpg



Şekil 2.3: Güneş lekelerinin Güneş Çevriminin maksimum ve minimum evresinde görünür bölgedeki görüntüsü (üstte). Güneş parlamalarının Güneş Çevriminin maksimum ve minimum evresinde morötesi bölgedeki görüntüsü (altta).

https://earthobservatory.nasa.gov/images/37575/sunspots-at-solar-maximum-and-minimum?src=ve

2.3.3. 10.7 cm Dalgaboyunda Güneş Radyo Akısı

Güneş aktivitesinin bir başka göstergesi, 10,7 cm (2,8 GHz) dalgaboyunda Güneş'ten gelen radyo akısıdır. Bu akı 1947'den beri günlük olarak ölçülmektedir. 10,7 cm güneş akısı ($F_{10.7}$), güneş lekesi sayısı ile yüksek oranda ilişkilidir. Bununla birlikte endeks, 1947'den beri sadece 6 güneş çevrimini kapsamaktadır. 10.7 cm Radyo Akısı, Kanada'da Ottawa yakınlarındaki Algonquin Radyo Gözlemevi tarafından rutin olarak kaydedilmiştir. 1991'de program, British Columbia, Penticton yakınlarındaki Dominion Radyo Astrofizik

Gözlemevi'ne transfer edilmiştir. Akı, $10^{-22}Js^{-1}m^{-2}Hz^{-1}$ birimlerinde veya güneş akı biriminde (sfu: *solar flux unit*) ölçülür.

$F_{10.7}$ tahminindeki çoğu çalışma, yalnızca orta ve uzun vadeli tahminde genellikle nispeten istikrarlı bir etkiye sahip olan doğrusal modeller oluşturmaya odaklanmıştır. Yukarıdaki yöntemlerin önemli bir dezavantajı, yüksek kaliteli kısa ve orta vadeli tahmin yeteneklerinin olmamasıdır (Luo ve diğ., 2022).

2.3.4. Toplam Güneş Işınımı

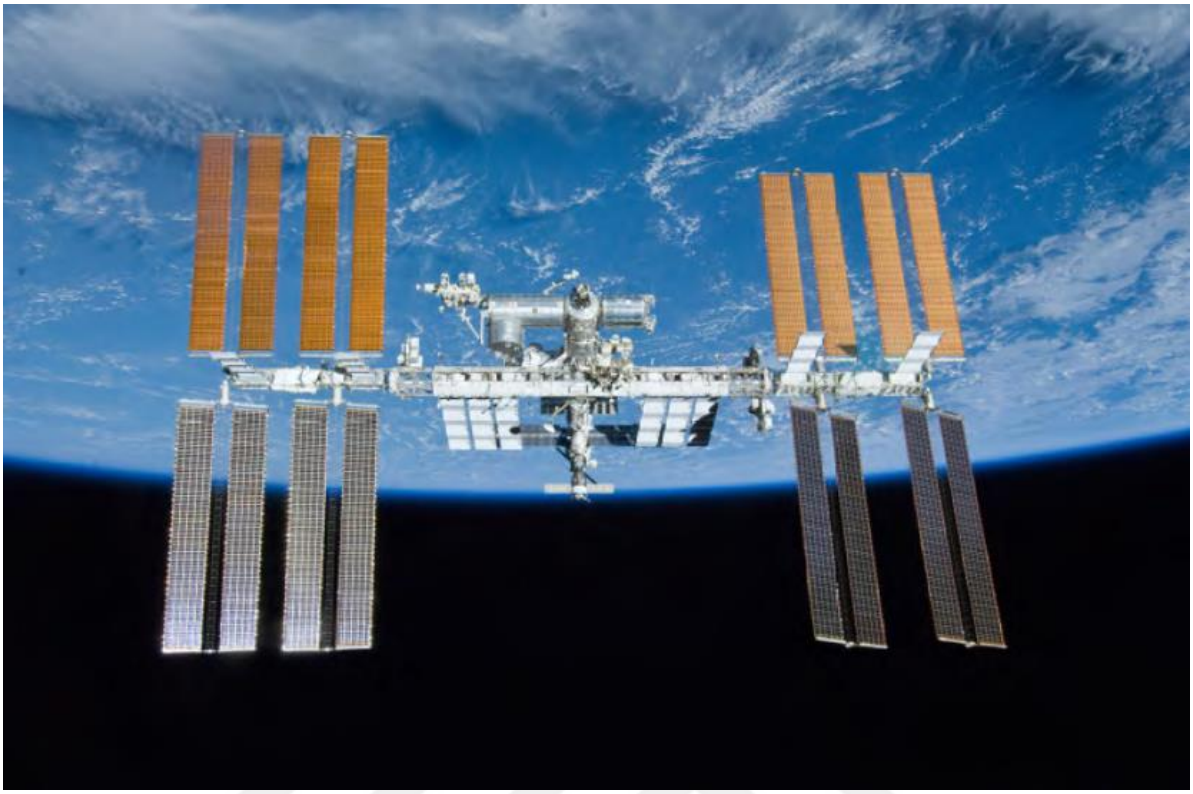
Güneş'in küresel iklimi etkileyeceği en önemli parametrelerden birisi, Toplam Güneş Işınımındaki (TGI, Güneş Sabiti) değişikliğidir (Owens ve diğ., 2017). TGI, Dünya atmosferi üzerinden ölçülen ve Güneş'ten gelen enerjinin metrekare başına düşen değeridir.

1230'dan 1890'a kadar 660 yıllık dört soğuk dönemli Küçük Buz Devri'nin TGI değişimlerinden etkilendiğine dair %98 olasılıkla kanıtlar mevcuttur (Schmutz, 2021). Güneş ışınımı, Dünya'nın iklimini etkiler. Çünkü bu parametre Dünya'nın atmosferinden ölçülen değer olduğundan, değişiminin Dünya iklimi ile ilişkisini incelemek diğer Güneş Aktivitesi parametrelerine göre daha kolaydır.

2.4.UZAY HAVASI

Koronal delikler, güneş parlamaları ve Koronal Kütle Atımları (KKA) gibi Güneş tarafından üretilen bu üç aktivite uzay havasının büyük bir kısmını oluşturmaktadır. Koronal delikler, Güneş diskinin X-ışınlarında gözlendiğinde korona katmanında karanlık görünen, tek kutuplu manyetik alan hücrelerinin olduğu bölgelerde oluşan yapılardır. Güneş rüzgârı, Dünya'ya ulaştığında, Dünya'nın manyetosferinin büzülmesine ve ardından Güneş rüzgârı geçtikten sonra genişlemesine neden olur. Bu değişiklikler, Dünya'nın manyetik alanında (genellikle hafif) elektromanyetik düzensizliklere neden olmaktadır.

Güneş parlamaları tarafından üretilen yüksek enerjili parçacıkların oluşturduğu enerji akımları, Dünya'ya doğru yoğun bir şekilde gelerek Dünya'nın üst atmosferindeki atomları iyonize eder. Burada serbest kalan elektronlar bir uzay aracındaki elektronik aksamlara zarar verebilir.



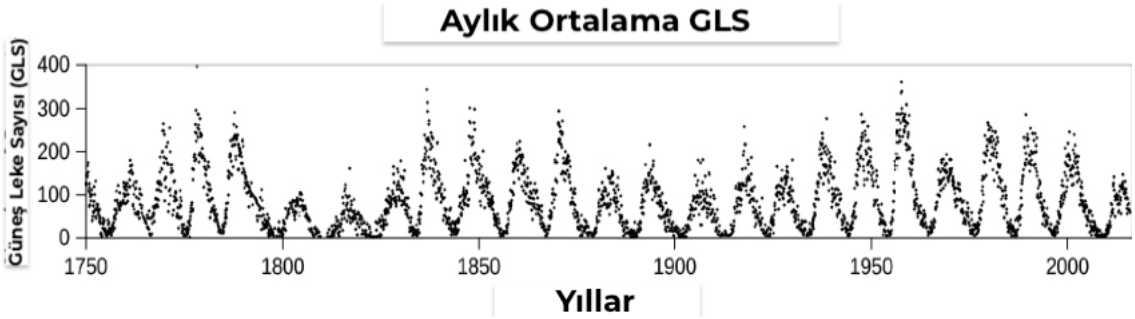
Şekil 2.4: Güneş rüzgârlarından etkilenebilecek en önemli uydulardan biri: Uluslararası Uzay İstasyonu, 2010 yılında Uzay Mekiği Atlantis'in çıkış yapan ekibi tarafından fotoğraflandığı gibi, Dünya'nın yörüngesinde görülüyor. (Fotoğraf Kaynağı: NASA)

Bir KKA Dünya'ya ulaştığında, Dünya'nın manyetik alanını bozar. Değişen bir manyetik alan elektrik akımını indüklediğinden, KKA elektronları bazen çok yüksek hızlara kadar yükseltilebilir. Bu "öldürücü elektronlar" uyduların derinliklerine nüfuz edebilir, bazen elektronik aksamlarını tahrip edebilir ve çalışmayı kalıcı olarak devre dışı bırakabilir. Bu durumun geçmişte bazı iletişim uydularında oluştuğu görülmüştür.

Dünyanın manyetik alanındaki bozulmalar, iletişimde, özellikle cep telefonu ve kablosuz sistemlerde kesintilere neden olabilir. Aslında, kesintilerin Güneş maksimumu sırasında yılda birkaç kez meydana gelmesi beklenebilir. KKA'ları nedeniyle Dünya'nın manyetik alanındaki değişiklikler, transformatörleri yakacak kadar büyük güç hatlarında dalgalanmalara ve büyük elektrik kesintilerine neden olabilir. KKA'larından kaynaklanan elektrik kesintilerinin Kuzey Amerika'da meydana gelme olasılığı Avrupa'dan daha fazladır; çünkü Kuzey Amerika, KKA'ları tarafından indüklenen akımların en güçlü olduğu Dünya'nın manyetik kutbuna daha yakındır (Franknoi, 2017).

Temel strateji, küçük, aktif bölgelerin görünümündeki değişiklikleri ve Güneş'teki yerel manyetik alanlardaki değişiklikleri, sonraki patlamalarla ilişkilendirerek gelecekteki olası durumlara karşı önlem alma yöntemleri geliştirmektir. Bununla birlikte, şu anda tahmin yeteneğimiz hala zayıf ve bu nedenle sahip olduğumuz tek gerçek çözüm, KKA ve parlamaları gözlemektir. Bir KKA, saniyede yaklaşık 500 km hızla dışarı doğru hareket ettiğinden, patlama etkileri, Dünya'nın uzaklığında bir mesafeye birkaç günlük sürede ulaşır. Bununla birlikte, Dünya üzerindeki etkinin şiddeti, KKA ile ilişkili manyetik alanın Dünya'nın manyetik alanına göre nasıl yönlendirildiğine bağlıdır. Yönlendirme ancak KKA bu amaç için kurduğumuz bir uydunun yanından geçtiğinde ölçülebilir. Güneş'in iç ve dış kısmında oluşan aktivitelerin nasıl oluştuklarını, bilimsel olarak açıklama mekanizmalarını kullanarak, teorik tahmin yöntemleri geliştirmek ve bu tahmin yöntemlerini gelecekte alınacak teknolojik önlemlerde kullanarak anlaşılabilir (Franknoi, 2017).

Güneş her gün tam olarak hesaplanabilen bir zamanda belirli bir noktadan doğup yükselirken, bilim insanları Güneş'in enerji çıkışının gerçekten sabit olmadığını, yüzyıllar boyunca muhtemelen % 1'den daha az küçük bir miktarda değiştiğini belirlediler. Güneş lekelerinin sayısının, yaklaşık 11 yıllık güneş lekesi maksimumları arasındaki zamanla değiştiğini ve maksimum güneş lekesi sayısı her çevrim için aynı olmamaktadır. Önemli kanıtlar, 1645 ve 1715 yılları arasında, güneş lekesi maksimumda olsa bile, güneş lekesi sayısının şimdi olduğundan çok daha düşük olduğunu göstermektedir. Bu önemli ölçüde düşük güneş lekesi sayısı aralığı ilk olarak 1887'de Gustav Spörer ve daha sonra 1890'da E. W. Maunder tarafından kaydedildi; şimdi Maunder Minimumu olarak adlandırılmaktadır. Son üç yüz yıldaki güneş lekesi sayısındaki değişim Şekil 2.6'da gösterilmektedir. On yedinci yüzyılda Maunder Minimum'un yanı sıra, on dokuzuncu yüzyılın ilk bölümünde güneş lekesi sayıları şimdi olduğundan biraz daha düşüktü; bu döneme Küçük Maunder Minimumu denir.



Şekil 2.5: 1750 – 2019 yılları aralığında yaklaşık 11 yıllık Güneş Leke Çevrimleri. Bu diyagram, leke sayısı tutarlı bir ölçekte kaydedilmeye başladığından beri Güneş lekesi sayısının zamanla nasıl değiştiğini göstermektedir. (Fotoğraf Kaynağı: NASA/ARC)

Güneş lekelerinin sayısı yüksek olduğunda, Güneş aktivitelerinin de yüksek olması Dünya'yı doğrudan etkilemektedir. Örneğin Güneş lekesi sayısı yüksek olduğunda daha fazla kutup ışıması (Aurora) görüntüsü ortaya çıkmaktadır. Kutup Işımaları, Güneş'ten gelen enerji yüklü parçacıkların Dünya'nın manyetosferi ile etkileşime girmesiyle ortaya çıkar ve Güneş aktifken ve güneş lekesi sayısı yüksek olduğunda, Güneş'in parçacıkları yayma olasılığı daha yüksektir. Tarihsel hesaplar ayrıca, Maunder Minimum'un birkaç on yılı boyunca kutup ışıması aktivitesinin anormal derecede düşük olduğunu göstermektedir. Uydu verileri, bir güneş çevrimi sırasında Güneş'ten gelen enerji çıkışının yalnızca yaklaşık % 0,1 oranında değiştiğini göstermektedir. Bu kadar küçük bir değişimin küresel sıcaklık değişikliklerinin nedenini açıklayacak hiçbir fiziksel süreç bilinmemektedir. Bununla birlikte, Güneş Aktivitesinin başka etkileri olabilir. Örneğin, Güneş'in toplam enerji çıkışı bir güneş çevrimi sırasında yalnızca % 0,1 oranında değişse de, aşırı morötesi ışınımı, güneş çevriminin maksimum zamanlarında minimum güneş minimumdan 10 kat daha fazladır. Bu büyük değişiklik, üst atmosferin kimyasını ve sıcaklık yapısını etkileyebilir. Bu etkilerden biri, ozon tabakasında bir azalma ve Dünya'nın kutuplarına yakın stratosferin soğuması şeklinde olabilir. Bu da havadaki rüzgârların sirkülasyon modellerini ve dolayısıyla fırtınaların yönlerini değiştirebilir. Bölgesel yağıştaki değişikliklerin, Güneş aktivitesi ile Dünya'nın küresel sıcaklığından daha iyi ilişkili olduğuna dair yakın tarihli bazı kanıtlar vardır (Franknoi ve diğ., 2017). Ancak, görüldüğü gibi, Güneş'te olanlarla kısa vadede Dünya'nın iklimine ne olduğu arasındaki ilişki, bilim insanlarının halâ araştırdığı ve tartıştığı bir alan olmaktadır.

Bununla birlikte Dünya'nın manyetik alanının Güneş'ten ne kadar etkilendiğini gösteren parametrelerden bir tanesi olan Ap yermanyetik indeksi, bir yermanyetik fırtına olayı sırasında ardışık 3 saatlik ap indekslerinin günlük (8 değer) ortalamasının hesaplanmasıyla elde edilen değer olarak tanımlanmaktadır. Bu indeks 44 ile 60 derece kuzey veya güney enlemlerindeki 13 ayrı gözlemevinden elde edilmektedir. Ap'nin takibi ile Güneş'in Dünya'nın manyetik alanına ne kadar etki edeceğini başka bir deyişle Güneş Aktivitesinin şiddetinin değişiminin Dünya'ya nasıl yansıyacağını tahmin etmek amaçlanır.

3. MALZEME VE YÖNTEM

3.1.MALZEME

Tez çalışmasında, son 4 Güneş Çevrimine (21. – 24.) ait toplam 44 yıllık aylık GLS verileri 532 adet olmak üzere Sunspot Index and Long-Term Solar Observations (SILSO)'dan, Güneş X-ışını Parlama verileri 532 adet olmak üzere National Oceanic and Atmospheric Administration (NOAA) – National Geophysical Data Center (NGDC)'den, $F_{10.7}$ verileri 532 adet olmak üzere Geo Forschungs Zentrum (GFZ-Postdam)'dan, TSI verileri 532 adet olmak üzere LASP Solar Irradiance Data Center (LISIRD)'den ve Ap verileri 532 adet olmak üzere GFZ-Postdam'dan elde edilmiştir. Elde edilen her veri satırında tarih, sıklık / şiddet sütunları halindedir. Bu verilerin çoğu aylık ortalamalar şeklinde gelse de bir kısmı tezde aylık ortalamalara çevrilmiştir. Aylık ortalamamız, o aya ait ilgili parametrenin tüm verilerinin o ayın sahip olduğu gün sayısına bölünmesi ile hesaplanır. Aylık ortalamaya çevrilmesinin nedeni verilerin beraber tahmin edilmesinde bütünlüğün sağlanmasıdır.

Bu malzemelerin istatistik değerlendirilmesinde İlişki Katsayısı (r), Ortalama Karekök Hata (RMSE) ve Normalize Nash-Sutcliffe Etkinlik Katsayısı (NNSE) kullanılmıştır. Bu verilerin giriş verisi olarak kullanılmasıyla "Yapay Sinir Ağları", "İleri Beslemeli Sinir Ağları", tez çalışmasında kullanılan NARX yöntemi ve sinir ağların eğitilmesini sağlayan MATLAB yazılımı malzemelerimiz içerisinde yer almaktadır.

Pearson ilişki katsayısı (r), tahmin verileri ve ölçülen veriler arasındaki bağlantı derecesini tanımlar. -1 ile 1 arasında değişen ilişki katsayısı, gözlemlenen ve tahmin edilen veriler arasındaki doğrusal ilişkinin derecesinin bir indeksidir. $r = 0$ ise, doğrusal bir ilişki yoktur. $r = 1$ veya -1 ise, mükemmel bir pozitif veya negatif doğrusal ilişki vardır (Moriasi ve diğ., 2007).

Ortalama Karekök Hatası (RMSE), tüm hatanın karesinin ortalamasının kareköküdür. RMSE kullanımı çok yaygındır ve sayısal tahminler için mükemmel bir genel amaçlı hata ölçütü olarak kabul edilir.

Burada gözlemler O_i, bir değişkenin tahmin edilen değerleri S_i ve n analiz için mevcut gözlem sayısıdır. RMSE iyi bir doğruluk ölçüsüdür, ancak ölçeğe bağlı olduğu için değişkenler arasında değil, yalnızca belirli bir değişken için farklı modellerin veya model konfigürasyonlarının tahmin hatalarını karşılaştırmak içindir.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(S_i - O_i)^2} \qquad (3.1)$$

Nash-Sutcliffe verimliliği (NSE), ölçülen veri değişimine kıyasla gürültü değerlerinin göreli büyüklüğünü belirleyen normalleştirilmiş bir istatistiktir (Nash ve Sutcliffe, 1970). Burada Y_i^{obs}, değerlendirilmekte olan bileşen için *i* gözlemdir, Y_i^{sim}, değerlendirilmekte olan bileşen için tahmin edilmiş değerdir, Y^{mean}, değerlendirilmekte olan bileşen için gözlemlenen verilerin ortalamasıdır ve *n*, toplam gözlem sayısıdır. NSE, $-\infty$ ile 1.0 (1 dâhil) arasında değişir ve NSE = 1 en uyum sağlayan değerdir. 0.0 ile 1.0 arasındaki değerler genellikle kabul edilebilir performans seviyeleri olarak görülürken, < 0.0 değerleri, ortalama gözlemlenen değerin, tahmin değerleriyle uyumlu olmadığını, bu da kabul edilemez performansı gösterir.

$$NSE = 1 - \left[\frac{\sum_{i=1}^{n}(Y_i{}^{obs} - Y_i{}^{sim})^2}{\sum_{i=1}^{n}(Y_i{}^{obs} - Y^{mean})^2}\right] \qquad (3.2)$$

$$Normalize\ NSE = \frac{1}{2-NSE} \qquad (3.3)$$

3.2.YÖNTEM

3.2.1. Yapay Sinir Ağları

Yapay Sinir Ağı (YSA), nöronlar veya birimler adı verilen çok sayıda basit işlem öğesinden oluşan bir bilgi işleme sistemidir. YSA'ları bir dereceye kadar nöronlar arasındaki bağlantı modeli, bağlantılardaki eğitim veya öğrenme algoritması ve aktivasyon fonksiyonu gibi özelliklerle biyolojik sinir ağlarının yapısına ve işleyişine benzemektedir (Fausset, 1994).

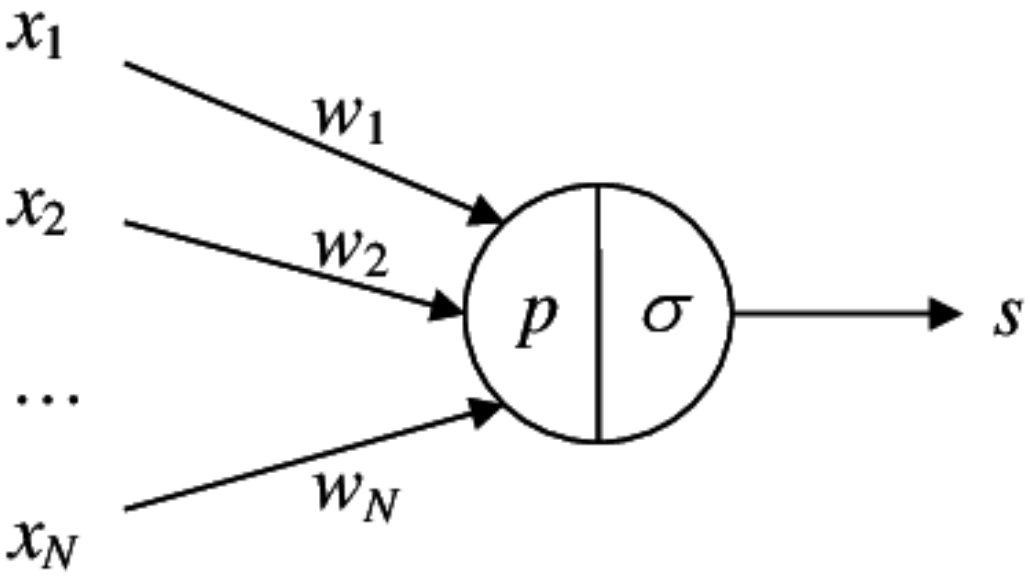
Tahminler için kullanılan sinir ağı modellerinde, üç tip nöron tanımlanmaktadır:

1- Zaman serileri içindeki değerleri temsil edecek şekilde ayarlanmış giriş verisi nöronlar,
2- Verilen girdi değerleri kümesine karşılık gelen çıktı değerlerini depolayan ve sinir ağının işlemlerinin sonuçlarını veren çıktı verisi nöronlar,
3- Problemi çözmede temsilen gizli tutulan nöronlar.

Nöronlar, ağın bilgisini koruyan ve her bir giriş verisinin her bir çıktı verisi üzerindeki etkisini yöneten ağırlıklarla birbirine bağlanır. Ağırlıklar, ağ hesaplamalarının bilinen durumlar için girdi-çıktı verileriyle karşılaştırılmasını içeren bir öğrenme süreciyle ayarlanır. Ağırlık ayarlama süreci ağ eğitimi olarak bilinmektedir. Eğitim sırasında, ağın girdileri istenen

çıktılarla doğru şekilde ilişkilendirilmesi için ağırlık değerleri belirlenir. Bu nedenle ağ, deneyimlerden sonuçları tahmin etmeyi öğrenir (Macpherson ve diğ., 1995).

YSA'nın ilk kez modellenmesi McCulloch ve Pitts (1943) tarafından geliştirilmiştir. Biyolojik sinir ağındaki gibi her bilgi değil, belirli bir eşik değerin üzerinde değere sahip veriler yapay sinir hücreleri arasında aktarılmaktadır. Birçok amaçta kullanılan yapay sinir ağı modeli de McCulloch ve Pitts (1943) modelini temel almıştır (Eğrioğlu ve diğ., 2020).



Şekil 3.1: Basit sinir ağı modeli, McCulloch ve Pitts (1943); (Courgeau ve diğ., 2016).

McCulloch – Pitts modelinde beş temel işlem ele alınmıştır (Şekil 3.1.): Girdileri tanımlama $x_1, x_2, \ldots x_N$, hücresel katsayılar $w_1, w_2, \ldots w_N$ ile ağırlıklandırma, alınan ağırlıklı uyaranların toplamının hesaplanması (p), altında iletimin gerçekleşmediği bir uyarım eşiğinin (σ) sabitlenmesi ve son olarak çıkış sinyalinin (s) hesaplanmasıdır. Bu işlevler belirli bir sırada düzenlenmiştir: Örneğin; girdilerin ağırlıklandırılması, ağırlıklı toplamın hesaplanmasından önce gelmelidir. Böylece, daha kesin olarak, McCulloch - Pitts modeli, nöronun gözlemlenen sonuçlarını üreten sürecin fonksiyonel yapısını temsil eder (Courgeau ve diğ., 2016).

YSA'larını öğretmek kullanım amacına göre (tahmin, kümeleme ve sınıflama) farklılık gösterir. Tahmin amaçlı kullanıldıklarında, önceden belirli olan girdi verilerine karşılık gelen

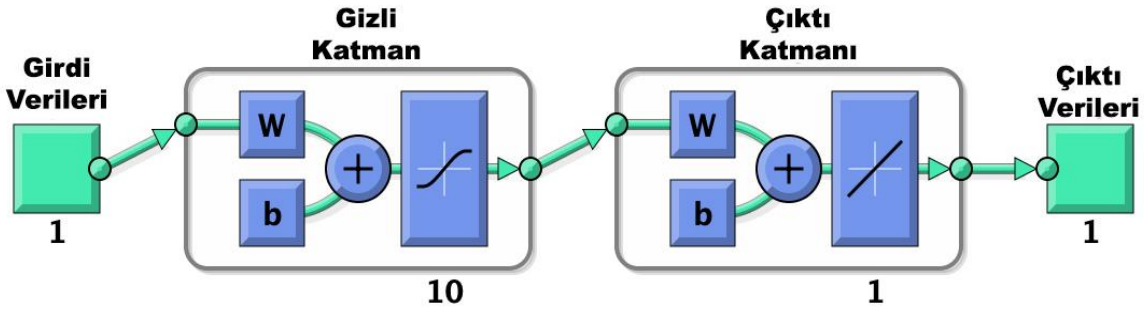
belirli çıktıları üretmesi ve bu işlemin tamamlandığı durumda öğrenme sürecinin gerçekleştiği anlamına gelmektedir (Eğrioğlu ve diğ., 2020).

3.2.2. İleri Beslemeli Sinir Ağları

İleri Beslemeli Sinir Ağı (FFNN), en basit ve en popüler yapay sinir ağı tipi olarak belirlenmiştir ve bu teknik çeşitli Uzay Meteorolojisi (*Space Weather*) tahminlerinde yaygın bir şekilde başarıyla kullanılmıştır (Conway ve diğ., 1998). Bir FFNN modelinde veri katmanları arasındaki nöronların işleyişi hep ileri yönde sağlanır. Bu tür sinir ağı modeli; girdi katmanı, gizli katman(lar) ve bir çıktı katmanından oluşur. Zaman serisinin önceki değerlerine ayarlanan giriş birimleri, sinyalleri gizli birimlere gönderir. Bu gizli birimler alınan bilgileri işler ve sonuçları giriş sinyallerini, son yanıtı üreten çıkış birimlerine iletir (Uwamahoro, 2008).

Genellikle zaman serileri iki veri setine ayrılır: biri eğitim seti ve diğeri bir test setidir. Eğitim seti, eğitim sırasında ağırlıkları ayarlamak için kullanılırken, test seti ağın tahmin performansını doğrulamak için kullanılır. Ağ, gelecekteki verilerde daha iyi performans göstermesi için sinir ağının asgari genelleme hatasına sahip olması amacıyla geçmiş veriler kullanılarak eğitilmektedir. Eğitimden önce, eğitim sonuçlarının verilerin sadece belirli bir bölümüne şartlı olarak işlem yapılmasını önlemek için hem eğitim hem de test veri setleri rastgele bölünüp, sinir ağlarının girdi-çıktı modellerindeki davranışı nasıl öğrendiğini belirlemek için, doğrulama kümesi olarak tanımlanan bir veri kümesi (ağ eğitim sürecine dâhil olmayan) kullanılır.

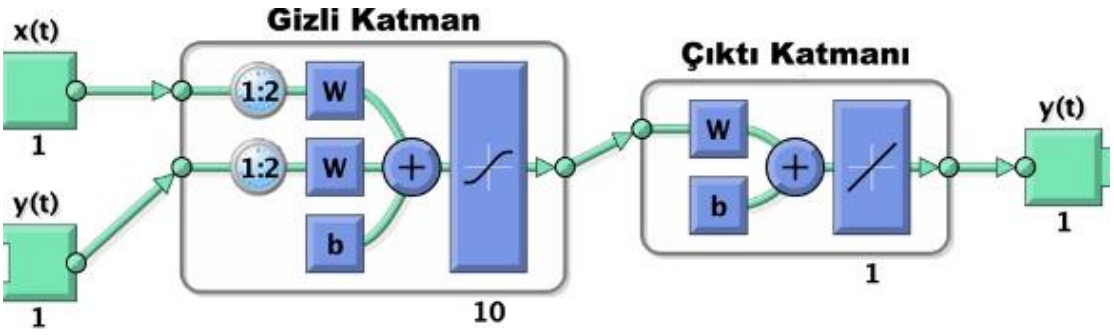
Eğitim, ağ genelleme yeteneğini kazanana kadar bir dizi yinelemeyle (iterasyon) tekrarlanır. Eğitim sürecinin hızı, öğrenme oranı olarak bilinen parametre tarafından kontrol edilir (0 ile 1 arasında bir değer). Aşırı eğitim, sinir ağının genel olarak sistem dinamiklerini temsil etmeyi öğrenmek yerine eğitim setindeki gürültüyü öğrendiği zamanda sinir ağının aşırı uyumuna neden olabilir. Bu eğitim, set hatası azalmaya başlarken test setindeki hata artmaya başladığında meydana gelir. Bu noktaya ulaşmadan hemen önce, ağın genelleme yeteneği en uygun düzeyine ulaştığında eğitim durdurulur (Macpherson ve diğ., 1995).



Şekil 3.2: Temel FFNN Model Diyagramı; Girdi verileri: Sinir ağlarının eğitilmesinde kullanılacak verilerin giriş katmanı, Gizli Katman(lar): Sinir ağlarının eğitildiği katman (Burada gösterilen ağırlıklar (*w*): Bir sinir hücresine gelen bilginin önemini ve sinir hücresinin üzerindeki etkisini gösteren faktördür (Öztemel, 2006), eşik değeri (*b*): Bir sinir ağında hiçbir girdi gerektirmeyip, net bir sonucun elde edilmesini sağlayan bir ek ağırlık kümesidir (Tezbaşaran ve Gelbal, 2018), Dikdörtgen içerisinde bir grafik şeklinde gösterilmiş bölüm olan Aktivasyon Fonksiyonu: Bir sinir hücresine gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur (Öztemel, 2006), Çıktı Katmanı: Bir sinir ağına gelen bir problemin gizli katman(lar) içerisinde işlenip bu problemin çözümünün çıktılarını düzenleyen katmandır, Çıktı Verileri: Sinir ağlarında işlenmiş verilerin bulunduğu kümedir.

3.2.3. Doğrusal Olmayan Otoregresif Dışsal Model (NARX)

Zaman serisi, gözlemlerle ilgili değişkenler için kullanılabilir ve geçmişten gelen veriler değişkenin gelecekteki gelişimi hakkında bilgiler içeriyorsa, geçmişte toplanan verilerin bazı işlevlerini tahminlerde kullanılabilir (Lütkepohl, 2005).



Şekil 3.3: NARX Sinir Ağı Model Örneği: *x(t)*; giriş verileri *y(t)* (soldaki); hedef verileri, 1:*x*; gecikme değeri, *w*; ağırlıklar, *b*; gürültü değerleri, aktivasyon fonksiyonu (matematiksel fonksiyon içeren mavi blok), 10; sinir ağı adedi, *y(t)* (sağdaki); çıkış (tahmin sonucu) verileridir (MATLAB).

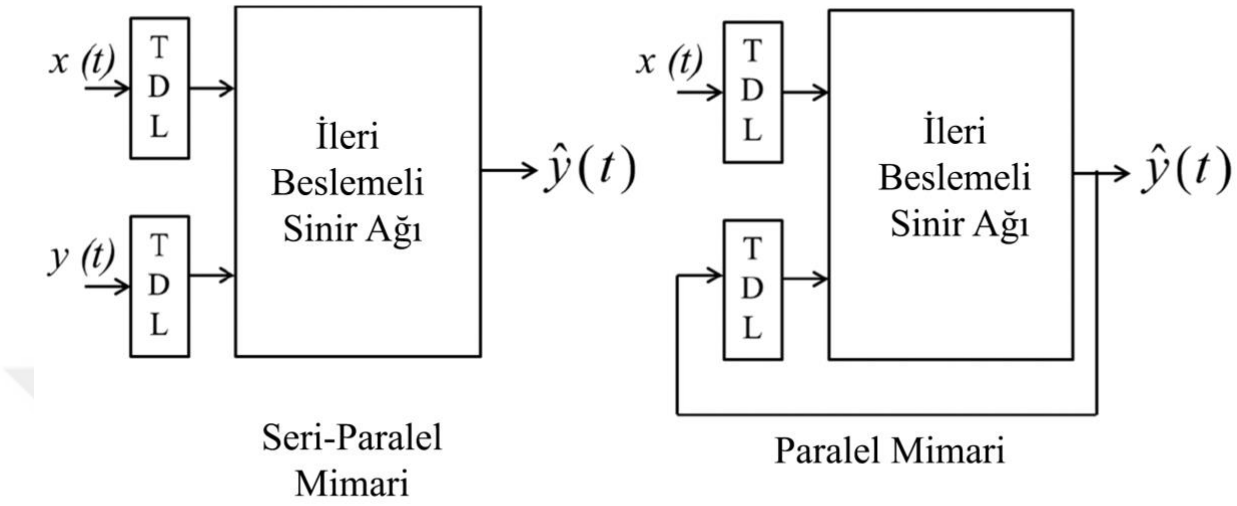
NARX modeli (Şekil 3.3), zamana bağlı doğrusal olmayan (bire bir tekrar etmeyen) sistemlerin tahmininde kullanılan dinamik bir sinir ağıdır (Boussada ve diğ., (2018).

NARX ağlarıyla yapılan tahminlerde, genellikle uzun süreli değişimleri keşfetmede geleneksel sinir ağlarından çok daha iyi olduğu ifade edilmektedir (Diaconescu, 2008). Kaotik zaman serileri ile başa çıkmak için önerilen mimari yaklaşım, bu nedenle NARX tekrarlayan sinir ağları olarak adlandırılan "Doğrusal Olmayan Otoregresif Dışsal Modeller" üzerine kuruludur (Haykin, 1999). Bu, doğrusal olmayan sistemleri ve özellikle zaman serilerini modellemek için çok uygun oldukları kanıtlanmış güçlü bir model sınıfıdır. NARX ağları hakkında bazı önemli nitelikler bildirilmiştir:

1- NARX ağlarında öğrenme, diğer sinir ağlarına göre daha etkilidir (gradyan inişi NARX'te daha iyidir)
2- Bu ağlar çok daha hızlı birleşir ve diğer ağlardan daha iyi genelleştirir (Lin ve diğ. 1996).

NARX modeli, sırasıyla Denklem (1) ve (2) ile verilen yapısına göre seri-paralel (açık-döngü) ve paralel (kapalı-döngü) olmak üzere iki mimari olarak ifade edilmektedir (Sekil 3.4). Seri-paralel yapı kullanılarak geliştirilen bir modelde, tahmin edilen çıktıyı geri beslemek yerine hedeflenen veri değerleri ($\widehat{y_t}$) kullanılır ve paralel mimari konfigürasyonunda iken eğitim test ve doğrulama periyodu için uygun hale gelir (Şekil 3.3), 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 3.4: NARX Sinir Ağının Mimarisi (Boussada ve diğ., 2018). (TDL; Tapped Delay Line -Gecikme Uygulanmış Hat).

NARX modeli şu sekilde formüle edilmistir (Boussada ve diğ., 2018):

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \ldots, y_{t-n_y}; x_{t+1}, x_t, x_{t-1}, \ldots, x_{t-n_x}) + \varepsilon_{t+1} \quad (3.3)$$

$$\hat{y}_{t+1} = f(\hat{y}_t, \hat{y}_{t-1}, \ldots, \hat{y}_{t-n_y}; x_{t+1}, x_t, x_{t-1}, \ldots, x_{t-n_x}) + \varepsilon_{t+1} \quad (3.4)$$

Denklem (3.3) ve (3.4)'de x_{t+1}, x_t, x_{t-1},..., x_{t-n_x}kısmı NARX giriş verilerini, y_{t+1}, y_t, y_{t-1},..., y_{t-n_x} kısmı tahmin edilecek döneme ait gerçek verilerini, $\hat{y}_t$, $\hat{y}_{t-1}$, ..., $\hat{y}_{t-n}$ kısmı Sekil 3.2.2'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, $n_x$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 ve diğ., 2019; Menezes ve Baretto, 2006; Menezes ve Baretto, 2008). Eğitim aşamasından sonra modelde, harici girdi verileri devreye sokularak sonraki dönemleri tahmin etmek için bir model oluşturulur. Çıkış verileri, FFNN'e 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 ve diğ., 2019; Guzman ve diğ., 2017).

Normalizasyon, aşağıdaki denklemle verileri 0 ile 1 aralığına ölçekler:

$$\widehat{x_t} = \frac{x_t - x_{min}}{x_{maks} - x_{min}} \qquad (3.5)$$

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

3.3.MATLAB

Güneş Aktivitesi parametrelerinin (GLS, POS, $F_{10.7}$ ve TGI) tahmin edilmesinde literatürde yapılan çalışmalar; Öncü yöntemler (*precursor*) ve ekstrapolasyon (*extrapolation*) yöntemlerdir (Petrovay, 2020). Ancak bunların içerisinde bizim kullandığımız NARX yöntemini birçok parametre beraber tahmin edilip karşılaştırılması duyarlı sonuçlar elde edilmesi diğer yöntemlere göre daha güvenilirdir. Bu yöntem kullanılarak literatürde yapılan çalışmalardan üç örnek şunlardır: Boussada ve diğ., 2018; Sansa ve Najiba, 2018; Di Piazza ve diğ., 2016). Ancak bu çalışmalardan farklı olarak tez çalışmasında GLS, POS, $F_{10.7}$ ve TGI parametrelerini de tahmin ederek literatürdeki çalışmalardan daha kapsamlı ve daha duyarlı tahmin sonuçları elde etmeye çalışıldı. Daha pratik arayüze sahip MATLAB ile NARX yöntemi uygulanmıştır. Başka araştırmacılara da yol gösterebilmesi açısından MATLAB NARX çalışma ekranları da aşağıda kısaca paylaşılmıştır.

MATLAB (*MATrix LABoratory*), bilimsel hesaplama için etkileşimli bir programlama ortamıdır. MATLAB, veri analizi, problem çözme, deney ve algoritma geliştirme için birçok teknik alanda yoğun olarak kullanılmaktadır. Araç kutuları adı verilen işlev kitaplıklarında düzenlenen, MATLAB'da yazılan disipline özgü yazılımlar da yaygın olarak kullanılmaktadır. MATLAB, teknik eğitimde hesaplamalı laboratuvar çalışmalarının temeli olarak geniş bir kullanım alanı bulmuştur; 1000'den fazla ders kitabı MATLAB'ı bir öğretim

aracı olarak kullanmaktadır. MATLAB, The Mathworks of Natick, Massachusetts, ABD'nin bir ürünüdür.

MATLAB'ın başarısının ana nedenlerinin, sezgisel, özlü sözdizimi, varsayılan sayısal veri nesnesi olarak karmaşık matrislerin kullanılması, yerleşik operatörlerin gücü, kolay kullanılan grafikleri olduğu konusunda genel bir fikir birliği vardır. Basit ve kullanıcı dostu programlama ortamı, dilin kolayca genişletilmesine izin verir. Buna, operatörlerin dayandığı sayısal yöntemlerin güvenilirliği de eklenebilir (Schreiber, 2007).

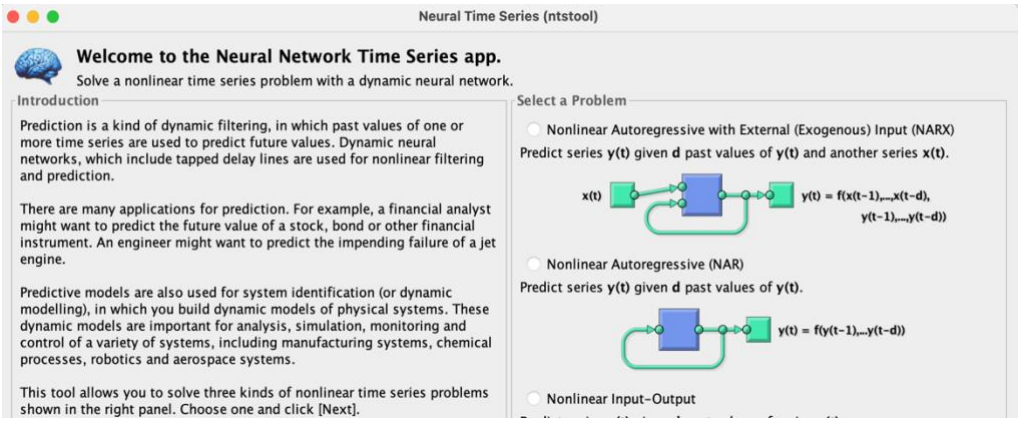
MATLAB yazılımında NARX sinir ağlarına;

1- Apps (Uygulamalar)
2- Neural Net Time Series (Sinir Ağı Zaman Serisi)
3- NARX

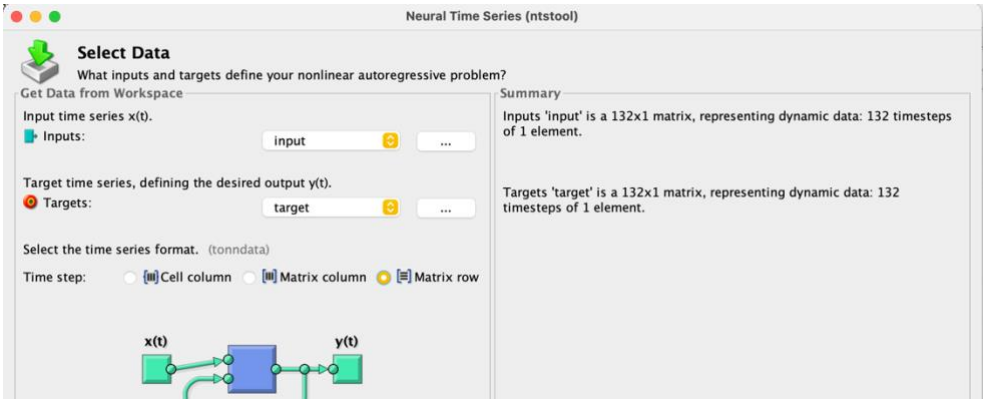
adımları ile ulaşılabilir. Sonrasında nöron sayısı ve gecikme katsayısı (ihtiyaç varsa) amaca göre belirlenir. Sonrasında ise "Advanced Script" bölümünden gerekli parametreler ayarlandığında tahmin işlemi gerçekleştirilir.



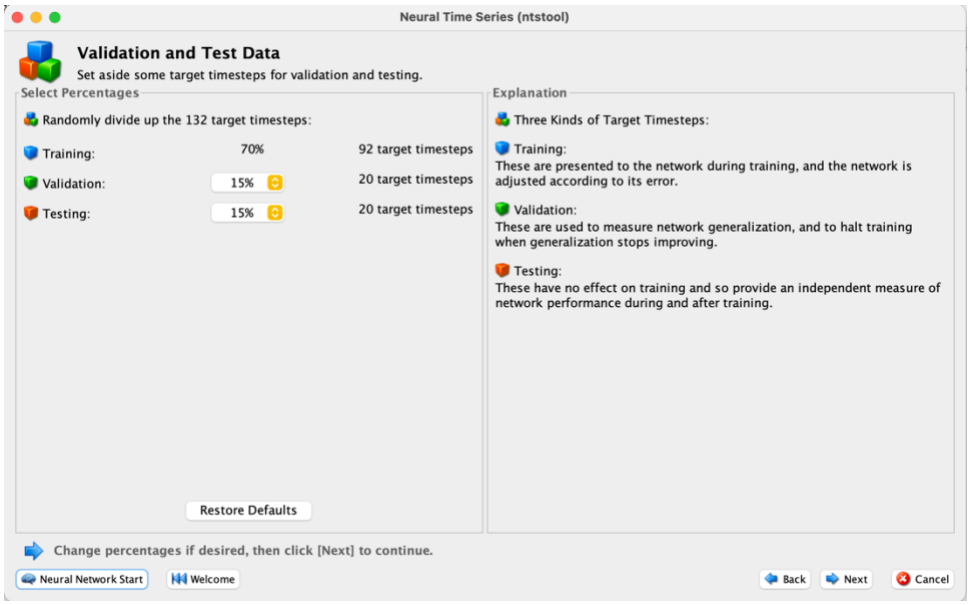
Şekil 3.5: MATLAB'ın içerisindeki "Çalışma Alanı" ekranında giriş ve hedef verilerinin programa tanımlanması. "Value" bölümü veri matrisinin boyutlarını gösterir. Burada 'double' matristeki sayıların çift kat duyarlılık (*double precision*) ile tanımlandığını ifade eder. Bu format MATLAB yazılımı için varsayılandır.



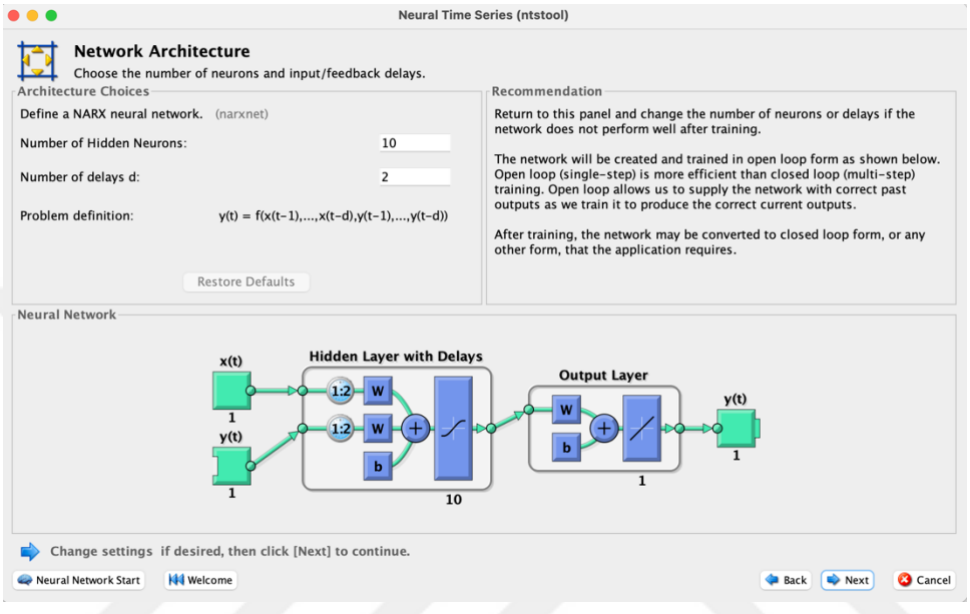
Şekil 3.6: MATLAB yazılımı içerisindeki "Uygulamalar (Apps)" bölümünden "Neural Net Time Series" ve sonrasında "Nonlinear Autoregressive with External (Exogenous) Input (NARX) seçilir. Böylece NARX sinir ağları çalıştırılır.



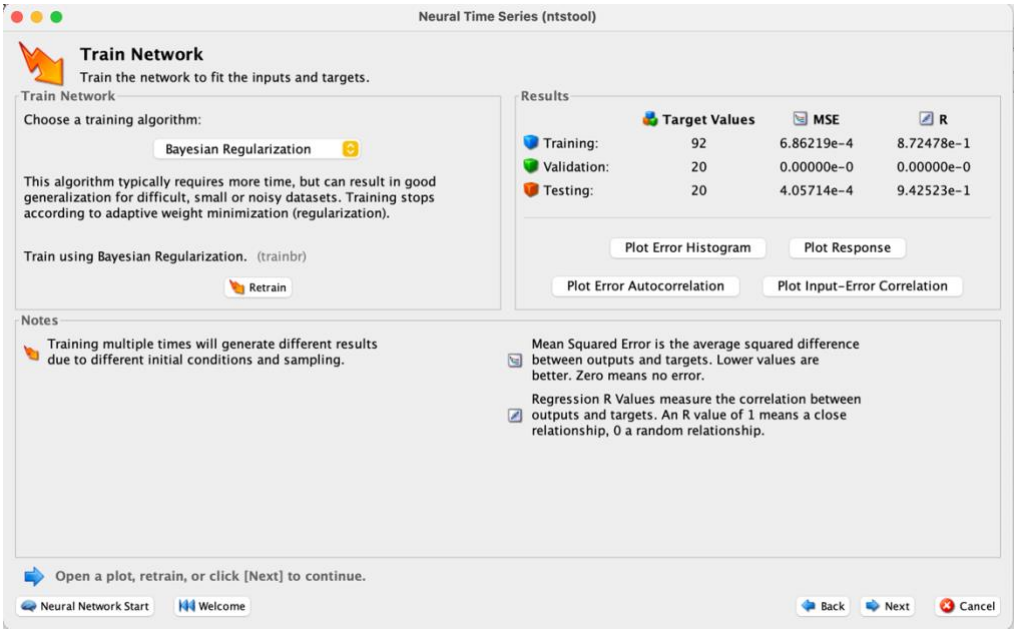
Şekil 3.7: MATLAB yazılımı içerisinde giriş ve hedef verilerinin sinir ağlarına tanımlanması.



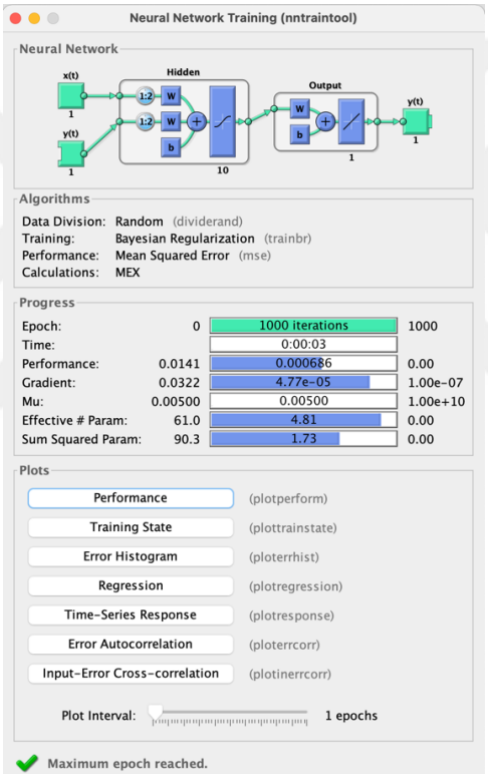
Şekil 3.8: MATLAB yazılımı içerisinde giriş verilerinin yüzde kaç öğrenme (training), onaylama (validation) ve test için kullanılacağının belirlenmesi.



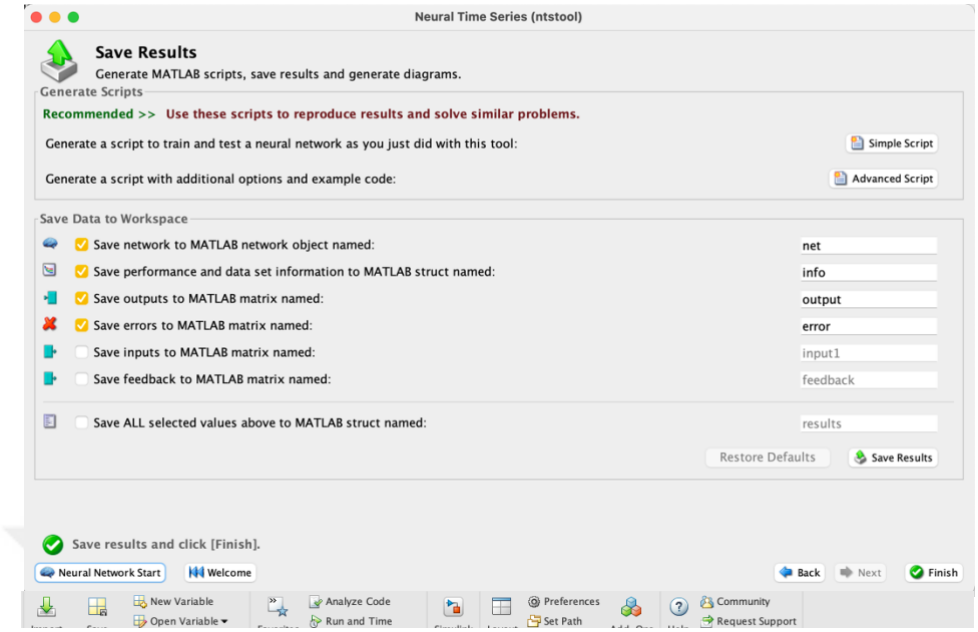
Şekil 3.9: MATLAB yazılımı içerisinde tahmin yapacak yapay sinir hücresi sayısı ve gecikme parametresinin belirlenmesi.



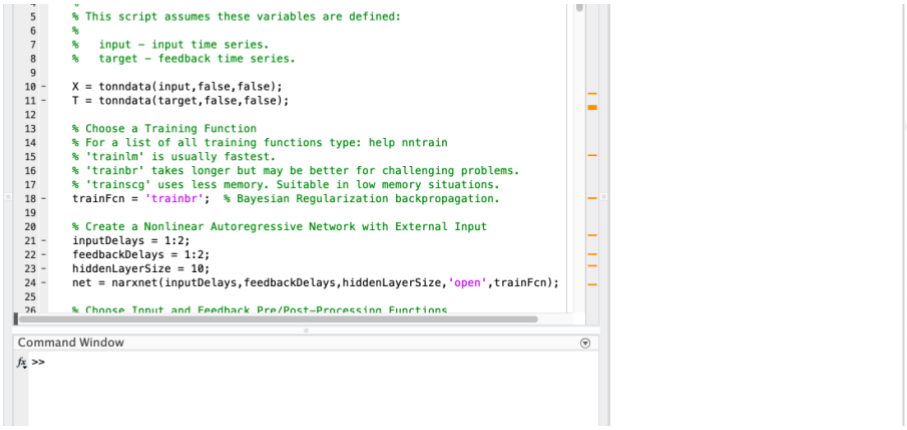
Şekil 3.10: MATLAB yazılımı içerisinde öğrenme algoritmasının belirlenmesi. Bu tez çalışmasında Bayesyen Düzeltme seçilmiştir. Bunun nedeni ise Bayesyen Düzeltmenin istatistiksel hatayı (Ortalama Kare Hatası: MSE) en aza indirmek için tekrarlamaya devam etmesidir. Bu da hassas tahminlerin yapılması için tercih edilen yöntemlerdendir.



Şekil 3.11: MATLAB yazılımı içerisinde NARX öğrenme arayüzü. Burada MATLAB'ın yaptığı işlemler kontrol edilir (Basit Tahmin).



Şekil 3.12: MATLAB yazılımında NARX tahmin sonuçlarının gösterildiği arayüz.



Şekil 3.13: MATLAB yazılımında "Advanced Script" arayüzü: Bu kısımda NARX sinir ağının kodlarına erişilir. Ayrıntılı değişiklikler yapılabilmesi için bu kısma başvurulur. Bu aşamadan önceki tüm aşamalar NARX kodlarına erişilebilmek için uygulanır, bundan sonraki aşamalar ise asıl tahmin sürecinin uygulanması olacaktır.

```
% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:2;
feedbackDelays = 1:2;
hiddenLayerSize = 10;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);
```

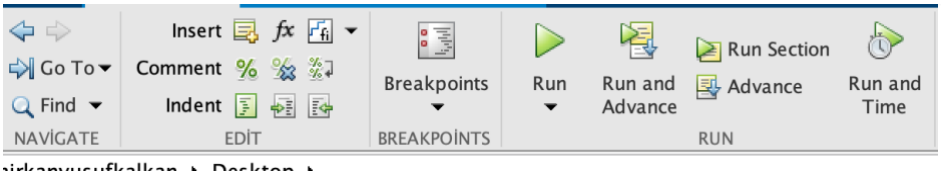
Şekil 3.14: NARX'in temel parametrelerinin (yapay sinir hücresi sayısı ve gecikme katsayısı) ayarlanması.

```
% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivision
net.divideFcn = 'dividerand';  % Divide data randomly
net.divideMode = 'time';  % Divide up every sample
net.divideParam.trainRatio = 70/100;
%net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 30/100;
```

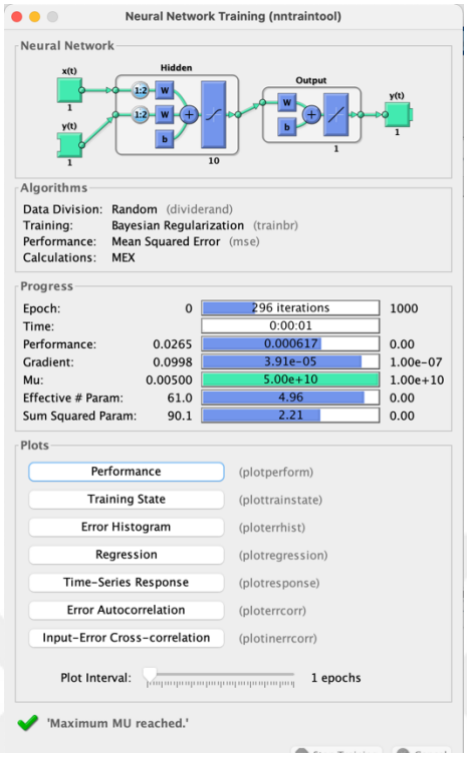
Şekil 3.15: Verilerin NARX sinir ağına ne kadar (net.divideParam.xxxxRatio), hangi işlevle (dividerand: rastgele) ve neye bağlı (net.divideMode = 'time': zamana bağlı) dağıtılacağının ayarlanması

```
% to perform multistep prediction while providing only the externa
% Here all but 5 timesteps of the input series and target series a
% to simulate the network in open-loop form, taking advantage of t
% accuracy that providing the target series produces:
numTimesteps = size(x,2);
knownOutputTimesteps = 1:(numTimesteps-5);
predictOutputTimesteps = (numTimesteps-4):numTimesteps;
X1 = X(:,knownOutputTimesteps);
T1 = T(:,knownOutputTimesteps);
[x1,xio,aio] = preparets(net,X1,{},T1);
[y1,xfo,afo] = net(x1,xio,aio);
```

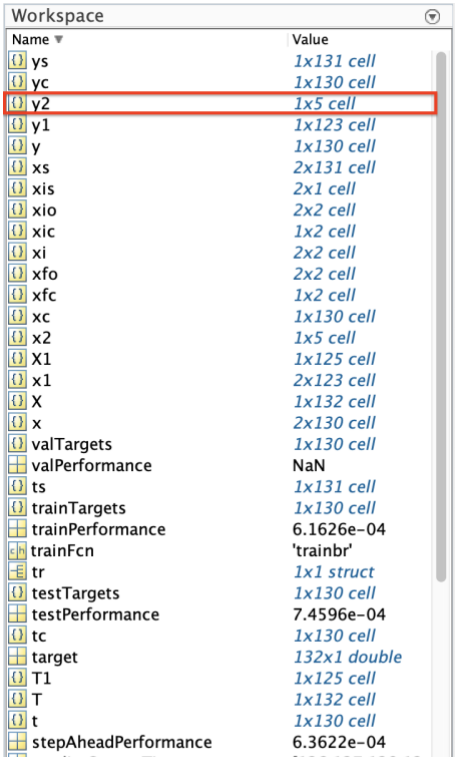
Şekil 3.16: *knownOutputTimesteps* ve *predictOutputTimesteps* işlevleri ile ileriye dönük tahmin edilecek veri sayısı belirlenmesi.



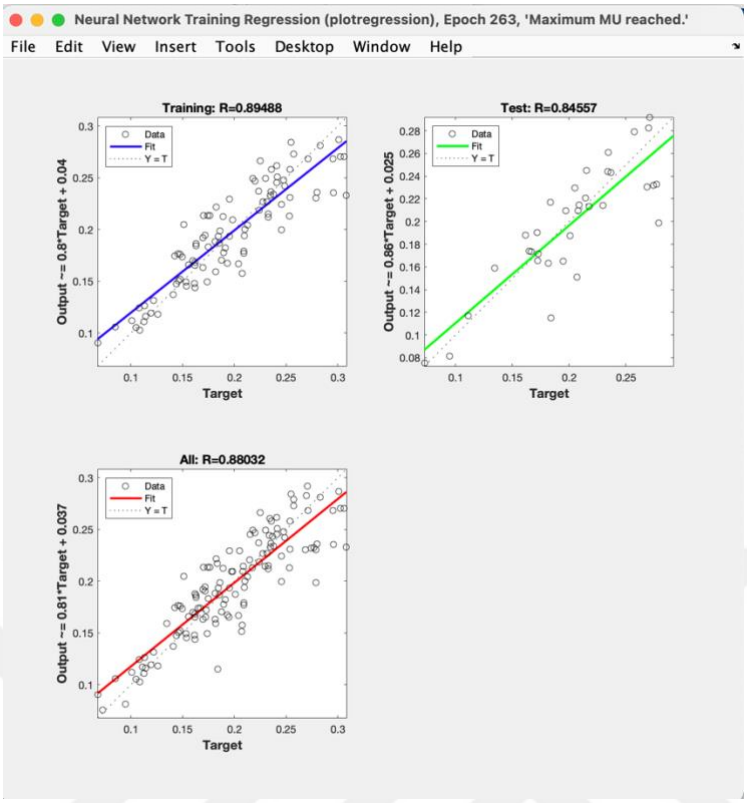
Şekil 3.17: Nihayer "Run" komutu ile tahmin gerçekleşitirecek script dosyasının çalıştırılması.



Şekil 3.18: MATLAB yazılımında NARX öğrenme arayüzü. Asıl tahmin yapılan aşamadır.



Şekil 3.19: NARX tahmin dosyaları. *y2*, tahmin sonucudur**.**



Şekil 3.20: NARX tahmin sonuçlarının öğrenme ve test ilişki analizi. Bu tahmin sonuçlarının öğrenme – hedef ve test – hedef verilerinin ilişkilerinin oranı grafikle beraber ondalık olarak verilmiştir.

y2

1x5 cell

	1	2	3	4	5	6	7
1	0.1681	0.1686	0.1744	0.1627	0.1566		
2							

Şekil 3.21: NARX tahmin sonucu örneği. Bu örnek tahminde gelecekteki 5 veri tahmin edilmiştir. NARX sinir ağlarına veriler normalize edilerek tanımlandığı için sonuçlar da 0 ile 1 arasında çıkmaktadır. Bunun için normalizasyonu tersine çeviren işlemi (Denklem 3.6) uygulanmalıdır.

$$x'_t = \hat{x}_t\,(x_{maks} - x_{min}) + x_{min} \qquad (3.6)$$

Normalizasyonu tersine çeviren işlem uygulandıktan sonra tahmin sonuçları karşılaştırmaya, analiz edilmeye ve yorumlanmaya hazırdır.

4. BULGULAR

4.1.GLS VERİLERİNDEN OLUŞTURULAN NARX TAHMİN SONUÇLARI

GLS NARX tahmin modelleri, nöron sayısı, geri bildirim sayısı, tahmin için en uygun şart (optimizasyon) algoritmaları, eğitim ve test periyotları dikkate alınarak 12 farklı kombinasyon ile 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.

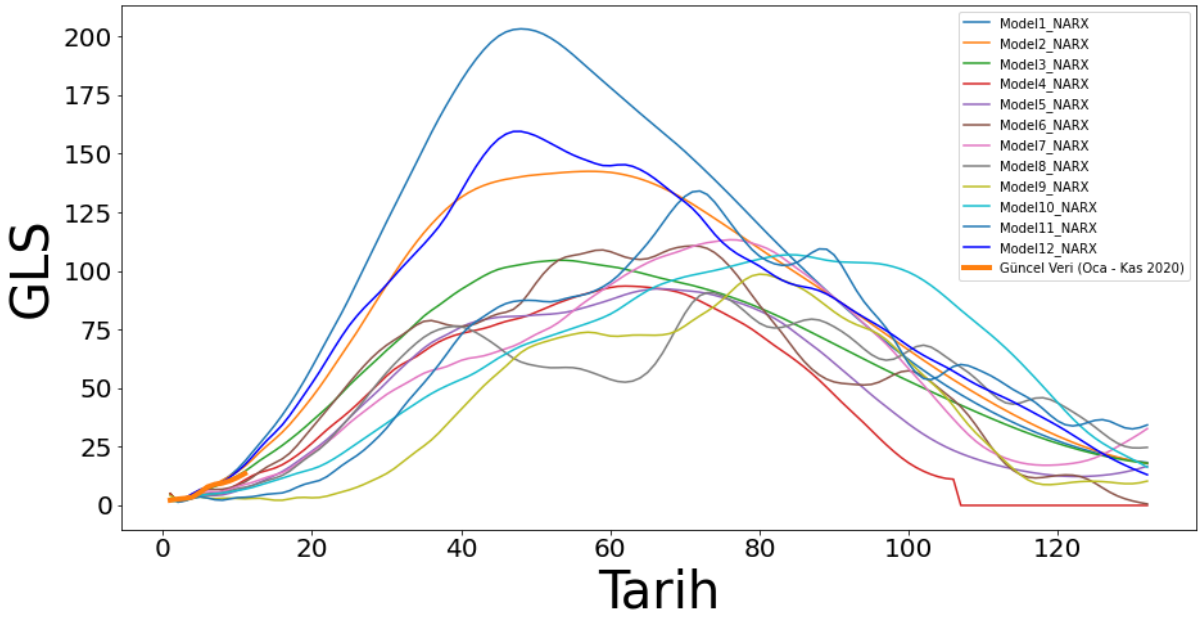
Tablo 4.1: Yapılan 12 NARX modeli arasında, hata analizi kriterlerine (*r*, RMSE ve NNSE) göre seçilen modeller.

Model	Mimari	Maks. Değeri	Maks. Değerine Karşılık Gelen Tarih	*r*	RMSE	NNSE
1	1-5-1-16	203,28	Aralık 2023	0,99	19,09	0,64
2	1-5-1-35	142,50	Eylül 2024	0,94	21,87	0,83
3	**1-10-1-45**	**104,58**	**Mayıs 2024**	**0,99**	**18,48**	**0,93**
4	1-15-1-45	93,55	Şubat 2025	0,97	13,08	0,85
6	1-25-1-45	110,71	Kasım 2025	0,98	7,47	0,69
7	**1-25-1-45**	**113,31**	**Nisan 2026**	**0,90**	**5,09**	**0,67**
10	1-25-1-50	106,92	Aralık 2026	0,99	6,65	0,64
12	1-35-1-45	159,54	Aralık 2023	0,99	17,53	0,77

Hata analizi ve güncel verilerle uyumluluk kriterlerine göre seçilen iki modelin (GLS_{Model3_NARX} = 104,58 ve maksimum tarihi Mayıs 2024; GLS_{Model7_NARX} = 113,31 ve

maksimum tarihi Nisan 2026) istatistiksel hata değerlerinin "iyi" olması ve literatürdeki tahmin çalışmaları veya mevcut GLS ile istatistiksel olarak uyumlu olduğu görülmektedir.

Farklı parametre kombinasyonları, yaklaşık 12 farklı model (Şekil 4.1) 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. Sonuçlarda, modellerin çoğu için r = 0.99 eğitim doğruluğu ve r = 0.98 test doğruluğu elde edilmiştir.



Şekil 4.1: 25. Güneş Çevriminde GLS değeri için 12 NARX modelinin karşılaştırılması (0-sıfır; Ocak 2020 tarihine denk gelmektedir).

4.1 bölümündeki bulguların özeti:

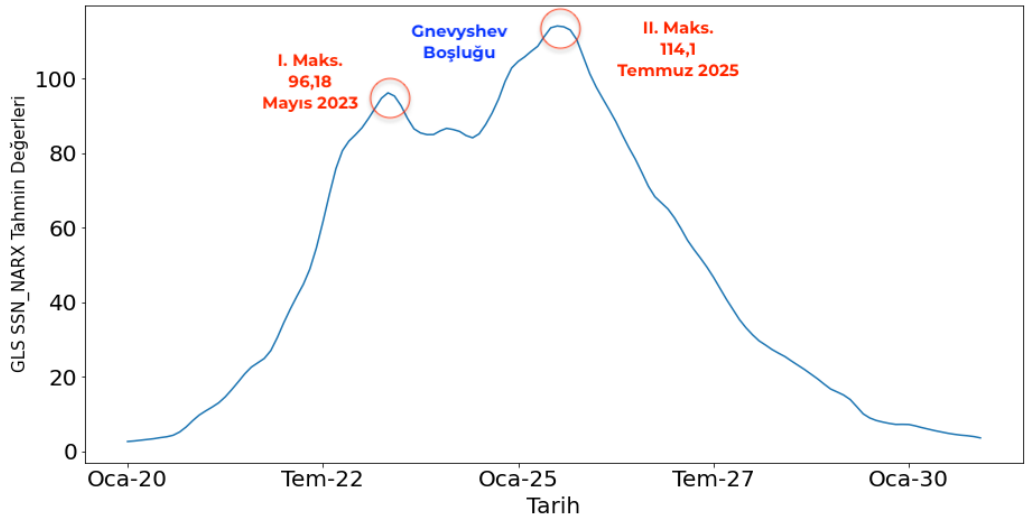
Tahmin modelleri, 12 farklı kombinasyon şeklinde oluşturulup, kriterlere göre önce 8 model, sonrasında 2 model seçilmiştir. Bu modeller ile;

1- Model1_NARX: 1-5-1-16 mimariyle 203,28 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2023,
2- Model2_NARX: 1-10-1-45 mimariyle 142,50 maksimum değeri ve bu maksimuma karşılık gelen tarih Eylül 2024,

3- **Model3_NARX:** 1-10-1-45 mimariyle 104,58 maksimum değeri ve bu maksimuma karşılık gelen tarih Mayıs 2024,
4- Model4_NARX: 1-15-1-45 mimariyle 93,55 maksimum değeri ve bu maksimuma karşılık gelen tarih Şubat 2025,
5- Model6_NARX: 1-25-1-45 mimariyle 110,71 maksimum değeri ve bu maksimuma karşılık gelen tarih Kasım 2025,
6- **Model7_NARX:** 1-25-1-45 mimariyle 113,31 maksimum değeri ve bu maksimuma karşılık gelen tarih Nisan 2026,
7- Model10_NARX: 1-25-1-50 mimariyle 106,92 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2026,
8- Model12_NARX: 1-35-1-45 mimariyle 159,54 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2023,

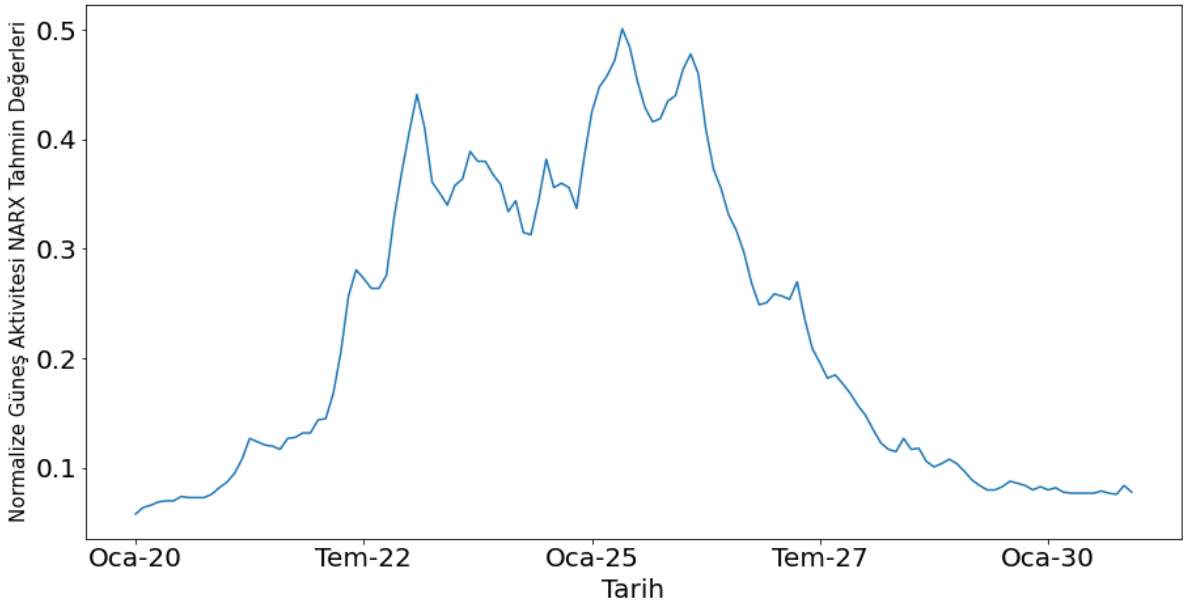
sonuçları bulunmuştur. Hata analizi katsayıları iyi olan, literatür veya güncel gerçek verilerle uyumlu modeller sırasıyla Model7_NARX ve Model3_NARX'tir.

4.2.DİĞER GÜNEŞ AKTİVİTESİ PARAMETRELERİNDEN OLUŞTURULAN NARX TAHMİN SONUÇLARI



Şekil 4.2: SSN_NARX I. ve II. Maksimum tahmin sonuçları ve Gnevyshev Boşluğu.

Diğer Güneş Aktivitesi verilerinden oluşturulan çoklu parametreli NARX tahmin modelleri; GLS verilerine ek POS, TGI ve $F_{10.7}$ verileriyle kendi türünde modeller oluşturulmuş ve



Şekil 4.3: 25. Güneş Çevrimi için GLS, POS, $F_{10.7}$, TGI parametreleriyle ayrı ayrı oluşturulmuş NARX tahmin modellerinin sonuçlarının ortalaması.

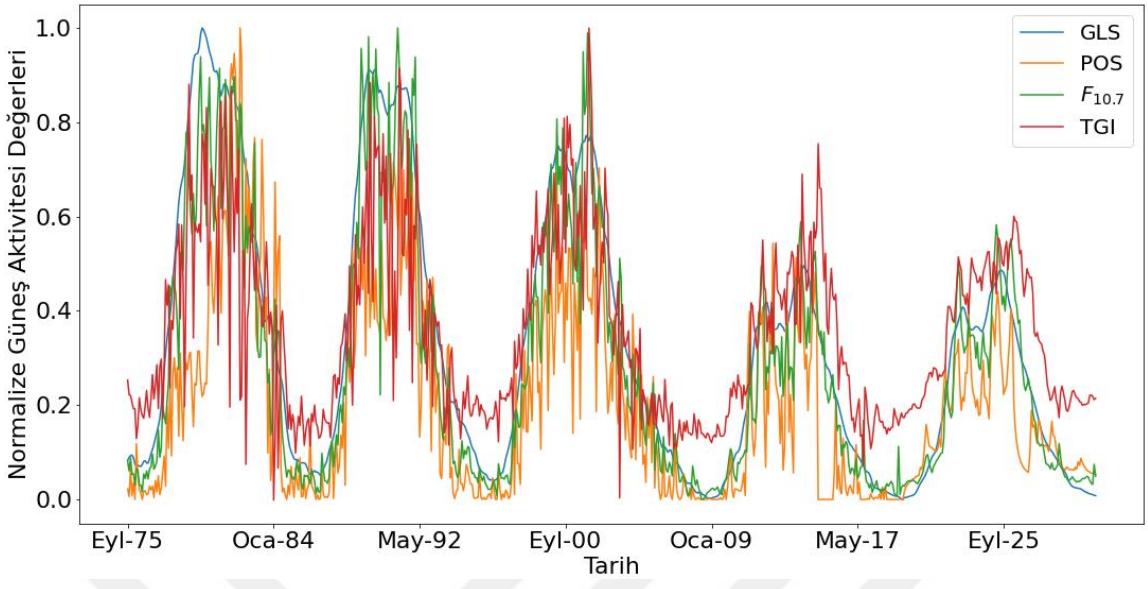
değerlendirilmiştir. Güneş'e ait farklı parametelerin verilerden oluşturulan modeller karşılaştırıldığında, daha güvenilir tahminler yapılabileceği düşünülmüştür. Her bir parametreye ait 4 farklı modelde gecikme değeri 1'de sabit tutulmuştur. Bunun nedeni ise modellerin bu değerde her bir parametre için en uygun eğrileri göstermesindendir. Bu modeller oluşturulurken tek parametreli modellerdeki strateji (NAR sinir ağlarıyla optimum bir eğri oluşturularak NARX hedef verileri olarak tanımlanması) izlenmiştir.

Tablo 4.2: 25. Güneş Çevrimi için GLS (Model3_NARX baz alınarak yeniden oluşturulmuş), POS, TGI ve $F_{10.7}$ parametrelerine ait NARX tahmin modellerinin sonuçları. GLS (SSN_NARX) için Güneş lekesi miktarı, POS (FLARE_NARX) için parlama miktarı, TGI (TSI_NARX) için W/m^2, $F_{10.7}$ (RADIO_NARX) için 1 Güneş Akı Birimi (sfu) = $10^{-22}Js^{-1}m^{-2}Hz^{-1}$ birimleri kullanılmaktadır.

Model	Mimari	Öğrenme	Test	*r*	RMSE	NNSE	I. Maks.	II. Maks.
SSN_NARX	1-10-1-1	0,998	0,998	0,990	0,103	0,686	96,18 (May 23)	114,1 (Tem 25)
FLARE_NARX	1-20-1-1	0,873	0,858	0,472	1,607	0,972	200 (Eyl 23)	220 (May 25)
TSI_NARX	1-7-1-1	0,823	0,776	0,859	0,003	0,828	1361,4 (Şub 23)	1361,6 (Nis 26)
RADIO_NARX	1-10-1-1	0,948	0,943	0,686	0,428	0,955	153,8 (Şub 23)	168,54 (Nis 25)

Tablo 4.3: 25. Güneş Çevrimi için GLS (Model3_NARX baz alınarak yeniden oluşturulmuş), POS, TGI ve $F_{10.7}$ parametrelerine ait NARX tahmin modellerinin Düşük ve Yüksek Düzgünleştirme işlevi uygulanmış sonuçları. GLS (SSN_NARX) için Güneş lekesi miktarı, POS (FLARE_NARX) için parlama miktarı, TGI (TSI_NARX) için W/m^2, $F_{10.7}$ (RADIO_NARX) için 1 Güneş Akı Birimi (sfu) = $10^{-22}Js^{-1}m^{-2}Hz^{-1}$ birimleri kullanılmaktadır (Orijinal: Sinir ağlarına herhangi bir şekilde düzgünleştirme işlevi uygulanmamış hali; Ort. (Yüksek): Yüksek düzgünleştirme işlevi uygulanmasından dolayı elde edilen ortalama değer; Ort. (Düşük): Düşük düzgünleştirme işlevi uygulanmasından dolayı elde edilen ortalama değer.

Model	**Maksimum I (Orijinal)**	**Maksimum II (Orijinal)**	**Maksimum (Ort.) (Yüksek)**	**Maksimum (Ort.) (Düşük)**
SSN_NARX	96,18 (May 2023)	114,1 (Tem 2025)	95,09 (Kas 2024)	108,63 (Haz 2025)
FLARE_NARX	200 (Eyl 2023)	220 (May 2025)	132 (Eki 2024)	152 (May 2025)
TSI_NARX	1361,4 (Şub 2023)	1361,6 (Nis 2026)	1361,37 (Haz 2024)	1361,30 (Eyl 25)
RADIO_NARX	153,8 (Şub 2023)	168,54 (Nis 2025)	135,88 (May 25)	147,20 (Haz 2025)

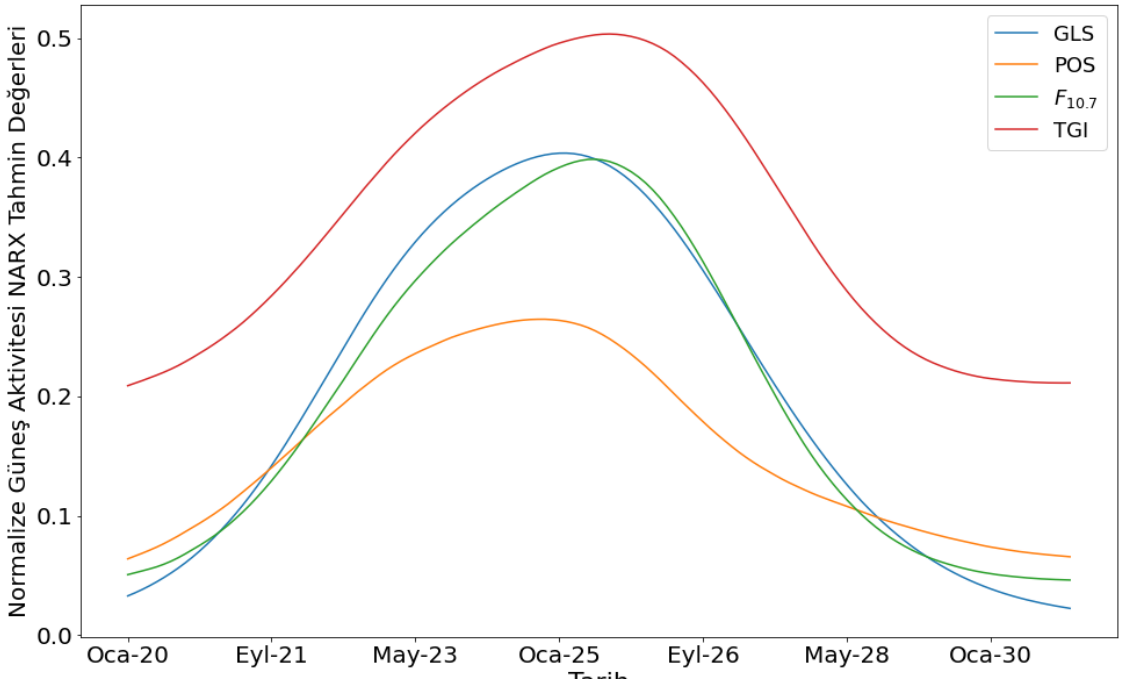


Şekil 4.4: 21.'den 25.'ye kadar olan Güneş Çevrimleri için Güneş Aktivitesi (25. Çevrim için tahmini) değişimleri (Mavi eğriler: GLS, Turuncu Eğriler: POS, Yeşil Eğriler: $F_{10.7}$, Kırmızı Eğriler: TGI).

25. Güneş Çevrimi için yapılan tahminlerin tutarlılığı, eğrilerin Gauss benzeri olmasına göre belirlenir. Çünkü böyle bir eğri elde edilmediğinde tahmin sonuçları sonsuz olasılık durumuna sahiptir. Ayrıca bir parametreye ait veri miktarı, modellerin sonuçlarının tutarlı olduğunu belirlemeyi kolaylaştırır. Parametrenin verileri detaylı olarak incelendiğinde eğer önemli değişiklikler varsa eğriye düzgünleştirme işlevi (*smoothing function*) uygulanır. Bu sayede verilerin değişimi daha kolay görülebilir. Elbette tahmin sonuçlarının hem orijinal hem de düzgünleştirilmiş versiyonlarını birbiriyle karşılaştırmak gerekir.

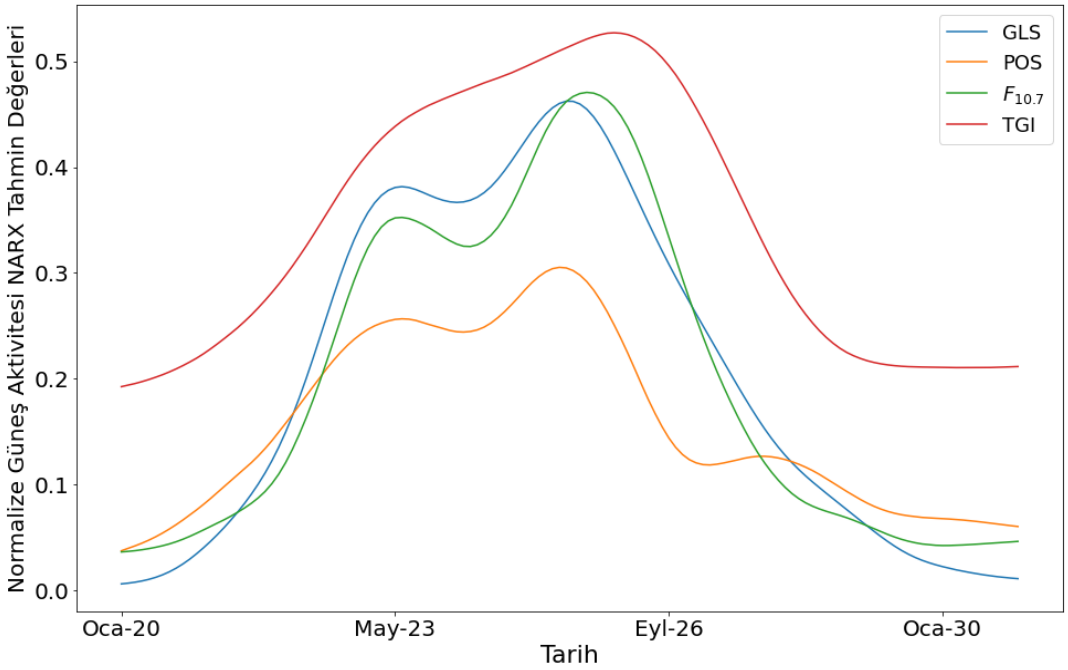
Bu strateji ile uygulanan düzgünleştirme işlevi ile eğrinin "aşırı öğrenme (*over-fitting*)" problemiyle karşılaşılmaması hedeflenmektedir.

Düzgünleştirme işlevi eğrilere iki tür düzende uygulanmıştır: Düşük Düzgünleştirme: 20 nokta (Şekil 4.5.), Yüksek Düzgünleştirme: 40-60 nokta (Şekil 4.4). Düşük düzgünleştirme



Şekil 4.5: 25. Güneş Çevrimi için NARX modelleri sonuçlarının karşılaştırılması (Mavi eğri: GLS, Turuncu Eğri: POS, Yeşil eğri: $F_{10.7}$, Kırmızı Eğri: TGI) (Yüksek Düzgünleştirme uygulanmıştır).

uygulandığında eğride açıkça bir Gnevyshev Boşluğu görülebilmektedir. Burada kesin sonuç değerini incelemek yerine her bir parametrenin sonuç eğrilerinin birbiriyle uyumluluğu kısmen incelenebilir. Bununla birlikte, yüksek düzgünleştirme eğrilerinde, çevrimin tüm yönlerinden iki tepe değerinin ortalaması şekline dönüştürülür. Buradan modellerin birbirileriyle uyumluluğu daha iyi görülebilmektedir.



Şekil 4.6: 25. Güneş Çevrimi için NARX modelleri sonuçlarının karşılaştırılması (Mavi eğri: GLS, Turuncu Eğri: POS, Yeşil eğri: $F_{10.7}$, Kırmızı Eğri: TGI) (Düşük Düzgünleştirme uygulanmıştır)..

4.2 bölümündeki bulguların özeti:

Oluşturulan modellerle her bir parametre için iki tepeli (Gnevyshev Boşluğuna sahip) çevrim sonuçları elde edilmiştir. GLS parametresi için I. Maksimum değeri ve tarihi: 96,18 (Mayıs 2023); II. Maksimum değeri ve tarihi: 114.1 (Temmuz 2025), POS parametresi için I. Maksimum değeri ve tarihi: 200 (Eylül 2023); II. Maksimum değeri ve tarihi 220 (Mayıs 2025), TGI parametresi için I. Maksimum değeri ve tarihi: 1361,4 W/m^2 (Şubat 2023); II. Maksimum değeri ve tarihi: 1361,6 W/m^2 (Nisan 2026), $F_{10.7}$ parametresi için I. Maksimum değeri ve tarihi: 153,8 sfu (Şubat 2023); II. Maksimum değeri ve tarihi: 168,54 sfu (Nisan 2025) olarak tahmin edilmiştir.

Ayrıca;

SSN_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 95,09 (Kasım 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 108,63 (Haziran 2025) olarak,

FLARE_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 132 (Ekim 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 152 (Mayıs 2025) olarak,

TSI_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 1361,37 (Haziran 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 1361,30 (Eylül 2025) olarak,

RADIO_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 135,88 (May 2025), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 147,20 (Haziran 2025) olarak hesaplanmıştır.

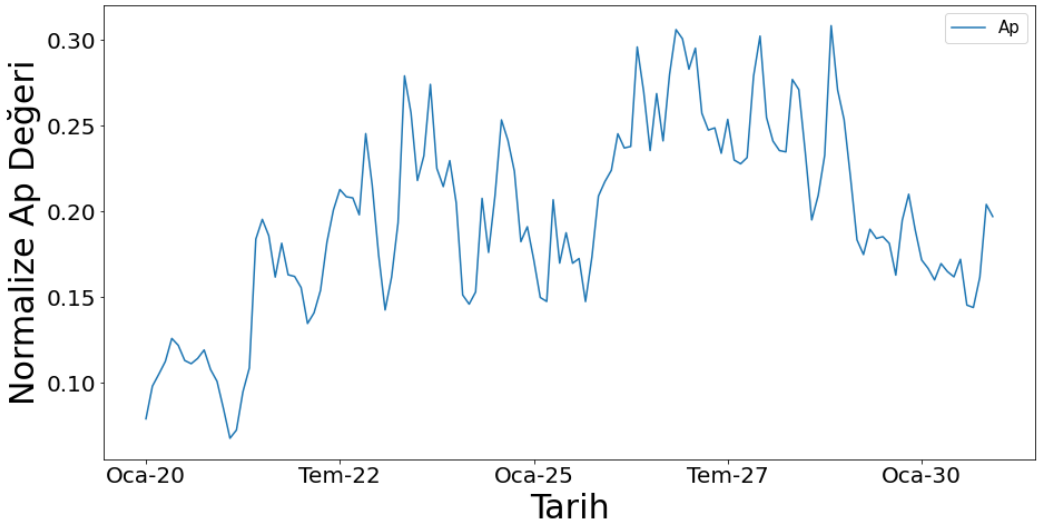
4.3.YER MANYETİK İNDİSLE (AP) OLUŞTURULAN NARX TAHMİN SONUÇLARI

Yermanyetik indislerden Ap değerinin aylık verileri ile oluşturulan NARX tahmin modelleri, Güneş Aktivitesinin 25. periyodunda Dünya'nın manyetik alanını ne şekilde etkileyeceğini tahmin etmeyi amaçlamaktadır. Burada Güneş – Dünya etkileşimi senaryosunun bitiş evresi öngörülmüştür.

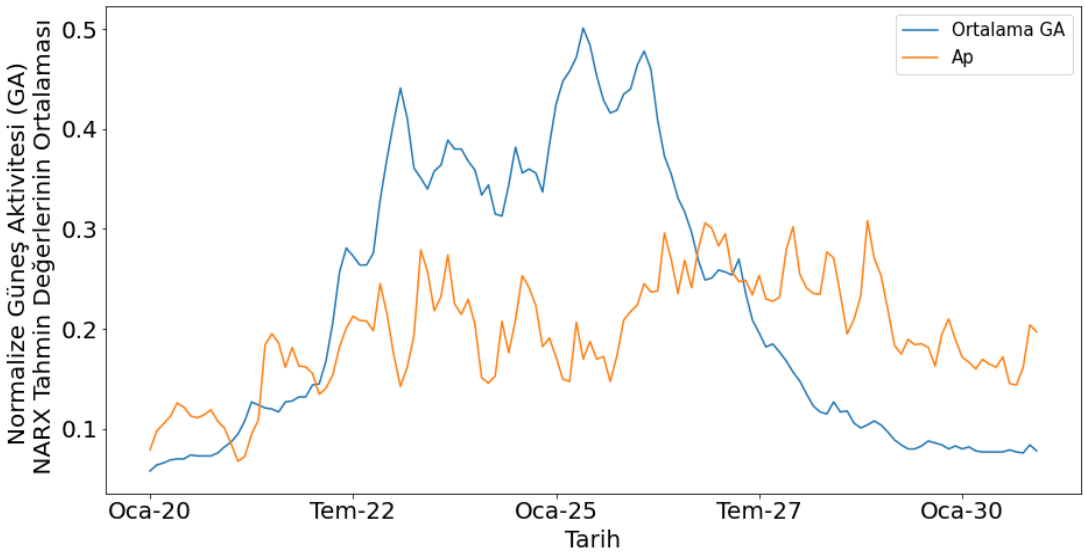
Ap indisi gibi saat mertebesinde anlık değişkenlik gösteren parametreler için NARX tahminlerinin sonuçları, sinir ağlarının önceki dönemleri baz alarak değerler türettiğinden dolayı, gerçek verilerle kıyaslandığında birebir örtüşmesi mümkün olmamaktadır. Bunun için sonuçları gerçek verilerin gidişatına göre düzgünleştirerek karşılaştırma yapılması gerekmektedir. Bu karşılaştırma, veriler arasında uyumluluk göstermektedir (Tablo 4.4).

Tablo 4.4: Ap için NARX tahmin sonuçlarının ham hali, 40 nokta ile düzgünleştirilmiş sonuçlar ve istatistiksel hata değerleri (*r*, RMSE ve NNSE).

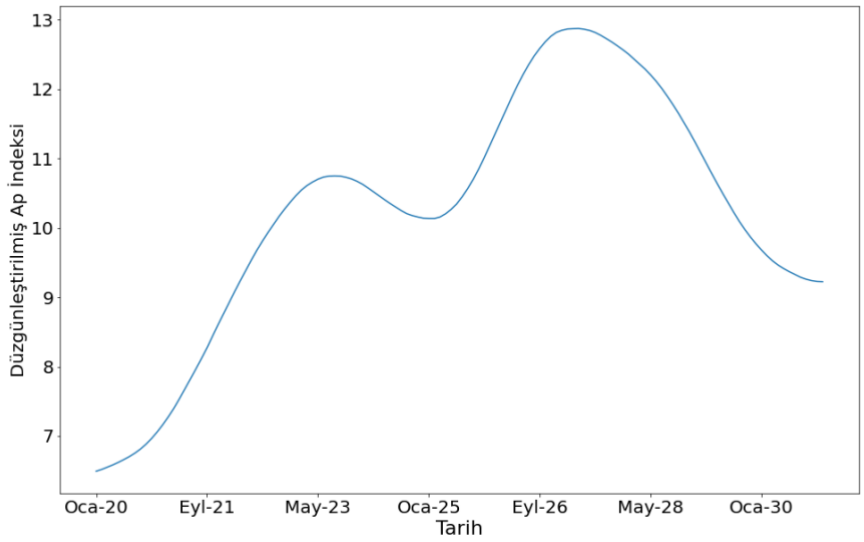
Model	Mimari	*r*	RMSE	NNSE	Maks. I.	Maks. II.
AP_NARX	1-15-1-1	0,56	1,90	0,59	13,77 May 2023	15,01 Kas 28
AP_NARX_Smooth	AP_NARX tahmin sonuçlarının düzenlenmesi ile oluşturuldu.	0,70	1,91	0,59	10,75 Ağu 2023	12,87 Nis 2027



Şekil 4.7: Ap yer manyetik indisi için oluşturulmuş NARX modelinin tahmin sonucu;. AP_NARX: I. Maksimum 13,77 nT (May 2023), II. Maksimum 15,01 (Kasım 2028).



Şekil 4.8: NARX tahmin modellerinin sonuçlarının ortalaması ile Ap değeri için tahmin edilen sonuç değerlerinin karşılaştırılması; Tarihsel olarak Ortalama GA (Mavi) değerinin I. Maksimum tarihi ve Ap değerinin (Turuncu) I. Maksimum tarihi ortak (Mayıs 2023), fakat Ortalama GA değerinin II. Maksimum tarihi ve Ap değerinin II. Maksimum tarihi arasında yaklaşık 3 yıllık bir gecikme gözlenmektedir.



Şekil 4.9: Ap yer manyetik indisi için oluşturulmuş NARX modelinin sonuçlarına düzgünleştirme işlemi uygulanmış hali.

4.3 bölümündeki bulguların özeti:

Ap indisi NARX ile 1-15-1-1 mimarisi ile tahmin edildiğinde r = 0,56, RMSE = 1,90, NNSE = 0,59 hata değerleriyle I. Maksimum 13,77 (Mayıs 2023) ve II. Maksimum 15,01 (Kasım 2028); 40 nokta ile düzgünleştirme işlevi yapıldığında r = 0,70, RMSE = 1,91, NNSE = 0,59 hata değerleriyle I. Maksimum 10,75 (Ağustos 2023) ve II. Maksimum 12,87 (Nisan 2028) olarak bulunmuştur.

5. TARTIŞMA VE SONUÇ

Tartışma

Güneş bize en yakın yıldız olma özelliği ile yüzeyden itibaren çeşitli tabakalarının incelenmesine, yüzeyindeki aktivitelerin gözlenebilmesine olanak verir. Bir yıldız olarak Güneş'in bu şekilde incelenmesi yıldızların astrofiziksel süreçlerini ve içyapılarının anlaşılmasında çok önemli bir kaynaktır. Güneş'in yaklaşık 11 yıllık süreçlerle yüzeyinde gerçekleşen leke çevrimleri ve buna bağlı olarak Parlama Oluşum Sıklığı (POS), 10.7 cm Güneş Radyo Akısı ($F_{10.7}$) ve Toplam Güneş Işınımı (TGI) parametrelerinin değişimi yukarıda bahsedilen astrofiziksel süreçler için oldukça kıymetli gözlemlerdir. Sistemimizin bir yıldızı olarak Güneş'teki bu değişimler özellikle fiziksel olarak Dünya'mızı yakından da ilgilendirmektedir. Uzay havası olarak kullandığımız terim de tam bu ilişkilerden ortaya çıkmıştır. Güneş'in aktif zamanlarındaki değişimlerin Dünya'mızın manyetik alanını manyetik kutuplardan itibaren atmosfer ve altı yüzeyini ve Dünya'mızın etrafında farklı yörüngelerde dolanan uyduları etkileyebilmektedir. Güneş Aktivitesi'ndeki değişimleri izlemek ve bu periyodik değişimlerin gelecekteki oluşum süreçlerini tahmin etmek yukarıda değindiğimiz hem astrofiziksel hem de uzay havası konularının daha iyi anlaşılabilmesini sağlayacaktır.

Güneş'in özellikle leke çevrimlerinin ve bağlı POS, $F_{10.7}$, ve TGI parametrelerinin gelecekteki tahminlerine ilişkin çalışmalar yaygın olarak ve farklı yöntemler kullanılarak yapılmaktadır. Kullanılan istatistik yöntemler farklıdır. Doğal olarak araştırmacılar farklı sonuçlara ulaşabilmektedir. Bununla ilgili olarak Ek 1.'de verilen tabloda 20 araştırmacının bulduğu rölatif sayının maksimum olduğu ve zamanlar sürmekte olan ve tahminen 2030 Aralık'ında sonlanması beklenen Güneş Aktivite Çevrimi'ne ait değerlerdir.

Literatür incelenip Güneş'in 25. Aktivite Çevrimi (tahmini 2020 başı 2031 sonu) için daha da iyi bir tahmin yöntemi bu tez çalışmasında ele alındı. Bu yöntem NARX olarak bilinen Doğrusal Olmayan Otoregresif Dışsal Model yöntemidir.

Tez çalışmasında, üç ayrı bulguya ulaşıldı. Bunlardan ilki Bölüm 4.1.'de açıklanan GLS verilerinden oluşturulan NARX tahmin sonuçlarıdır. Bu sonuçlara göre;

Tahmin modelleri, 12 farklı kombinasyon şeklinde oluşturulup, kriterlere göre önce 8 model, sonrasında 2 model seçilmiştir. Bu modeller ile;

1- Model1_NARX: 1-5-1-16 mimariyle 203,28 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2023,
2- Model2_NARX: 1-10-1-45 mimariyle 142,50 maksimum değeri ve bu maksimuma karşılık gelen tarih Eylül 2024,
3- **Model3_NARX:** 1-10-1-45 mimariyle 104,58 maksimum değeri ve bu maksimuma karşılık gelen tarih Mayıs 2024,
4- Model4_NARX: 1-15-1-45 mimariyle 93,55 maksimum değeri ve bu maksimuma karşılık gelen tarih Şubat 2025,
5- Model6_NARX: 1-25-1-45 mimariyle 110,71 maksimum değeri ve bu maksimuma karşılık gelen tarih Kasım 2025,
6- **Model7_NARX:** 1-25-1-45 mimariyle 113,31 maksimum değeri ve bu maksimuma karşılık gelen tarih Nisan 2026,
7- Model10_NARX: 1-25-1-50 mimariyle 106,92 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2026,
8- Model12_NARX: 1-35-1-45 mimariyle 159,54 maksimum değeri ve bu maksimuma karşılık gelen tarih Aralık 2023,

sonuçları bulunmuştur. Hata analizi katsayıları iyi olan, literatür veya güncel gerçek verilerle uyumlu modeller sırasıyla Model7_NARX ve Model3_NARX'tir. Bu değerlerimiz literatürdeki (Model3_NARX için; Benson ve diğ., (2020): 106, Chowdhury ve diğ., (2021): 100,21 - Model7_NARX için; Bhowmik ve Nandy (2018): 118; Du ve Du (2006): 111,6; Helal ve Galal (2013): 118,2; NOAA (2019): 115; Pishkalo (2008): 112,3; Sarp ve Kılçık (2018): 119,6; Svalgaard (2020): 128; Upton ve Hathaway (2018): 24. Çevrimle aynı) değerleriyle uyuşmaktadır.

İkinci bulgu ise, Bölüm 4.2'de açıklanan diğer Güneş Aktivitesi parametrelerinden oluşturulan NARX tahmin sonuçlarıdır;

Oluşturulan modellerle her bir parametre için iki tepeli (Gnevyshev Boşluğuna sahip) çevrim sonuçları elde edilmiştir. GLS parametresi için I. Maksimum değeri ve tarihi: 96,18 (Mayıs 2023); II. Maksimum değeri ve tarihi: 114.1 (Temmuz 2025), POS parametresi için I.

Maksimum değeri ve tarihi: 200 (Eylül 2023); II. Maksimum değeri ve tarihi 220 (Mayıs 2025), TGI parametresi için I. Maksimum değeri ve tarihi: 1361,4 W/m^2 (Şubat 2023); II. Maksimum değeri ve tarihi: 1361,6 W/m^2 (Nisan 2026), $F_{10.7}$ parametresi için I. Maksimum değeri ve tarihi: 153,8 sfu (Şubat 2023); II. Maksimum değeri ve tarihi: 168,54 sfu (Nisan 2025) olarak tahmin edilmiştir.

Ayrıca;

SSN_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 95,09 (Kasım 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 108,63 (Haziran 2025) olarak,

FLARE_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 132 (Ekim 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 152 (Mayıs 2025) olarak,

TSI_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 1361,37 (Haziran 2024), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 1361,30 (Eylül 2025) olarak,

RADIO_NARX modelinin sonuçlarına Yüksek Düzgünleştirme uygulandığında çevrim maksimumu 135,88 (May 2025), Düşük Düzgünleştirme uygulandığında çevrim maksimumu 147,20 (Haziran 2025) olarak hesaplanmıştır.

Bu sonuçlar literatürdeki (SSN_NARX için, Bhowmik ve Nandy (2018): 118; Dani ve Sulistiani (2019): 110,2; Du ve Du (2006); Helal ve Galal (2013): 118,2; NOAA (2019): 115; Pishkalo (2008): 112,3; Sarp ve Kılçık (2018): 119,6; Svalgaard (2020): 128; Upton ve Hathaway (2018): 24. Çevrimle aynı (116,4 civarı)) sonuçlarıyla oldukça uyumludur. Ayrıca burada ortaya çıkan en önemli bulgu ise I. Maksimum'unun daha düşük II. Maksimumunun daha yüksek olan Gnevyshev Bolşuğu'nun ortaya çıkacak olmasıdır (Şekil 4.2).

Üçüncü bulgu ise, Bölüm 4.3'te açıklanan yer manyetik indisle (Ap) oluşturulan NARX tahmin sonuçlarıdır;

Ap indisi NARX ile 1-15-1-1 mimarisi ile tahmin edildiğinde r = 0,56, RMSE = 1,90, NNSE = 0,59 hata değerleriyle I. Maksimum 13,77 (Mayıs 2023) ve II. Maksimum 15,01 (Kasım

2028); 40 nokta ile düzgünleştirme işlevi yapıldığında *r* = 0,70, RMSE = 1,91, NNSE = 0,59 hata değerleriyle I. Maksimum 10,75 (Ağustos 2023) ve II. Maksimum 12,87 (Nisan 2028) olarak bulunmuştur. Bu değerler literatürdeki (Singh ve diğ., 2021 (Ap = 8.78 nT); Du, 2020 (Ap = 19,4 nT)) sonuçlarıyla uyumludur.

Öte yandan çalışmalarının ciddiyetine inanılan ve dikkatle takip edilen www.nasa.gov/msfcsolar adlı NASA web sitesindeki GLS, $F_{10.7}$ ve Ap verilerinin grafikleriyle uyumluluğumuz; GLS parametresi için Model1_NARX ve NASA'nın GLS [%95] adlı modeli, Model2_NARX ve NASA'nın GLS [%50] modeli, Model12_NARX ve NASA'nın [%50] adlı modeli; $F_{10.7}$ parametresi için RADIO_NARX ve NASA'nın 10.7 cm [%50] ve [%75] adlı modelleri; Ap parametresi için AP_NARX ve NASA'nın Ap [%50] ve [%95] adlı modelleri ile uyumludur (Ek 2.).

Kullandığımız modellerimizdeki tahmin sonuçlarını ne kadar ileriye götürülebileceğini anlamak üzere 2031 yılından sonra oluşacak 26. Güneş Leke Çevrimi'nin de tahmini gerçekleştirildi. Ancak bu tez çalışmasında bu tahmine yer verilmeyip "Multi-Parameter Neural Network Prediction for Solar Cycles 25 and 26" adlı makale MNRAS'a gönderilmek üzere (Haziran 2022) hazırlanmıştır. Bu çalışmadan ortaya şu çıkmaktadır;

25. Güneş Leke Çevrimi'nin genliği (R_{SSN_NARX} = 114,1, R_{Model3_NARX} = 104,58, R_{Model7_NARX} = 113,3) 24. Güneş Leke Çevriminin (R = 116,4) genliğine eşit veya ondan daha az çıkacaktır. 26. Güneş Çevriminin genliği ise 25. Güneş Çevriminkinden daha düşük çıkmaktadır.

Şimdi de tartışmamızda analizlerimizdeki hataların özelliklerine değinelim:

Şekil 4.5 (Yüksek Düzgünleştirme) ve Şekil 4.6 (Düşük Düzgünleştirme) 25. Güneş Çevrimi için NARX tabanlı tahminleri göstermektedir. Her iki şekilde de mavi eğriler GLS'yi, turuncu eğriler POS'u, yeşil eğriler $F_{10.7}$'u ve kırmızı eğriler TGI'yı temsil etmektedir. Parametrelerin verileri NARX sinir ağları tarafından %80'in üzerinde uyumlulukla öğretilmiş ve %70'in üzerinde test edilmiştir. Bunun nedeni, gerçek verilerde POS sonuçları detaylı olarak incelendiğinde düzenli bir artış göstermemesidir. POS, GLS ve TGI'ye göre daha kısa sürede gerçekleşen ani olaylar olduğu için tahminlerde yaklaşık % 47'lik bir uyumluluk değeri göstermektedir. NARX sinir ağları çalışma mekanizmasında, önceki verilerin davranışına göre tahminlerde bulunulduğundan, Güneş parlamalarının düzensiz

değişimleriyle üst düzey uyumluluk sağlamadığı görülmektedir. POS'a nazaran, bu durum $F_{10.7}$ 'da biraz daha iyi olmaktadır. Yine de % 60'lık bir uyumluluk değeri kabul edilebilir. Bu durumda, sık veya düzenli olarak değişen parametrelerin uyumluluk değerlerinin daha yüksek olduğu görülmektedir (Tablo 4.2).

En azından bu karmaşıklığı daha güvenilir bir duruma dönüştürmek için RMSE ve NNSE gibi hata analizi değerleri de incelenmiştir (Tablo 4.2). Aynı şekilde POS ve $F_{10.7}$ değerlerinin RMSE değerleri incelendiğinde, hata değerinin yüksek olduğu görülmektedir. Bu, parametrelerin *r* değerleri için de açıklamamızı desteklemektedir. NNSE değerinin 1'e yakın olması yöntemin iyi bir performansa sahip olduğunu gösterir (Yılmaz, 2014). %80 üzerindeki NNSE değerlerimizin çoğu, modellerin "iyi" olarak değerlendirilebileceği anlamına gelmektedir.

Tablo 4.2'den de görüleceği üzere, Ocak 2020'den bu zamana kadar parametrelerin mevcut verileri ile tahmin sonuçlarla karşılaştırdığımızda çoğunlukla %60'ın üzerinde bir uyumluluk göstermektedir.

Literatür karşılaştırmalarında 25. Güneş Çevrimi için tahminlerin uyumlu olduğu görülmektedir.

NARX sinir ağlarında hata en aza indirilerek aşırı eğitim sorunu ile karşılaşılmadan, daha önceki Güneş çevrimlerinin verileri ile tahmin yapılabileceği anlaşılmaktadır.

Literatürdeki tahmin çalışmaları, Güneş aktivitesinin uzun süreye dayanan tahminleri, gelecekte gerçekleştirilecek uzay görevlerini planlamak ve Güneş çevriminin işleyişini anlamak için gereklidir (Hathaway 2015, Petroway 2020).

24. Güneş Çevrimi, Dalton minimumundan beri (1810 yılı civarı) kaydedilen en düşük ikinci çevrimdir (Wu ve Qin, 2021). Bu nedenle son yıllarda pek çok araştırma gibi bu tezde de 25. Güneş çevriminin Güneş maksimumunun tahminine odaklanıldı. 25. Güneş çevrimi'nde GLS için Güneş maksimumu 24. Çevrimin maksimumundan %14 (Macario-Rojas ve diğ., 2018), %24 (Labonville ve diğ., 2019) ve %31 (Singh ve Bhargawa, 2019) daha düşük olacağı tahmin edileceği ifade edilmektedir. Buna ek olarak birkaç çalışma, 25. Güneş Çevriminin GLS maksimumunun çok daha düşük değerler elde edilebileceğini ifade

etmektedir; 50 ± 15 (Kitiashvili 2020) ve 57 ± 17 (Covas ve diğ., 2019). Bu durumun Maunder Minimumundan itibaren en zayıf Güneş Aktivitesi olacağını belirtmektedir.

Bazı çalışmalar ise bunun tam aksini ifade etmektedir. 25. Güneş Çevriminin GLS maksimumu 24. Güneş Çevriminden %16 (Pesnell ve Schatten, 2018), %24 (Kakad ve diğ., 2020), %30 (Du 2020), %32 (Sarp ve diğ., 2018) ve %45 (Li ve diğ., 2018) daha yüksek olacağı tahmin edilmiştir. Han ve Yin (2019) GLS 228,8 ± 40,5 oldukça büyük bir değer önermiştir. Bunlarla beraber 25. Güneş çevrimi maksimumunun 24. Güneş çevrimine benzer olacağını tahmin eden bazı çalışmalar da bulunmaktadır (%10'dan daha az) (Bhowmik ve Nandy, 2018; Jiang ve diğ., 2018; Okoh ve diğ., 2018; Upton ve Hathaway, 2018; Lee, 2020).

Çeşitli yöntemlerle tahmin edilen 25. Güneş Çevriminin maksimumunun oldukça düşük bir değer olan 50'den 228 gibi çok büyük bir değere kadar değiştiği görülmektedir (Wu ve Qin, 2021).

Sonuçlar

1- 25. Güneş Aktivite Çevriminin tahmin edilmesi için SILSO, GFZ-Postdam, NOAA, Penticton Gözlemevi kaynaklarından alınan GLS, POS, $F_{10.7}$, TGI parametrelerinin her biri için 532 veri kullanılmıştır.
2- Bu verilerin diğer analiz yöntemlerinden farklı olarak en düşük istatistiksel hata değerine sahip olana kadar tahmin tekrarlaması yapan NARX sinir ağları yöntemi kullanılmıştır.
3- Kullandığımız yöntemde GLS verileri için yapılan toplam 13 modelden en iyi sonucu veren üç model Model3_NARX, Model7_NARX (Şekil 4.1) ve SSN_NARX'tir (Şekil 4.2).
4- Bu modellerle sırasıyla; 104,58; 113,31; 114,1 maksimum GLS değerleri; Mayıs 2024; Nisan 2026; Temmuz 2025 tarihleri tahmin edilmiştir (Tablo 4.1).
5- Elde edilen sonuçlar, Bhowmik ve Nandy (2018): 118; Dani ve Sulistiani (2019): 110,2; Du ve Du (2006); Helal ve Galal (2013): 118,2; NOAA (2019): 115; Pishkalo (2008): 112,3; Sarp ve Kılçık (2018): 119,6; Benson ve diğ., (2020): 106; Chowdhury ve diğ., (2021): 100,21 uyumludur (Ek 1.).

6- Tahmin sonuçlarımız aynı zamanda 25. Güneş Çevrimin bir Gnevyshev Boşluğu'nu da içereceğini göstermektedir. GLS parametresi için I. Maksimum değeri ve tarihi: 96,18 (Mayıs 2023); II. Maksimum değeri ve tarihi: 114.1 (Temmuz 2025), POS parametresi için I. Maksimum değeri ve tarihi: 200 (Eylül 2023); II. Maksimum değeri ve tarihi 220 (Mayıs 2025), TGI parametresi için I. Maksimum değeri ve tarihi: 1361,4 W/m^2 (Şubat 2023); II. Maksimum değeri ve tarihi: 1361,6 W/m^2 (Nisan 2026), $F_{10.7}$ parametresi için I. Maksimum değeri ve tarihi: 153,8 sfu (Şubat 2023); II. Maksimum değeri ve tarihi: 168,54 sfu (Nisan 2025) olarak tahmin edilmiştir (Tablo 4.2).

7- Yer manyetik Ap indeksi için yapılan tahminlerde I. Maksimum 13,77 nT (Mayıs 2023) ve II. Maksimum 15,01 nT (Kasım 2028) sonuçları elde edilmiştir (Tablo 4.4, Şekil 4.7).

KAYNAKLAR

- Ahmed, U. M. R., Anwar, H., Shah, A. A., et al., 2019, Efficient Water Quality Prediction Using Supervised Machine Learning, *Water*, 11 (11), 2210.

- Antia, H. M., Basu, S., Chitre, S. M., 1998, Solar internal rotation rate and the latitudinal variation of the tachocline, *Monthly Notices of Royal Astronomical Society*, 298, 543-556.

- Antia, H. M., Basu, S., 2011, Revisiting the Solar Tachocline: Average Properties and Temporal Variations, *The Astrophysical Journal Letters*, 735, L45.

- Antia, H. M., Basu, S., 2019, Changes in solar rotation over two cycles, *The Astrophysical Journal*, 883, 93.

- Aschwanden, M. J., 2014, *Encyclopedia of the Solar System (3rd Edition)*, Elsevier, 235 – 259.

- Astronomy Picture of the Day, 2019, The Space Station Crosses a Spotless Sun, https://apod.nasa.gov/apod/image/1907/SpotlessSunIss_Colacurcio_2048.jpg,

  [Ziyaret Tarihi: 07.06.2021]

- Attia, A., Ismail, H., Basurah, H. 2012, A Neuro-Fuzzy modeling for prediction of solar cycles 24 and 25. *Astrophysics and Space Science*. 344. 10.1007/s10509-012-1300-6.

- Balogh, A., Hudson, H.S., Petrovay, K., 2015, *Solar Activity Cycle*, Springer.

- Bartels, J., Heck, N. H., Johnstone, H. F., 1939, The three-hour-range index measuring geomagnetic activity, *J. Geophys. Res*., 44, 411.

- Basu, S., and Antia, H. M., 2003, Changes in Solar Dynamics from 1995 to 2002, *The Astrophysical Journal*, 585, 553-565.

- Beer, J., 2000, Long-term indirect indices of solar variability, *Space Science Reviews*, 94, 53 - 66.

- Benson, B., Pan, W., Prasad, A., 2020, Forecasting Solar Cycle 25 Using Deep Neural Networks. *Solar Physics*. 295. 10.1007/s11207-020-01634-y.

- Bhowmik, P., Nandy, D. Prediction of the strength and timing of sunspot cycle 25 reveal decadal-scale space environmental conditions. *Nat Commun* **9,** 5209 (2018). https://doi.org/10.1038/s41467-018-07690-0.

- Bisoi, S., Janardhan, P., Ananthakrishnan, S., 2020, Another Mini Solar Maximum in the Offing: A Prediction for the Amplitude of Solar Cycle 25. *Journal of Geophysical Research: Space Physics*. 125. 10.1029/2019JA027508.

- Boğazlıyan, M., 2015, Time Series Analysis of Turkish Exports of Selected ORES and Concentrates, M. Sc., The Graduate School of Natural and Applied Sciences of Middle Technical University, METU (ODTÜ).

- Bornmann, P. L., Speich, D., Hirman, J., Matheson, L, Grubb, R., Garcia, H. A., Viereck, R., 1996, GOES x-ray sensor and its use in predicting solar-terrestrial disturbances, *Proc. SPIE 2812, GOES-8 and Beyond*, https://doi.org/10.1117/12.254076.

- Boussaada, Z.; Curea, O.; Remaci, A., 2018, Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation, *Energies*, 11, 620. https://doi.org/10.3390/en11030620

- Carrington, R. C., 1859, Description of a Singular Appearance seen in the Sun on September 1, 1859, *Monthly Notices of Royal Astronomical Society*, 20, 13.

- Chowdhury, P., Jain, R., Ray, P., ve diğ., 2021. Prediction of Amplitude and Timing of Solar Cycle 25. Solar Physics. 296. 10.1007/s11207-021-01791-8.

- Conway, A. J., Macpherson, K. P., Blacklaw, G., Brown, J. C., 1998, A neural network prediction of solar cycle 23, *J. Geophys. Res.*, 103(A12), 29733– 29742, doi:10.1029/98JA02539.

- Cortie, A.L.: 1901, *The Astrophysical Journal*, 13, 260. DOI: 10.1086/140816.

- Courgeau, D., Bijak, J., Franck, R., et al., 2016, *Model-Based Demography: Towards a Research Agenda.* 10.1007/978-3-319-32283-4_2.

- Covas, E., Peixinho, N., ve Fernandes, J. (2019). Neural Network Forecast of the Sunspot Butterfly Diagram. *Solar Physics, 294*, 1-15.

- Dani, T., Sulistiani, S., 2019, Prediction of maximum amplitude of solar cycle 25 using machine learning. *Journal of Physics: Conference Series.* 1231. 10.1088/1742-6596/1231/1/012022.

- Diaconescu, E., 2008, The use of NARX neural networks to predict chaotic time series, WSEAS Transactions on Computer Research,3.

- Di Piazza, A., Di Piazza, M. C., ve Vitale, G., 2016, Solar and wind forecasting by NARX neural networks, Renewable Energy and Environmental Sustainability, 1, 39, 10.1051/rees/2016047.

- Du, Z., 2020, "Predicting the Shape of Solar Cycle 25 Using a Similar-Cycle Method", *Solar Physics*, vol. 295, no. 10. doi:10.1007/s11207-020-01701-4.

- Du, Z., Du, S., 2006, The Relationship Between the Amplitude and Descending Time of a Solar Activity Cycle, *Solar Physics*. 238. 431-437. 10.1007/s11207-006-0175-5.

- Eğrioğlu, E., Yolcu, U., Baş, E. 2020. "Yapay Sinir Ağları", İkinci Baskı, Nobel Yayınevi, İstanbul.

- Fausset, L. V. 1994. "Fundamentals of neural networks: architecture, algorithms and applications", Prentice Hall.

- Fletcher, L., Hudson, H., Cauzzi, G., et al.,20112, Splinter Session: Solar and Stellar Flares, *16th Cambridge Workshop on Cool Stars, Stellar Systems, and the Sun. ASP Conference Series, Vol. 448, proceedings of a conference held August 28- September 2, 2010 at the University of Washington, Seattle, Washington. Edited by Christopher M. Johns- Krull, Matthew K. Browning, and Andrew A. West. San Francisco: Astronomical Society of the Pacific*, 441.

- Franknoi, A., Morrison, D., Wolff, S. C., 2017, *Astronomy*, OpenStax, ISBN: 978-1-947172-24-1.

- Garaud, P., 2020, The Tachocline Revisited, Dynamics of the Sun and Stars, In: Monteiro M.J.P.F.G., García R.A., Christensen-Dalsgaard J., McIntosh S.W. (eds), Astrophysics and Space Science Proceedings, vol 57. *Springer*, https://doi.org/10.1007/978-3-030-55336-4_29.

- 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., Yin, Z.Q., 2019, A Decline Phase Modeling for the Prediction of Solar Cycle 25, *Solar Physics*, 294, 107.

- Hathaway, D., 2015, The Solar Cycle, *Living Reviews of Solar Physics*, 12, 4.

- Haykin, S., 1999, *Neural Networks*, Second Edition, Pearson Education

- Helal, R., Galal, A.A.., 2013, An early prediction of the maximum amplitude of the solar cycle 25, *Journal of Advanced Research.* 4. 275–278. 10.1016/j.jare.2012.10.002.

- Hodgson, R., 1859, On a curious Appearance seen in the Sun, *Monthly Notices of Royal Astronomical Society*, 20, 15.

- Kakad, B., Kumar, R. ve Kakad, A., 2020, Randomness in Sunspot Number: A Clue to Predict Solar Cycle 25, *Sol Phys*, **295,** 88. https://doi.org/10.1007/s11207-020-01655-7.

- Käpylä, P. J., Mantere, M. J., Brandenburg, A., 2012, Cyclic magnetic activity due to turbulent convection in spherical wedge geometry, *The The Astrophysical Journal Letters*, 755 (1), L22.

- Kitiashvili, I. N., 2020, Application of Synoptic Magnetograms to Global Solar Activity Forecast, *The Astrophysical Journal*, 890 (1), doi:10.3847/1538-4357/ab64e7.

- Kosovichev, G. A., 1996, Helioseismic Constraints on the Gradient of Angular Velocity at the Base of the Solar Convection Zone, *The Astrophysical Journal*, 469, L61.

- Labonville, F., Charbonneau, P., Lemerle, A., 2019, A Dynamo-based Forecast of Solar Cycle 25, *Solar Physics*, 294. 10.1007/s11207-019-1480-0.

- Lang K.R., 2001, *The Cambridge encyclopedia of the Sun*, Cambridge University Press.

- Lee K., Moon Y. J., Lee J. Y., Lee K. S., Na H., 2012, Solar Flare Occurrence Rate and Probability in Terms of the Sunspot Classification Supplemented with Sunspot Area and Its Changes, *Sol. Phys*., 281, 639 – 650.

- Li, K., Feng, W., Li, F.Y., 2015, Predicting the maximum amplitude of solar cycle 25 and its timing, *Journal of Atmospheric and Solar-Terrestrial Physics*, 135. 72-76. 10.1016/j.jastp.2015.09.010.

- Li, F. Y., Kong, D. F., Xie, J. L., et al.., 2018, Solar cycle characteristics and their application in the prediction of cycle 25, *Journal of Atmospheric and Solar-Terrestrial Physics*, 181, 110-115.

- Lin, T., Horne, B.G., Tino, P., et al. 1996, Learning long-term dependencies in NARX recurrent neural networks, *IEEE Transactions on Neural Networks*, Vol. 7, No. 6, pp. 1329-1351
-

- Loomis, E., 1861, On the great auroral exhibition of Aug. 28th to Sept. 4th, 1859 and on auroras generally, 8th article, *American Journal of Science*, 96, 318 – 335.

- Luo, J., Liucun, Z., Kunlun, Z., 2022, Forecasting the 10.7-cm Solar Radio Flux Using Deep CNN-LSTM Neural Networks, *Processes*, no. 2: 262. https://doi.org/10.3390/pr10020262

- Lütkepohl, H. ,2005, New introduction to multiple time series analysis. Berlin ; New York : *Springer*, ISBN: 978-3-540-40172-8.

- Macario-Rojas, A., Smith, K. L., Roberts, P. C. E., 2018, Solar activity simulation and forecast with a flux-transport dynamo, *Monthly Notices of the Royal Astronomical Society*, 479 (3), 3791–3803, https://doi.org/10.1093/mnras/sty1625

- Macpherson, K. P., Conway, A. J., Brown, J. C. 1995. "Prediction of solar and geomagnetic activity data using neural networks*", Journal of Geophysical Research*, 100(A11), 735-744.

- McCulloch, W.S. and Pitts, W.H. (1943) A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5(4), 115–133.

- McIntosh P. S., 1990, The classification of sunspot groups, *Solar Physics*., 125, 251-267.

- Menezes, J. M. P., Baretto, 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., Baretto, G. D. A., 2008, Long-term time series prediction with the NARX network: An empirical evaluation, *Neurocomputing, 71*, 3335 – 3343.

- Moore, R. L., Sterling, A. C., Hudson, H. S., Lemen, J. R., 2001, Onset of the Magnetic Explosion in Solar Flares and Coronal Mass Ejections, *The Astrophysical Journal*, 552 (2), 833 – 848.

- Moriasi, D., Arnold, J., Van Liew, M., et al., 2007, Model evaluation guidelines for systematic quantification of accuracy in watershed simulations, *Transactions of the ASABE, 50*, 885-900.

- NASA, 2009, Sunspots at Solar Maximum and Minimum, https://earthobservatory.nasa.gov/images/37575/sunspots-at-solar-maximum-and-minimum?src=ve, [Ziyaret Tarihi: 07.06.2021].

- NASA, 2022, Solar Cycle Progression and Forecast, www.nasa.gov/msfcsolar [Ziyaret Tarihi: 02.06.2022]

- Nash, J. E., Sutcliffe, J. V., 1970, River flow forecasting through conceptual models: Part 1. A discussion of principles. J. Hydrology 10(3): 282-290.

- Okoh, D. I., Seemala, G. K., Rabiu, A. B., 2018, A Hybrid Regression-Neural Network (HR-NN) method for forecasting the solar activity, *Space Weather*, 16, 1424– 1436. https://doi.org/10.1029/2018SW001907

- Owens, M. J., Lockwood, M., Hawkins, E., et al., 2017, The Maunder Minimum and the Little Ice Age: an update from recent constructions and climate solutions, *Journal of Space Weather and Space Climate*, 7 (10).

- Öztemel, E., 2003, *Yapay Sinir Ağları*. İstanbul: Papatya, 15-18.

- Ökten, A., Gültekin Annak, A., 2020, 24. Güneş Leke Aktivite Çevriminin Karakteristik Özellikleri, Turkish Journal of Astronomy and Astrophysics, 1 (2), 455-456.

- Pala, Z., ve Atıcı, R., 2019, Forecasting Sunspot Time Series Using Deep Learning Methods, *Solar Physics*. 294. 10.1007/s11207-019-1434-6.

- Parker, E. N., 1955, The Formation of Sunspots from Suns Toroidal Field, *The Astrophysical Journal,* 121, 491.

- Passos, D., and Charbonneau, P., 2014, Characteristics of magnetic solar-like cycles in a 3D MHD simulation of solar convection, *Astronomy and Astrophysics*, 568, A113, 16
  DOI: 10.1051/0004-6361/201423700.

- Pesnell, W., Schatten, K., 2018, An Early Prediction of the Amplitude of Solar Cycle 25. *Solar Physics*. 293. 10.1007/s11207-018-1330-5.

- Peter, H., 2001, On the nature of the transition region from chromosphere to the corona of the Sun, *Astronomy and Astrophysics*, 374, 1108 – 1120.

- Petrovay, K, 2010, Solar Cycle Prediction, *Living Reviews in Solar Physics* ,**7,** 6. https://doi.org/10.12942/lrsp-2010-6.

- Pishkalo, M., 2008, Preliminary Prediction of Solar Cycles 24 and 25 Based on the Correlation Between Cycle Parameters. *Kinematics and Physics of Celestial Bodies*. 24. 242-247. 10.3103/S0884591308050036.

- Prasad, A., Roy, S., Sarkar, A., et al., 2022, Prediction of solar cycle 25 using deep learning based long short-term memory forecasting technique, *Advances in Space Research*, 69 (1), 798–813, 2022. doi:10.1016/j.asr.2021.10.047.

- Rigozo, N. Pereira de Souza Echer, M., ve Evangelista, H., et al., 2011, Prediction of sunspot number amplitude and solar cycle length for cycles 24 and 25, *Journal of Atmospheric and Solar-terrestrial Physics - J ATMOS SOL-TERR PHYS,* 73, 1294-1299. 10.1016/j.jastp.2010.09.005.

- Sansa, I., Najiba, M. B., 2018, Solar Radiation Prediction Using NARX Model. 10.5772/intechopen.70570.

- Sarp, V., Kılçık, A., 2018, Nonlinear Prediction of Solar Cycle 25, Poster.

- Sarp, V., Kilcik, A., Yurchyshyn, V., 2018, Prediction of the solar cycle: a non-linear approach, Astrophys. Space Sci., 365(6), 2981– 2985.

- Schmutz, W. K., 2021, Changes In the Total Solar IrradIance and clImatIc effects**,** J. *Space Weather Space Clim.,* 11, 40.

- Schou, J., Antia, H. M., Basu, S., et al., 1998, Helioseismic Studies of Differential Rotation in the Solar Envelope by the Solar Oscillations Investigation Using the Michelson Doppler Imager, *The Astrophysical Journal,* 505 (1), 390 – 417.

- Schreiber, R., 2007, MATLAB. *Scholarpedia*, 2 (7), 2929.

- Singh, A., Bhargawa, A., 2019, Prediction of declining solar activity trends during solar cycles 25 and 26 and indication of other solar minimum, *Astrophysics and Space Science*. 364. 10.1007/s10509-019-3500-9.

- Stix, M., 2003, On the time scale of energy transport in the Sun, *Solar Physics*, 212, 3–6.

- Strong, K., Saba, J. Kucera, T., 2012, Understanding Space Weather: The Sun is a Variable Star, *Bulletin of the American Meteorological Society*, 93(9), 1327-1335.

- Stromgrew, B., 1968, Principles of Stellar Evolution and Nucleosynthesis. McGraw-Hill, 612, ISBN: 9780226109534

- Strugarek, A., Beaudoin, P., Charbonneau, P., Brun, A. S., do Nascimento Jr., J.-D., 2017, Reconciling solar and stellar magnetic cycles with nonlinear dynamo simulations, *Science*, 357 (6347), 185-187.
  DOI: 10.1126/science.aal3999

- Sugiura, M., 1964, Hourly Values of the Equatorial Dst for IGY in Ann. Int. Geophys. Year, Vol. 35 (Oxford: Pergamon), 945.

- Svalgaard, L, 2020, Prediction of Solar Cycle 25, *arxiv: Solar and Stellar Astrophysics.*

- Tezbaşaran, E., Gelbal, S., 2018, Temel Bileşenler Analizi ve Yapay Sinir Ağı Modellerinin Ölçek Geliştirme Sürecinde Kullanılabilirliğinin İncelenmesi, *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 14, 225-252. 10.17860/mersinefd.338879.

- Tsurutani, B. T., Gonzalez, W. D., Lakhina, G. S., Alex, S., The extreme magnetic storm of 1-2 September 1859, *Journal of Geophysical Research*, 108 (A7), 1268. doi:10.1029/2002JA009504

- Upton, L. A., Hathaway, D. H., 2018,. An updated Solar Cycle 25 prediction with AFT: The Modern Minimum, *Geophysical Research Letters*, 45, 8091– 8095. https://doi.org/10.1029/2018GL078387

- Usoskin, I. G., Mursula, K., 2003, Long-Term Solar Cycle Evolution: Review of Recent Developments, *Solar Physics*, 218, 319 – 343.

- Uwamahoro, J., 2008, *Forecasting Solar Cycle 24 Using Neural Networks*, Yüksek Lisans, Rhodes University, Faculty of Science.

- Waldmeier M., 1938, *Chromospäriche Eruptionen I. Mit 6 Abbildungen*, Zeitschrift für Astrophysik, 16, 276.

- Wolf, R., 1877, *Geschichte der Astronomie*, vol. 16 of Geschichte der Wissenschaften in Deutschland. Neuere Zeit, Oldenbourg, München..

- Wood, T. S., and Brummel, N. H., 2018, A Self-consistent Model of The Solar Tachocline, *The Astrophysical Journal*, 853, 97.

- Wu, S. S., Qin, G., 2021, Predicting Sunspot Numbers for Solar Cycles 25 and 26, *arxiv*.

- Vasil, G. M., Julien, K., Featherstone, N. A., 2020, *arxiv: Solar and Stellar Astrophysics*.

- Yılmaz, M. U., 2014, *Performans Ağırlıklı Yöntemlerle Aylık Akımların Tahmini: Orta Fırat Havzası Uygulaması*, Yüksek Lisans, İTÜ Fen Bilimleri Enstitüsü.

EKLER

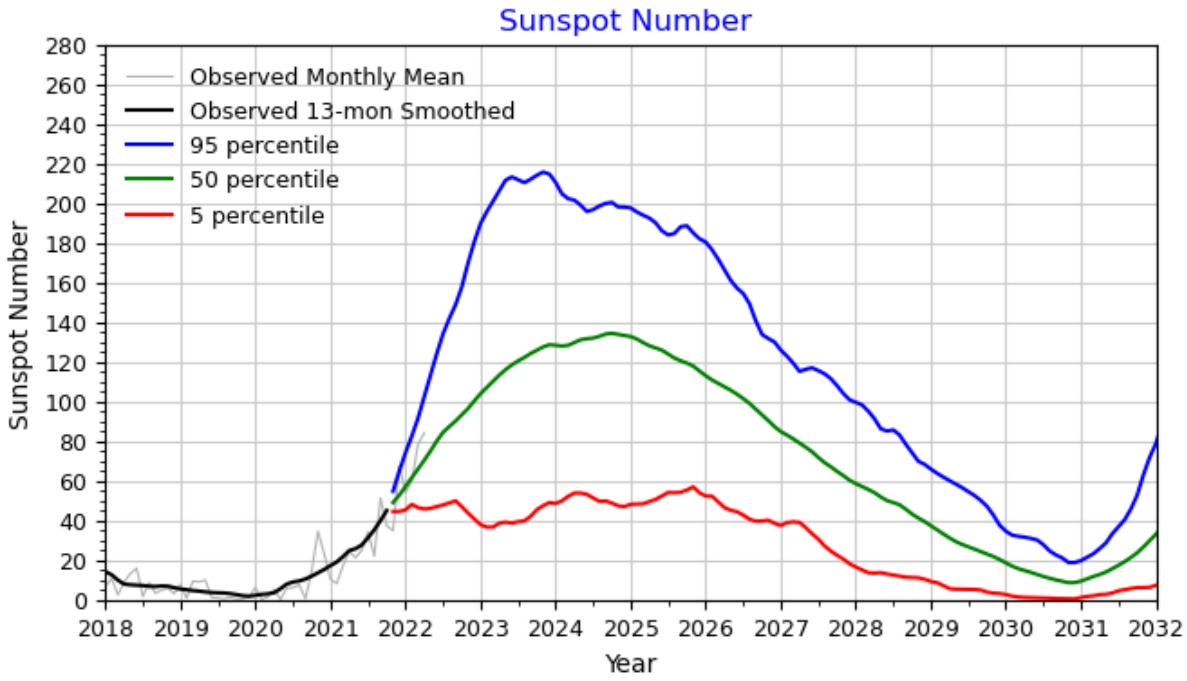
Ek 1.: Literatürdeki çeşitli tahmin yöntemleriyle elde edilen sonuçlar ile tez çalışmasında oluşturulan NARX modellerinin sonuçların karşılaştırılması (GLS cinsinden).

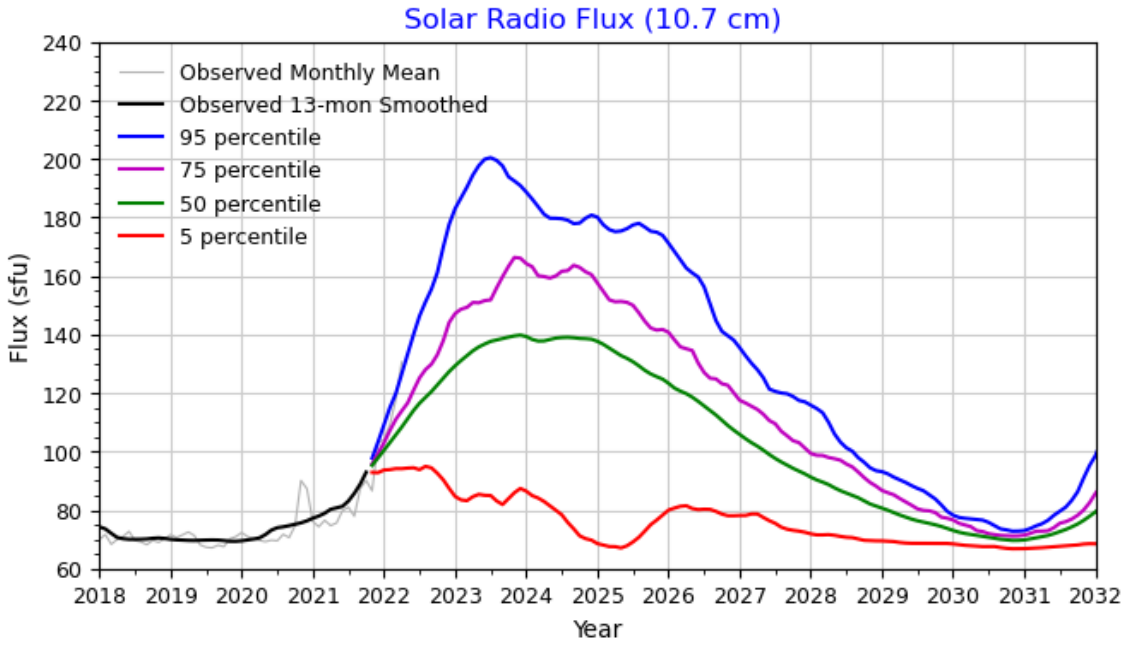
Kaynak	**Tahmin (ler)**	**Metod (lar)**	**Bizim ilgili modelimiz (modellerimiz)**
Attia, Ismail ve Basurah (2013)	90.7 ± 8 (SSN) in 2022	Neuro-Fuzzy Model in Sunspot Numbers (SSN)	SSN_NARX (Yüksek) ve Model4_NARX
Benson ve diğ., (2020)	106 ± 19.75 (SSN) Mayıs 2025	Neural Networks on SSN and Area	Model3_NARX Model10_NARX SSN_NARX (Düşük)
Bisoi ve Janardhan (2020)	76 ± 5 (North) 85 ± 5 (South) $161 \pm$ 7,07 (Total)	Precursor technique on net photospheric magnetic flux	Model12_NARX
Bhowmik ve Nandy (2018)	118 (SSN) 2024	Surface Flux Transport, Internal Dynamo, Century Scale Calibrated Models	Model7_NARX SSN_NARX
Chowdhury ve diğ., (2021)	100.21 ± 15.06 (SSN) Nisan 2025 $\pm$ 6 months	χ^2 Test Analysis in Ap-index, SSN Area	Model3_NARX Model4_NARX
Dani ve Sulistiani (2019)	159.4 ± 22.3 (SSN) Eylül 2023	Linear Regression (LR)	Model12_NARX

	110.2 ± 12.8 (SSN) Aralık 2024 95.5 + 21.9 (SSN) Aralık 2024 93.7 ± 23.2 (SSN) Temmuz 2024	Random Forest Radial Basis Function Support Vector Machine	Model6_NARX Model10_NARX SSN_NARX ve SSN_NARX (Düşük) Model4_NARX Model4_NARX
Du ve Du (2006)	111.6 ± 17.4 (SSN)	Spectral Analysis of SSN	Model6_NARX Model7_NARX SSN_NARX ve SSN_NARX (Düşük)
Du (2020)	137.8 (SSN) October 2024	Similar Cycle	Model2_NARX
Helal ve Galal (2013)	118.2 (SSN) 2022 - 2023	Precursor Technique on Spotless Events	Model7_NARX SSN_NARX
Li, Feng ve Li (2015)	109.1 (SSN) Ekim 2023	Statistical Relations between Solar Cycles	Model6_NARX Model10_NARX SSN_NARX (Düşük)
NOAA (2019)	115 Temmuz 2025	-	Model7_NARX SSN_NARX

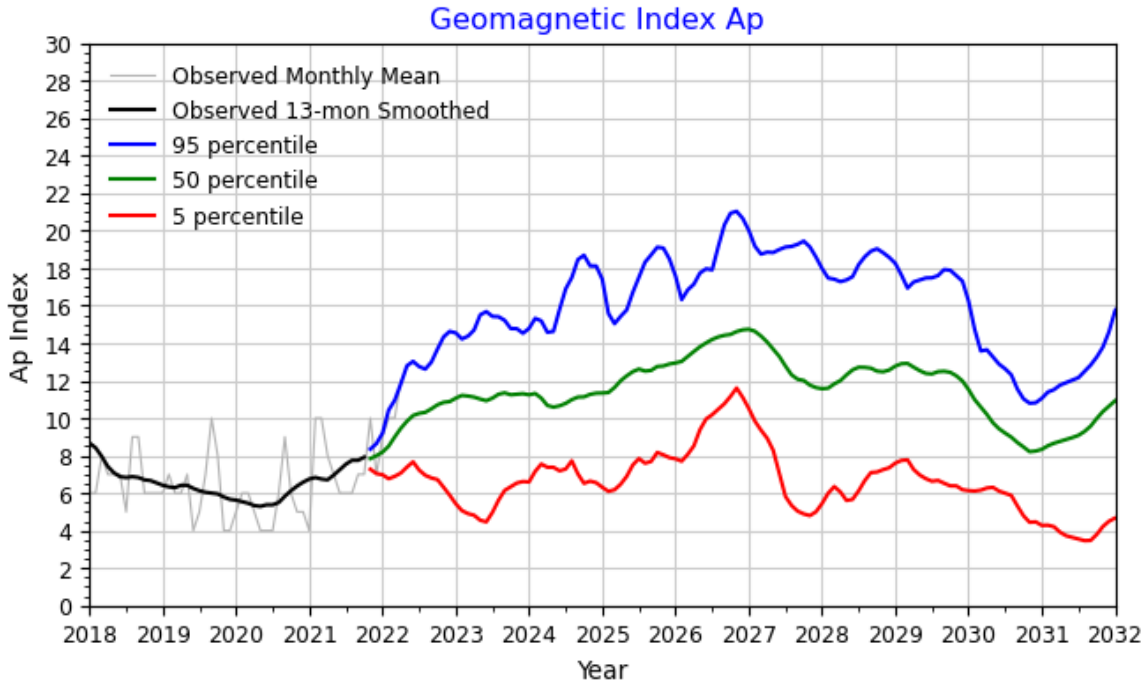
Pala ve Atici (2019)	167.3 (SSN) 2022 -2023	Machine Learning Tool (Using R Language)	Model12_NARX (Fits with Year and Nearly Value SSN)
Pesnell ve Schatten (2018)	135 ± 25 (SSN)	Polar Precursor Method	Model2_NARX
Pishkalo (2008)	112.3 ± 33.4 (SSN) Nisan - Haziran 2023	Regression Analysis of SSN	Model6_NARX Model7_NARX SSN_NARX
Prasad ve diğ., (2022)	171.9 ± 3.4 (SSN) Ağustos 2023 ± 2 ay	Long Short Term Memory (LSTM)	Model12_NARX
Rigozo ve diğ., (2011)	132.1 (SSN) Nisan 2023	Spectral Wavelet Decomposition Tree	Model2_NARX
Sarp ve Kılçık (2018)	119.6 (SSN) Mayıs 2024	Simplex Projection	Model7_NARX SSN_NARX
Singh ve Bhargawa (2019)	89 ± 9 (SSN) Şubat 2024	Hodrick – Prescott Filter on SSN	Model4_NARX SSN_NARX (Yüksek)
Svalgaard (2020)	128 ± 10 (SSN)	Polar Field Precursor	Model2_NARX Model7_NARX SSN_NARX
Upton ve Hathaway (2018)	Similar Solar Cycle 24	Advective Flux Transport Model	Model7_NARX SSN_NARX

Ek 2.: NASA'nın 25. Güneş Çevrimi için GLS, Ap ve $F_{10.7}$ parametreleriyle yaptığı 9 Mayıs 2022 tarihine ait tahmin sonuçları (Tezin tamamlandığı Haziran 2022'de alınan değerler (**www.nasa.gov/msfcsolar**).





Ek 2. Devamı: NASA'nın 25. Güneş Çevrimi için GLS, Ap ve $F_{10.7}$ parametreleriyle yaptığı 9 Mayıs 2022 tarihine ait tahmin sonuçları (Tezin tamamlandığı Haziran 2022'de alınan değerler (**www.nasa.gov/msfcsolar**).

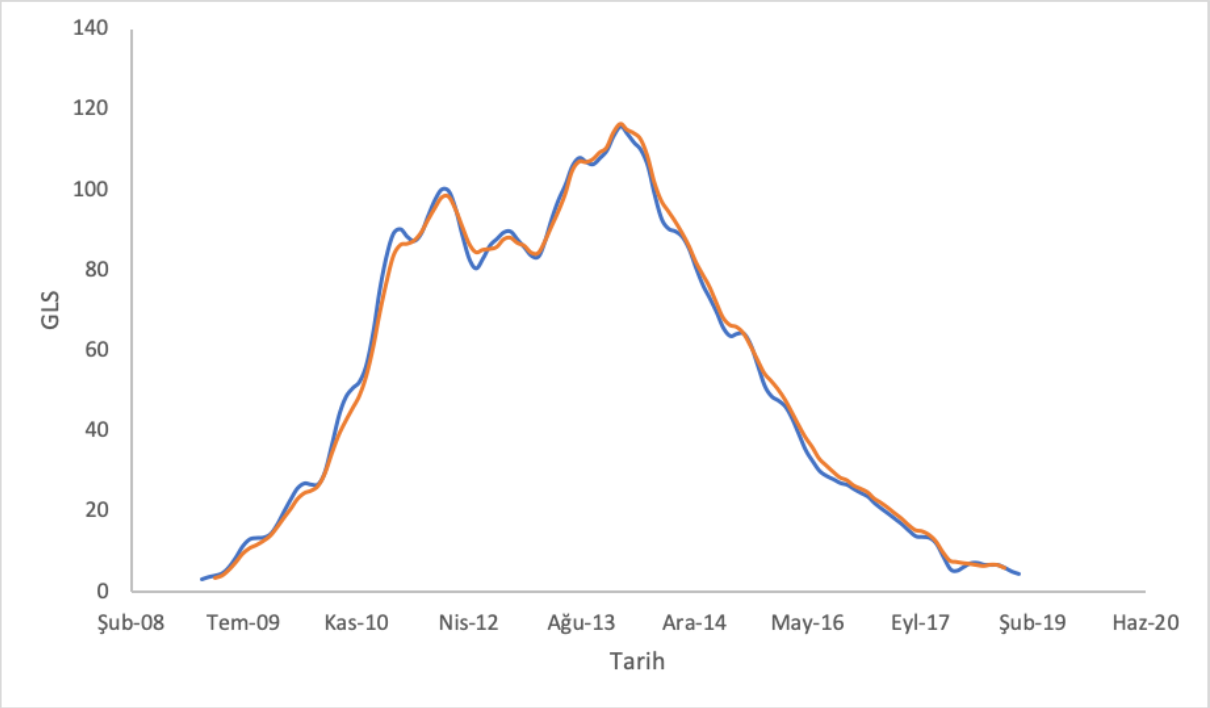


Ek 3.: 21 – 23. Güneş Çevrimlerinin verileriyle 24. Güneş Çevriminin NARX ile tahmini (Model24NARX:). 24. Güneş Çevriminin gerçek değerlerine yakın maksimum değerleri elde edilmiştir.

	Maksimum I	Maksimum II	Öğrenme	Test
Model24NARX	100,7	117,23	0,9997	0,9997
24. Güneş Çevrimi		116,4	-	-

Tez çalışmasında kullanılmış NARX tahmin etme yönteminin doğruluğunu test etmek için 21 – 23. Güneş Çevrimlerinin GLS'nı girdi değerleri olarak kullanıldı ve Model24NARX (Mimari: 1-15-1-3) adlı model ile 24. Güneş Çevrimi'nin maksimum GLS değeri tahmin edildi. Sonuçlar, 24. Güneş Çevriminin gerçek verileri ile karşılaştırıldığında %98 uyumluluk göstermiştir. Dolayısıyla bu tez kapsamında kullandığımız NARX yönteminin Güneş Çevrimlerinin maksimum değerini tahmin etmek için en iyi yöntemlerden biri olduğu düşünülmektedir.

Mavi eğri tahmin, turuncu eğri gerçek verileri göstermektedir.



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Mirkan Yusuf KALKAN
Doğum Yeri	
Doğum Tarihi	Tarih girmek için tıklayın veya dokunun.
Uyruğu	☑ T.C. ❒ Diğer:
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Fen Fakültesi
Bölümü	Astronomi ve Uzay Bilimleri
Mezuniyet Yılı	11.09.2019

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri
Anabilim Dalı	Astronomi ve Uzay Bilimleri
Programı	Astronomi ve Uzay Bilimleri

Doktora	
Üniversite	
Enstitü Adı	
Anabilim Dalı	Anabilim Dalı Adı
Programı	Program Adı

Makale ve Bildiriler
Kalkan, M. Y., Saygaç, A. T., Fawzy, D. E., 2022, NARX Sinir Ağları Yöntemiyle 25. Güneş Aktivite Çevrimi Tahmini, *Turkish Journal of Astronomy and Astrophysics*, 3 (3), 57 -60 . (Astrofizikte Güncel Lisansüstü Çalışmalar Çalıştayı Bildirisi) Kalkan, M. Y., Saygaç, A. T., Fawzy, D. E., 2022, Multi-Parameter Neural Network Prediction for Solar Cycles 25 and 26, *MNRAS* (1 Haziran 2022 yayına gönderilmek üzere hazırlık aşamasında).