

## Güneş Işınım Tahmininde NARX Modelinin Uygulanması

Ali Sarı\*<sup>1</sup>, Muzaffer Aktaş<sup>2</sup>, Ahmet Yönetken<sup>3</sup>, Rasim Doğan<sup>3</sup>

<sup>1</sup>Radyo ve Televizyon Üst Kurulu, Ankara.

<sup>2</sup>Türkiye Petrolleri AO, Ankara.

<sup>3</sup>Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, Afyonkarahisar.

e-posta: [alisari06@gmail.com](mailto:alisari06@gmail.com) ORCID ID: <https://orcid.org/0000-0003-4070-5040>

e-posta: [muzaffer2580@gmail.com](mailto:muzaffer2580@gmail.com); ORCID ID: <https://orcid.org/0000-0002-7444-3512>

e-posta: [ayonetken@aku.edu.tr](mailto:ayonetken@aku.edu.tr); ORCID ID: <https://orcid.org/0000-0003-1844-7233>

e-posta: [rasimdogan@aku.edu.tr](mailto:rasimdogan@aku.edu.tr); ORCID ID: <https://orcid.org/0000-0003-2122-9528>

Geliş Tarihi:06.11.2020

; Kabul Tarihi: 15:01.2021

### Öz

Elektrik enerjisi üretiminde, fosil yakıtlardan yenilenebilir enerjiye doğru, bir geçiş söz konusudur. Bu enerji kaynaklarından biri de güneş panelleridir. Güneş panellerinden üretilen enerji ise güneş ışınım miktarıyla doğrudan bağlantılıdır. Bu sebeple güneş ışınım tahmini, üretilecek enerji miktarının talebi karşılamada ihtiyaç duyulan enerjinin bilinmesi ve diğer enerji kaynaklarının ekonomik kullanımını da sağlar. Enerji üretiminde talep tahmininin önceden bilinmesi büyük önem taşımaktadır. Enerji talep tahmininde, birçok yöntem kullanılmaktadır. Bu çalışmada NARX tahmin modeli kullanılarak sıcaklık, nem ve yağış verilerinin değişken olduğu durumlarda güneş ışınımının tahmini incelenmiştir. Bunun için Ankara ili sınırlarından alınan ölçümler kullanılmıştır. En düşük MSE değerleri sıcaklık, nem ve yağış durumları için sırasıyla 0.00407, 0.00507 ve 0.0056 olarak verilmiştir. En başarılı tahminin sıcaklık verisiyle elde edildiği görülmüştür. Simülasyon sonuçları, tablolar halinde verilerek araştırılması yapılmıştır.

### Anahtar kelimeler

Güneş ışınım tahmini, NARX modeli, sıcaklık, nem, yağış.

## Application of NARX Model in Estimation of Solar Radiation

### Abstract

There is a transition from fossil fuels to renewable energy in electrical energy production. One of these energy sources is solar panels. The energy produced by solar panels is directly related to the amount of solar radiation. For this reason, solar radiation prediction provides the knowledge of the energy needed to meet the demand for the amount of energy to be produced and the economical use of other energy sources. It is very important to know the demand forecast in advance in energy production. Many methods are used in energy demand forecasting. In this study, the prediction of solar radiation in cases where temperature, humidity and precipitation data are variable using NARX prediction model has been investigated. For this, measurements taken from the borders of Ankara province were used. The lowest MSE values are given as 0.00407, 0.00507 and 0.0056 for temperature, humidity and precipitation conditions, respectively. It was seen that the most successful estimation was obtained with temperature data. The simulation results are given in tables and researched.

### Keywords

Solar radiation prediction, NARX model, Temperature; Humidity, Precipitation.

© Afyon Kocatepe Üniversitesi

### 1. Giriş

Güneş enerjisi, sonsuz bir kaynağa sahip olması ve çevreye zararlı gaz salınımının bulunmamasından dolayı giderek önemini artıran bir enerji kaynağıdır (Bekun vd., 2019). Elektrik enerjisine

çevrilmesi için güneş panelleri (PV) kullanılmakta ve bu panellerin çıkışında üretilmiş oldukları elektrik enerjisi üzerine düşen ışınım miktarı ile doğrudan ilişkilidir (Hosseini vd., 2019). Işınım ise çeşitli parametrelere bağlı olarak doğrusal olmayan bir

şekilde değişim göstermektedir. Bu sebepten dolayı günlük olarak ne kadarlık bir enerji üretileceği de doğrusal olmayan bir şekilde değişmektedir. Bu değişimlerin önceden tahmin edilebilmesi ise güç sisteminin arz-talep dengesini, yani kararlılığını ve sürekliliğini sağlamak adına önemlidir. Tahmin modellerinde ise yapay sinir ağı kullanımı ön plana çıkmaktadır.

Yapay sinir ağları günümüzde hemen hemen her alanda kullanılmaya başlanmıştır(Akarıslan and Doğan, 2020; Khan vd., 2020). İnsan beyninin kurduğu bağlantıları taklit etmek üzere yapılandırılan yapay sinir ağlarında çeşitli algoritmalar mevcuttur(Zupan, 1994). Girdiler ile çıktılar arasındaki korelasyonu hesaplayabilen ve aynı girdiyle bir daha karşılaştığında ya da aynı girdiye benzer durumlar ile karşılaştığında bu korelasyonu kullanarak yeni durum hakkında gerçekçi sonuçlar ortaya koyabilen bir sistem olarak tasarlanmıştır(Priddy and Keller, 2005). Yapay sinir ağlarının bu üstün özelliği, yenilenebilir enerji için çok önemli olan güneş ışınım verisinin tahmininde de kullanılmıştır(Boussaada vd., 2017, 2018; Nazaripouya vd., 2016).Burada, harici girdi olarak solar panel gücü(Nazaripouya vd., 2016), bulutsuz durum için hesaplama ve bulutlu durum için ise bulutluluk ölçümü(Boussaada vd., 2017), bir öncekine ek olarak solar radyasyonun meteorolojik ölçümleri (Boussaada vd., 2018)kullanılmıştır. Zaman serisi için çok iyi bir tahmin modeli olan Nonlinear autoregressive with external input (doğrusal olmayan otoregresif eksojen model)NARX,güneş ışınım verilerinin de zaman bağımlı olmasından dolayı,bu tahminlerde ön plana çıkmakta ve sıklıkla ölçümü yapılan meteorolojik parametreler girdi olarak kullanılmıştır.Sıcaklık, nem,rüzgâr hızı (Bounoua and Mechaqrane, 2018)ve sıcaklık, nem, yağış miktarı, güneş açıları, basınç, rüzgâr hızı ve yönü (Ahmad vd., 2015)girdi parametresi olarak kullanıldığı 2 farklı makalede NARX'in başarılı sonuçlar verdiği ortaya konulmuştur. Ayrıca, sıcaklık, nem ve güneşlenme süresi girdi parametresi olarak kullanılan farklı öğrenme algoritmaları karşılaştırılmış ve en başarılı algoritma olarak da Levenberg-Marquardt

(LM)algoritması ortaya konulmuştur(Mohanty vd., 2016).

NARX modeli sadece dışarıdan girdi ile değil daha önceki zaman verilerini de kullanabilmekte ve bu şekilde yapılan güneş paneli çıkış gücü tahminlerinde %99 üzerinde başarı elde edilmiştir (Louzazni vd., 2020).

NARX modeli, ayrıca trafo sargılarının termal analizi(Aşkin vd., 2011), yeraltı sularının seviyesinin tahmini(Di Nunno and Granata, 2020), atmosferik değişkenlerin deniz seviyesine etkisi(Zubier and Eyouni, 2020), enerji tüketimi(Ruiz vd., 2016), rüzgâr hızının tespiti (Cadenas vd., 2016; Karasu vd., 2017) ve hatta kan şekerinin tahmini (Cheng vd., 2020)gibi birçok yerde kullanılmış ve başarılı sonuçlar elde edilmiştir.

Bu makalede, NARX modeli kullanılarak güneş ışınım şiddetinin tahmin edilmesi üzerine durulmuştur. Burada ışınım verisi tahminlerinde harici girdi olarak sıcaklık, nem ve yağış faktörlerinden faydalanılmıştır. Ankara ili Ayaş ilçesi için Meteoroloji Genel Müdürlüğü'nden alınan veriler kullanılarak tahminler yapılmış ve sonuçlar karşılaştırılmıştır. Girdiler ile çıktılar arasındaki bağıntılar incelenmiş ve sonuçlar ortaya konmuştur.

Çalışmada kullanılan materyal ve metotlar tarif edilmiştir. 3. Bölüm de ise bulgular tablolar halinde ortaya konulmuştur. 4. Bölüm de bulgular üzerine değerlendirmeler yapılmıştır. 5. Bölüm de ise sonuçlar ve öneriler verilmiştir.

## 2. Materyal ve Metot

Bu çalışmada, NARX modelde sıcaklık, nem ve yağış verilerini harici veri olarak kullanımı ile ışınım verilerinin tahmin edilmesi üzerinde durulmuştur.

Zaman serisi modellemesinde, NARX modeli harici girdilere sahip bir modeldir. Burada, dizinin son değeri; önceki değerlerinin bir sabit terimin ve bir hata teriminin doğrusal bir fonksiyonudur. Bu modelde aynı seriye ait, geçmiş değerler ile bu seriye etkisi olduğu değerlendirilen harici diğer


veriler, bir arada regresyona tabi tutularak tahmin yapılmaktadır. Seri-paralel (1) ve paralel (2) olarak iki farklı mimariye sahiptir ve aşağıdaki eşitliklerde matematiksel olarak ifade edilmiştir.

$$\hat{y}(t+1) = F(y(t), y(t-1), \dots, y(t-n_y), x(t+1), x(t), z(t-1), \dots, x(t-n_x)) \quad (1)$$

$$\hat{y}(t+1) = F(\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-n_y), x(t+1), x(t), z(t-1), \dots, x(t-n_x)) \quad (2)$$

Burada  $F()$  haritalama fonksiyonu ve  $\hat{y}$  NARX çıkışını ve  $t$  ise zamanı simgelemektedir.  $y$  ile verilenler ise eskiye dönük gerçek verileri,  $x$  ise NARX girişini,  $n_x$  ve  $n_y$  ise sırasıyla giriş ve çıkış gecikmeleri ifade etmektedir.

Bu çalışma kapsamında şekil 1’de gösterildiği gibi, giriş katmanında geçmiş ışınım verileri ( $y(t)$ ) ile sıcaklık, nem ve yağış verileri ( $x(t)$ ) ayrı ayrı giriş olarak kullanılmıştır. Söz konusu veriler Matlab üzerinden NARX ağına uygulanarak ışınım değeri tahmin edilmeye çalışılmıştır.



Şekil 1. NARX modeli

NARX modeli için Matlab programı kullanılmış ve burada “narxnet” fonksiyonu ile bir dizi paralel NARX ağı oluşturulmuştur. Giriş ve çıkış katmanlarındaki nöron sayıları durumdan duruma göre farklılık gösterebilmektedir. Bu sebeple gizli katman nöron sayısı, deneme yanılma yöntemiyle belirlenmiştir. Gizli katmanda, birbirinden farklı değerler kullanılarak optimum sistem performansı tespit edilmeye çalışılmıştır.

Eğitim fonksiyonu için “trainlm” modeli kullanılmıştır. Bu model, veri dizisinde tahmin edilen değeri ve komşu değerlerini LM optimizasyonuna göre güncelleyen bir ağ eğitim işlevidir. LM algoritması ise optimal bir çözüm için hem “Gauss-Newton” hem de “steepest descent” yaklaşımlarını kullanan hibrit bir tekniktir. Bu

algoritma orta ölçekli -birkaç yüzlük değerler- ileri beslemeli sinir ağlarını eğitmek için en hızlı ve tutarlı yöntem olduğu değerlendirilmektedir. Ayrıca Matlab’da bulunan yerleşik matris mimarisinden dolayı da çok verimli olarak uygulandığı değerlendirilmektedir.

Bu çalışmada, “nz” tipinde belirtilen gecikme değerleri için, “n” zamanından başlayarak “z” zamanındaki elemana kadar olan değerlerin kullanıldığı anlamını taşır.


Aşağıda Ankara ili Ayaş ilçesi sınırlarında elde edilmiş ışınım, nispi nem, sıcaklık ve yağış verileri ayrı başlıklar halinde verilmiştir. Her bir veri, NARX modelinde kullanılmadan önce normalize edilmiştir.

## 2.1 Işınım Verisi

Ankara ili Ayaş ilçesi sınırlarında 40.0300 enlem ve 32.2345 boylam koordinatlarında (bkz. Şekil 2), 2018 yılı içerisinde ölçümlenen ışınım verisi şekil 3’te gösterilmiştir. Buradan da net bir şekilde görülmektedir ki ışınım miktarı yıl içerisinde Güneş’in hareketi ile birlikte paralel bir değişim göstermektedir.




Şekil 2. Ankara ili Ayaş ilçesi Meteoroloji İstasyon Konumu



Şekil 3. Ankara ili Ayaş ilçesi Işınım Verisi

## 2.2 Nispi Nem Verisi


Ankara ili Ayaş ilçesi sınırlarında 2018 yılı içerisinde ölçümlenen nispi nem verisi şekil 3'te gösterilmiştir. Şekil 3 ve şekil 4 birlikte değerlendirildiğinde ışınım miktarının artış gösterdiği zamanlarda nispi nemin azalma eğiliminde olduğu görülmektedir.



Şekil 4. Ankara ili Ayaş ilçesi Nispi Nem Verisi

## 2.3. Sıcaklık Verisi


Ankara ili Ayaş ilçesi sınırlarında 2018 yılı içerisinde ölçümlenen sıcaklık verisi şekil 4'te gösterilmiştir. Şekil 3 ve şekil 5 birlikte değerlendirildiğinde ışınım miktarının artış gösterdiği zamanlarda sıcaklık değerlerinin de arttığı gözlemlenmektedir.



Şekil 5. Ankara ili Ayaş ilçesi Sıcaklık Verisi

## 2.4. Yağış Verisi

Ankara ili Ayaş ilçesi sınırlarında 2018 yılı içerisinde ölçümlenen yağış verisi şekil 5'te gösterilmiştir. Şekil 3 ve şekil 6 birlikte değerlendirildiğinde her iki veri arasında direkt bir ilişki gözlenmemektedir.



Şekil 6. Ankara ili Ayaş ilçesi Yağış Verisi

## 3. Bulgular

NARX modeli kullanılarak ışınım verisinin tahmini yapılmıştır. Burada harici veri olarak sıcaklık, nem ve yağış ayrı ayrı değerlendirilmiştir. Her bir değerlendirme öncesinde veriler normalize edilmiştir. Böylelikle, sıcaklık verisi ile yapılan modelleme sonucunda elde edilen bulgular çizelge 1'de, nem verisi ile elde edilen bulgular çizelge 2'de yağış verisi ile elde edilen bulgular çizelge 3'te gösterilmiştir. Her bir çizelgede gizli katman nöron sayısı (GKNS) ile giriş gecikmesi (ID) ve çıkış gecikmesi (FD) değişimleri sonucu modelin başarısı gözlemlenmiştir. Her bir durum için ortalama karesel hata (MSE), iterasyon sayısı, eğitim R, validasyon R ve test R değerleri hesap edilmiştir. Burada MSE'nin 0'a en yakın olduğu durumda eşleşmenin çok büyük doğruluğa sahip olduğu bilinmelidir.

Çizelge 1. Sıcaklık verisi ile elde edilen bulgular:

GKNS	ID	FD	MSE [10 <sup>-3</sup> ]	İterasyon	Eğitim R	Validasyon R	Test R
10	1_5	1_5	4.57	15	0.96	0.946	0.954
10	1_3	1_3	6.91	35	0.959	0.954	0.952
10	1_4	1_4	5.47	24	0.96	0.962	0.962
10	1_6	1_6	5.82	41	0.964	0.951	0.959
20	1_5	1_5	7.02	17	0.962	0.963	0.951
30	1_5	1_5	5.6	13	0.957	0.956	0.963
40	1_5	1_5	4.97	14	0.963	0.953	0.964
50	1_5	1_5	6.06	12	0.963	0.951	0.959
60	1_5	1_5	5.33	20	0.963	0.958	0.964
100	1_5	1_5	7.03	11	0.967	0.955	0.952

**Çizelge 2.**Nem verisi ile elde edilen bulgular:

GKNS	ID	FD	MSE [10 <sup>-3</sup> ]	İterasyon	Eğitim R	Validasyon R	Test R
10	1_5	1_5	5.07	37	0.961	0.958	0.963
10	1_3	1_3	5.25	22	0.954	0.955	0.965
10	1_4	1_4	6.73	45	0.96	0.956	0.952
10	1_6	1_6	6.13	45	0.964	0.953	0.955
20	1_5	1_5	5.31	17	0.959	0.959	0.962
30	1_5	1_5	5.25	13	0.957	0.962	0.962
40	1_5	1_5	7.01	18	0.966	0.952	0.95
50	1_5	1_5	8.32	13	0.963	0.958	0.943
60	1_5	1_5	6.65	21	0.965	0.959	0.951
100	1_5	1_5	6.76	11	0.964	0.958	0.951

**Çizelge 3.**Yağış verisi ile elde edilen bulgular:

GKNS	ID	FD	MSE [10 <sup>-3</sup> ]	İterasyon	Eğitim R	Validasyon R	Test R
10	1_5	1_5	6.97	22	0.96	0.952	0.949
10	1_3	1_3	6.87	18	0.952	0.958	0.951
10	1_4	1_4	5.32	25	0.954	0.956	0.96
10	1_6	1_6	5.67	19	0.957	0.953	0.961
20	1_5	1_5	8.14	13	0.958	0.95	0.948
30	1_5	1_5	6.04	11	0.956	0.957	0.954
40	1_5	1_5	6.47	11	0.954	0.96	0.957
50	1_5	1_5	6.47	18	0.96	0.954	0.954
60	1_5	1_5	6.96	11	0.961	0.949	0.954
100	1_5	1_5	5.6	13	0.961	0.948	0.961

Çizelge 1’de gösterilen sıcaklık verisinin harici girdi olarak kullanımında en düşük MSE, GKNS’nin 10 ve ID ile FD’nin 1\_5 olduğu durumda ortaya çıkmaktadır. Bu durumda GKNS’nin artırılması ile MSE arasında lineer bir değişimin söz konusu olmadığı görülmektedir. Ayrıca, iterasyon sayısı da lineer değişim göstermemektedir. Aynı durum çizelge 2’de gösterilen nem verisinin harici girdi olarak kullanımında da geçerlidir. Fakat çizelge 3’te gösterilen yağış verisinin harici girdi olarak kullanımında en düşük MSE, GKNS’nin 100 olduğu durumda ortaya çıkmaktadır. Bu durumda bile sıcaklık ve nem verisinin harici veri olduğu durumlardan daha yüksek MSE değerine sahiptir.

İterasyon sayısı, seçilen değerlere göre öğrenmenin durdurulduğu iterasyonu göstermektedir. Dolayısıyla seçimler değiştiğinde, iterasyon sayısında da değişimler söz konusu olmaktadır. Bu

değişimler, GKNS, ID ve FD’ye bağlı olarak öngörülebilir değildir. Ayrıca, verilen R değerleri arasında yakın değerlerin olması NARX modelinin tutarlı sonuçlar ortaya koyduğunu göstermektedir.

#### 4. Tartışma

Elektrik enerjisinin büyük güçler açısından depolanmasının zorluğu ve yatırım maliyetinin yüksek oluşundan dolayı, üretim tahminlerinin önceden yapılmasını zorunlu hale getirmektedir. Bu konuda, birçok araştırma ve enerji tahmin modelleri yapılmaktadır. Güneş ışınım tahminlerinde NARX modelinin kullanılması harici girdi verisinin türüne göre farklılık arz etmektedir. Bu modelin uygulanmasında, burada kullanılan veri seti ile başarılı sonuçtur. Sıcaklık ile yapılan en başarısız sonuçlar ise yağış ile elde edilmiştir. Nemin tahminler üzerine etkisi ise sıcaklık verisinden daha düşük olduğu görülmüştür.

Işınımın yüksek olduğu zamanlarda sıcaklığın artması beklenen bir gelişmedir. Fakat sıcaklık her zaman ışınım ile artmamakta bazen farklı sebepler (rüzgârlar vb.) vasıtasıyla da aşağı ya da yukarı yönlü değişebilmektedir. Burada, ışınım ve sıcaklık arasındaki MSE değeri 0.00457 olarak karşımıza çıkmakta ve böylelikle sıcaklığın ışınım verisi tahmininde kullanılmasında diğer verilere göre, daha doğru sonuç verdiği anlaşılmaktadır.

Her ne kadar MSE değerleri arasında fark varsada eğitim, validasyon ve test R değerleri birbirlerine çok yakın çıkmaktadırlar. Bu ise dengeli ve tutarlı sonuçlar olduğuna işaret etmektedir.

NARX modelinin başarısında GKNS ile ID ve FD’yi de göz önüne aldığımızda, GKNS artırıldığında değişken süre ve doğrulukta sonuçlar verdiği gözlenmiştir. Bu durum, ID ve FD değişimi sonucunda da görülmektedir.

#### 5. Sonuç

Bu çalışmada güneş ışınım verisinin tahmini için harici girdi olarak sıcaklık, nem ve yağış verilerinin NARX yapay sinir ağı modelinde kullanılması üzerinde durulmuştur. Çalışmada, Ankara ili Ayaş ilçesinde bulunan istasyonundan alınan gerçek

veriler kullanılmıştır. Bu veriler Matlab programı vasıtasıyla NARX modeline uygulanmıştır.

En iyi sonuç, harici verilerden sıcaklık verisi ile elde edilmiş ve 0.00457 MSE değerine sahiptir. Ayrıca, diğer nem ve yağış harici girdileriyle sırasıyla 0.00507 ve 0.0056 MSE değerine sahiptir.

Makalede kullanılan 1 yıllık veri seti yerine daha uzun zaman dilimi boyunca elde edilen veri seti NARX modelinde kullanılsaydı, hata oranlarının düşmesi ve benzerliklerin artması beklenmektedir.

## Teşekkür

Meteoroloji Genel Müdürlüğüne bu çalışmada kullanılan verileri sağladığından dolayı teşekkür ederiz.

## 5. Kaynaklar

- Ahmad, A., Anderson, T. N., and Lie, T. T., 2015. Hourly global solar irradiation forecasting for New Zealand. *Solar Energy*, 122, 1398–1408.
- Akarşlan, E., and Doğan, R., 2020. Harmonik Sinyallerin Yük Tanımadaki Başarısının İncelenmesi ve Yeni Bir Model Önerisi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 7(1), 452–460.
- Aşkin, D., İskender, İ., and Mamizadeh, A., 2011. Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi. *Gazi Üni. Müh. Mim. Fak. Der.*, 26,4, 905–913.
- Bekun, F. V., Alola, A. A., and Sarkodie, S. A., 2019. Toward a sustainable environment: Nexus between CO2 emissions, resource rent, renewable and nonrenewable energy in 16-EU countries. *Science of the Total Environment*, 657, 1023–1029.
- Bounoua, Z., and Mechaqrane, A., 2018. Prediction of daily global horizontal solar irradiation using artificial neural networks and commonly measured meteorological parameters. *AIP Conference Proceedings*, 2056(1), 020024.
- Boussaada, Z., Curea, O., Remaci, A., Camblong, H., and Mrabet Bellaaj, N., 2018. A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation. *Energies*, 11(3), 620.
- Boussaada, Z., Remaci, A., Curea, O., Camblong, H., Bellaaj, N., Mrabet Bellaaj, N., Professor, A., and Professor, E., 2017. *Prediction of the Daily Direct Solar Radiation Using Nonlinear Autoregressive Exogenous (NARX) Network Model*. 10<sup>th</sup> International Conference on Sustainable Energy and Environmental Protection.
- Cadenas, E., Rivera, W., Campos-Amezcuca, R., and Cadenas, R., 2016. Wind speed forecasting using the NARX model, case: La Mata, Oaxaca, México.

- Neural Computing and Applications*, 27(8), 2417–2428.
- Cheng, J., Ji, Z., Li, M., and Dai, J., 2020. Study of a noninvasive blood glucose detection model using the near-infrared light based on SA-NARX. *Biomedical Signal Processing and Control*, 56, 101694.
- Di Nunno, F., and Granata, F., 2020. Groundwater level prediction in Apulia region (Southern Italy) using NARX neural network. *Environmental Research*, 190, 110062.
- Hosseini, S. A., Kermani, A. M., and Arabhosseini, A., 2019. Experimental study of the dew formation effect on the performance of photovoltaic modules. *Renewable Energy*, 130, 352–359.
- Karasu, S., Altan, A., Saraç, Z., Hacıoğlu, R., and Karasu, S., 2017. Estimation of Fast Varied Wind Speed Based on Narx Neural Network by Using Curve Fitting. In *International Journal of Energy Applications and Technologies*, 4,3.
- Khan, M. M. H., Muhammad, N. S., and El-Shafie, A., 2020. Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting. *Journal of Hydrology*, 590, 125380.
- Louazani, M., Mosalam, H., and Khouya, A., 2020. A non-linear auto-regressive exogenous method to forecast the photovoltaic power output. *Sustainable Energy Technologies and Assessments*, 38, 100670.
- Mohanty, S., Patra, P. K., and Sahoo, S. S., 2016. Prediction of global solar radiation using nonlinear auto regressive network with exogenous inputs (narx). *Proceedings of the 2015 39th National Systems Conference*, 151-157.
- Nazaripouya, H., Wang, B., Wang, Y., Chu, P., Pota, H. R., and Gadh, R., 2016. Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method. *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*.
- Priddy, K., and Keller, P., 2005. *Artificial neural networks: an introduction*. SPIE Press. Bellingham, Washington USA
- Ruiz, L., Cuéllar, M., Calvo-Flores, M., and Jiménez, M., 2016. An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. *Energies*, 9(9), 684.
- Zubier, K. M., and Eyouni, L. S., 2020. Investigating the Role of Atmospheric Variables on Sea Level Variations in the Eastern Central Red Sea Using an Artificial Neural Network Approach. *Oceanologia*, 62(3), 267–290.
- Zupan, J., 1994. Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them. *Acta Chimica Slovenica*, 41.