

Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini

Ömer ÇETİN^{1*}, Ali Hakan IŞIK¹

¹Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Burdur

Geliş Tarihi (Received): 17.07.2022, Kabul Tarihi (Accepted): 27.11.2022

✉ Sorumlu Yazar (Corresponding author*): eng.omercetin@gmail.com

☎ +90 248 2132750 📠 +90 248 2132704

ÖZ

Günümüzde elektrikli cihazların yoğun kullanımı ile elektrige olan ihtiyaç artmıştır. Bu ihtiyacı karşılamak için genellikle fosil yakıtlar kullanılmaktadır. Ancak fosil yakıtların çevreye verdiği zararı azaltmak için hükümetler yenilenebilir enerji kaynaklarına çeşitli teşvikler sunmaktadır. Bu kapsamda güneş enerjisi santrallerine yönelik teşvikler de oldukça fazladır. Son zamanlarda birçok yatırımcı güneş enerjisi santrali kurmak istemektedir. Güneş enerjisi santrali kurmak yüksek yatırım maliyeti gerektirdiğinden amortisman sürelerinin hesaplanabilmesi yatırım kararı vermekte önemli rol oynamaktadır. Teknolojinin gelişmesi, bu maliyetlerin amortisman sürelerini yapay zekâ algoritmaları ile tahmin etmeyi mümkün kılmıştır. Bu çalışmada, gerçek güneş enerjisi santrali verileri kullanılarak, derin öğrenme algoritmaları ile gelecekte üretilebilecek enerji verileri tahmin edilmiştir. Veriler, Humartaş Enerji firmasına ait güneş enerjisi santrallerinden alınmıştır. Çalışmada zaman serisi algoritmalarında yoğunlukla kullanılan LSTM (Long Short-Term Memory, Uzun Kısa Süreli Bellek) yöntemi kullanılarak analizler ve tahminler yapılmıştır. Çalışmanın hata oranı %1 ile %17 arasında olduğu görülmüştür. Bu çalışmanın rüzgâr, hidrolik, jeotermal enerji gibi diğer yenilenebilir enerji kaynakları içinde kullanılabileceği öngörülmektedir.

Anahtar Kelimeler: Enerji tahmini, güneş enerjisi santralleri, LSTM, yapay zekâ, yenilenebilir enerji

Monthly Electricity Production Forecast in Solar Power Plants with Deep Learning

ABSTRACT

Today, with the intensive use of electrical devices, the need for electricity has increased. Fossil fuels are generally used to meet this need. However, to reduce the damage caused by fossil fuels to the environment, governments offer various incentives to renewable energy sources. In this context, incentives for solar power plants are also quite high. Recently, many investors wanted to establish a solar power plant. Since establishing a solar power plant requires high investment costs, the calculation of amortization periods plays an important role in making investment decisions. The development of technology has made it possible to predict the amortization times of these costs with artificial intelligence algorithms. In this study, energy data that can be produced in the future have been estimated with deep learning algorithms using real solar power plant data. The data were taken from solar power plants belonging to Humartaş Energy company. In the study, analyzes and predictions were made using the LSTM (Long Short-Term Memory) method, which is used extensively in time series algorithms. The error rate of the study was found to be between 1% and 17%. It is predicted that this study can be used in other renewable energy sources such as wind, hydraulic, geothermal energy.

Keywords: Energy forecasting, solar power plants, LSTM, artificial intelligence, renewable energy

GİRİŞ

İstikrarlı ve hızlı bir şekilde büyümeye ve kalkınmaya devam eden Türkiye’de artan sanayi faaliyetleri, gelişen teknoloji, artan nüfus nedeniyle enerji tüketiminde her geçen gün artış yaşanmaktadır (Acaroğlu ve Güllü, 2022). Artan tüketime karşılık fosil yakıtlar ile çözümler üretilmeye çalışılmaktadır. Fakat fosil yakıtların karbon emisyonu yüksek olması nedeniyle çevreye verdiği zarar ciddi oranda fazladır. Uluslararası enerji ajansı raporu 2035 yılında enerji kaynaklı CO₂ emisyonlarında %20 artış yaşanacağını öngörmektedir (Dam, 2014).

Karbon emisyonunun büyük çoğunluğuna fosil yakıtlar neden olmaktadır. 2015 yılında yapılan Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi kapsamında, Paris Anlaşması yapılmıştır. 2016 yılında yürürlüğe giren anlaşma ile Türkiye’de yenilenebilir enerji kaynaklarına yatırımı artırmak ve fosil yakıt tüketimini azaltmak istenmiştir. Yatırımlara ciddi oranda teşvik verilmesi ile süreç daha da hızlanmıştır. Bu yatırımlar ile güneş enerji santralleri de büyük oranda teşviklerden yararlanmışlardır.

Ortalama güneşlenme süresi 7 saat 50 dk olarak ölçülen ülkemizde güneş enerji santrallerinin amortisman süresi diğer ülkelere kıyasla daha kısa olduğu görülmektedir (URL-1, 2020). Son zamanlarda yapılan çalışmalara göre toplam kurulu gücün %64’ü yenilenebilir enerji kaynaklarından sağlanmaktadır. Bu gücün %7,2 oranını güneş enerji santralleri oluşturmaktadır. Bu oran gün geçtikçe artmaktadır.

1956 yılında ortaya çıkan ve teknolojinin gelişmesiyle ilerleyen yapay zekâ günlük hayatımızın birçok yerinde karşımıza çıkmaktadır (Moor, 2006). Yapay zekâ, öğrenme, karar verme, tahmin etme gibi insan özelliklerini makinelerin taklit etmesine denir. Kısacası organik beynin yapabileceği işlemleri makinelerin yapabileceğidir. Telefonlarda kullanılan kişisel asistanlar yapay zekâ uygulamasının basit bir örneğidir. Yenilenebilir enerji alanında rüzgâr gücü tahmini, rüzgâr hız tahmini, güneş radyasyon miktarı tahmini, fotovoltaik sistemde güç tahmini, güneş takip sistem algoritmaları, hidrolik enerjide su akış modellemesi, okyanus enerjisinde su seviyesi tahminleri gibi çeşitli yenilenebilir enerji kaynaklarında yapay zekâ uygulamaları bulunmaktadır (AlShabi ve Assad, 2021).

Yaşamımızın her anında ihtiyaç duyduğumuz enerji ile işlerimizi kolaylaştırıp zamanı verimli kullanmamıza olanak sağlayan yapay zekâ, bu çalışma günümüzde popüler olan ve gelecekte de popülerliğini devam ettirecek bu iki alanı birleştirilecek bir çalışma yapılmıştır. Derin öğrenme algoritmalarında kullanılacak verilerin

doğruluk oranının yüksek olması amacıyla bir enerji firmasından alınan veriler kullanılmıştır. Güneş enerji santrallerinin hava durumu, güneşlenme süresi, santral konumu, kullanılan güneş paneli gücü, inverter gücü, çevresinde bulunan yerlerin albedo etkileri kullanılarak yeni kurulacak veya kurulumu tamamlanmış santrallerin aylık ortalama elektrik üretim tahmini yapılmıştır. Tahmin yapabilmek için yapay sinir ağlarından LSTM (Long Short-Term Memory, Uzun Kısa Süreli Bellek) yöntemi kullanılmıştır. Diğer yapay sinir ağlarına kıyasla bellekte veri tutma özelliğinin olması tahmin gücünü artırmaktadır. Bu avantajı kullanarak doğruluk oranı yüksek bir tahmin yapmak amaçlanmıştır. Çalışma sonucunda güneş enerji santrali olan yatırımcılar bir ay önceden elektrik üretim miktarını öğrenebilmeye başlayacaklardır. Kur farklarının fazla olması, artan malzeme ve işçilik maliyetleri nedeniyle güneş enerji santrali kurmak isteyen yatırımcılar, amortisman sürelerini merak etmektedirler. Bu çalışma ile kurulumu yapılacak güneş enerji santrallerinin amortisman süreleri kolaylıkla öğrenilebilecektir. Yazılımın ilerleyen aşamalarında veri toplama işlemleri için bir yazılım yapılması hedeflenmektedir. Bu sayede veriler sürekli eğitilerek tahmin gücü yüksek bir uygulama yapılması hedeflenmiştir.

MATERYAL VE YÖNTEM


Klasik derin öğrenme ağları giriş verileri ile çıkış verileri bağımsız olarak çalışmaktadırlar. Fakat RNN (Recurrent Neural Network, Yinelemeli Sinir Ağı) giriş verileri ile çıkış verilerini etkileyebilmektedir (Sherstinsky, 2020). Örneğin; insanlar bir kelime söylerken nasıl ki önceki deneyimlerine bağlı olarak bir cümlede o kelimeyi tam anlamıyla kullanabiliyorsa RNN yapay sinir ağı da aynı şekilde tahmin yapabilmektedir. RNN yapay sinir ağları kelimeleri anlam bütünlüğü olacak şekilde art arda gelmesini sağlayabilmektedir. RNN önceki yapılan adımların sonuçlarını hafızasında bekletmektedir. RNN’ ler teorik olarak uzun dizilerde (long-sequence) iyi sonuçlar vermesi beklenmektedir. Fakat pratikte gözlemlendiğinde bunun başarısız olduğu görülmektedir. Bu tarz problemlerin üstesinden gelmek için LSTM ve GRU (Geçitlenmiş Özyinelemeli Birimler) gibi ağlar geliştirilmiştir (Sherstinsky, 2020).

Derin öğrenme alanında geliştirilen LSTM yapay bir RNN mimarisidir (YU ve ark., 2019). GAN (Generative Adversarial Networks), CNN (Convolutional Neural Network) yapay sinir ağları ileri besleme mantığı ile çalışmaktadır ancak LSTM geri besleme mantığı ile çalışmaktadır. LSTM, tek veri noktasında değil de tüm veri dizilerinde, örneğin video ve konuşma gibi işlemlerde kullanılabilir.

Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini

LSTM ünitesi, 4 katmandan oluşmaktadır. Bunlar; bir hücre, bir unutmaya kapısı, bir çıkış kapısı ve bir giriş kapısıdır. Hücre, rastgele zaman aralıklarındaki değerleri hatırlamaktadır. Bu üç kapı ise hücreye çıkan ve giren bilgi akışını düzenlemektedirler.

Şekil 1' de LSTM yapısı ve kapıları gösterilmiştir (URL-2, 2015). Durum hücresi değerleri tahmin yapmak için hücreler boyunca taşımaktadır. Bu hücre ağ hafızası ve bir iletişim hattı olarak düşünülebilir. Hücre taşınması ile kısa süreli bellek problemi çözümlenerek önceki veriler ağ boyunca iletebilmektedir (Landi ve ark., 2021). Durum hücresinin taşıdığı önemli verileri kapılar belirleyebilir. Kapılar sayesinde önemli veya önemsiz veriler belirlenebilmektedir. Kapılara gelen veriler sıfır ile bir arasında sigmoid aktivasyon fonksiyonu ile sıkıştırılmaktadır. Aktivasyon sonucunda sıfır olan veriler unutulurken bir olan veriler durum hücresi ile ilerlememektedirler.



Şekil 1. LSTM yapısı

Unutmaya kapısında ne tür bilgilerin unutulacağına ne tür bilgilerinse devam edeceğine karar verilmektedir (Van Der Westhuizen ve Lasenby, 2018). Hücrelerden gelen bilgi (ht) ve hücre içerisinde bulunan bilgi (xt) sigmoid aktivasyon fonksiyonuna girer ve bununla karar verilir. Sıfır olan bilgiler unutulurken bir olan bilgiler durum hücresi ile taşınmaya devam etmektedir.

Giriş kapısı durum hücresi güncellemesi yapmaktadır. Giriş kapısı içerisinde bulunan bilgi ve önceki bilgileri sigmoid aktivasyon fonksiyonuna girer. Bunun sonucunda güncelleme olup olmayacağına karar verilir. Sıfır olan bilgiler önemsiz olarak görülürken. Bir olan bilgiler kullanılmaya devam eder. Aynı zamanda ağı düzenleme (regulate) işlemi için veriyi eksi bir ve bir aralığına sıkıştırılan tanh aktivasyon fonksiyonu da kullanılmaktadır. Sonrasında tanh ve sigmoid fonksiyon çıkışları çarpılarak hangi bilginin güncelleneceğine karar verilmektedir (Pulver ve Lyu, 2017).

Bir sonraki hücrenin girişini (ht+1) çıkış kapısı belirlemektedir. Aynı zamanda bu kapı tahmin yapmak için

de kullanılır. Öncelikle kapıda bulunan bilgi ve geçmişteki bilgi sigmoid fonksiyonunda geçirilmektedir. Sonrasında durum hücresi üzerinde mevcut olan veri tanh fonksiyonundan geçirilmektedir. Son olarak iki sonuç çarpılarak bir sonraki hücre için hangi verilerin giriş (ht+1) hücresi olacağı kararlaştırılır. Kapı işlemleri tamamlandığında bir sonraki hücreye gidecek olan durum hücresi ve hücrenin giriş bilgisi olarak tanımlanan Hidden State (ht) bilgilerine karar verilmiş olur.

Yapılan çalışmada yinelemeli sinir ağlarından LSTM yöntemi kullanılmıştır. Geçmiş yıllardaki enerji verileri kullanarak bir zaman serisi içerisinde yeni elektrik üretim verileri tahmin edilmiştir. Geçmiş yıllara ait veriler bir enerji firmasından alınmıştır ve güneş enerji santrallerinde enerji kaybını etkileyen faktörlere bakılarak veriler seçilmiştir. En önemli faktörlerden enerji veri tarihi (ay-yıl), güneşlenme süresi, panel teknolojisi, panel gücü, hava durumu, inverter gücü, santral yaşı, santralin bulunduğu şehir ve santralin bulunduğu bölgenin albedo değerleri geçmiş verileri ele alınarak gelecekte aylık elektrik üretimi tahmin edilmiştir. Daha önce LSTM yöntemi kullanılarak buna benzer birçok çalışma yapılmıştır (Konstantinou ve ark., 2021). Fakat yapılan çalışmalar yabancı asıllı olması nedeniyle tam anlamıyla ülkemize hitap etmemektedir bu nedenle ülkemizin konumuna bağlı olarak farklı parametreler ele alınıp daha özgün ve sadece LSTM yöntemiyle enerji verileri tahmin edilmeye çalışılmıştır.

Verilerin daha hızlı eğitilebilmesi ve sürecin hızlı ilerlemesi için Google Colabs'da kodlamalar yapılmıştır. Programlama dili olarak Python kullanılmıştır. Çalışmada 9 şehirde (İzmir, Tokat, Konya, Şanlıurfa, Erzurum, Nevşehir, Kayseri, Erzincan, Denizli) bulunan güneş enerji santrallerinin verileri kullanılmıştır. Tarih, enerji verisi, güneşlenme süresi, panel çeşidi, saha tipi, saha albedo oranı, panel gücü, inverter çeşidi, inverter gücü, güneş paneli açısı, AG kablo türü, santral performans oranı, santralin kurulduğu yıldan itibaren geçen süre; saha yılı gibi parametreler kullanılarak bir veri seti oluşturulmuştur. Eğitim için 708 adet veri kullanılmıştır.

BULGULAR VE TARTIŞMA

Eğitim verilerinin çok fazla olması yapay zekâ algoritmalarında doğruluk oranını artırmaktadır. Güneş enerji santrallerinde aylık elektrik üretim tahmini çalışmasında eğitim için 708 veri toplanarak tahmin edilecek olan enerji verisinin doğruluk oranı artırılmış ve daha verimli sonuçlar elde edilmiştir. Verilerin sistem tarafından ezberlenip tekrar aynı sonuçların alınmaması için

Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini

eğitimde test ve train oranlarının yani train verileri, derin öğrenme için kullanılacak verileri ifade ederken, test verileri derin öğrenme algoritmasında eğitilen verilerin ne kadar başarılı eğitildiğini görebilmek için kullanılmaktadır. Train ve test verilerinin oranları iyi bir şekilde ayarlanması gerekmektedir. Aksi taktirde yanlış tahminler ile karşılaşma olasılığı yükselmektedir.

Yapılan çalışma için ilk aşamada ele alınan verilerin birbiri ile ilişkisi incelenmiştir. Bu incelemeler sonu-

cunda bazı veriler gruplandırılarak gözlemler bu şekilde değerlendirilmeye alınıp analizler yapılmıştır. Şekil 2'de gösterilen betimsel istatistik göz önünde bulundurularak veriler arasındaki ilişkiler incelenmiştir. Toplam; toplam ne kadar verinin olduğunu, ortalama; verilerin ortalamalarını, std; standart sapmayı, min; minimum değeri, %25 verilerin %25 değerini, %50 verilerin %50 değerini, %75 verilerin %75 değerini ve max ise verilerin en yüksek değerinin kaç olduğunu göstermektedir, Il ise şehirleri ifade etmektedir.

	Toplam	Ortalama	std	min	25%	50%	75%	max
EnerjiVerileri	708.0	147260.032865	50646.057292	12947.30	103772.3825	152827.655	190691.7375	247280.11
Il	708.0	44.847458	18.297693	3.00	35.0000	42.0000	63.0000	81.00
GuneslenmeSuresi	708.0	7.683616	3.074541	2.00	5.0000	7.0000	10.0000	14.00
PanelCesidi	708.0	1.457627	0.562537	1.00	1.0000	1.0000	2.0000	3.00
SahaTipi	708.0	1.152542	0.359800	1.00	1.0000	1.0000	1.0000	2.00
Albedo	708.0	0.344986	0.273111	0.15	0.1500	0.2000	0.6000	0.80
PanelGucu	708.0	291.186441	44.171669	117.50	265.0000	320.0000	320.0000	365.00
InvertorCesidi	708.0	1.152542	0.359800	1.00	1.0000	1.0000	1.0000	2.00
InvertorGucu	708.0	309.932203	745.711994	30.00	60.0000	60.0000	60.0000	5000.00
PanelAcisi	708.0	25.169492	0.557400	25.00	25.0000	25.0000	25.0000	27.00
AGKabloTuru	708.0	2.000000	0.000000	2.00	2.0000	2.0000	2.0000	2.00
PerformansOrani	708.0	80.611356	1.095128	79.97	80.4500	80.4500	80.4500	86.41
SahaYili	708.0	3.375706	1.289750	2.00	2.0000	3.0000	5.0000	6.00

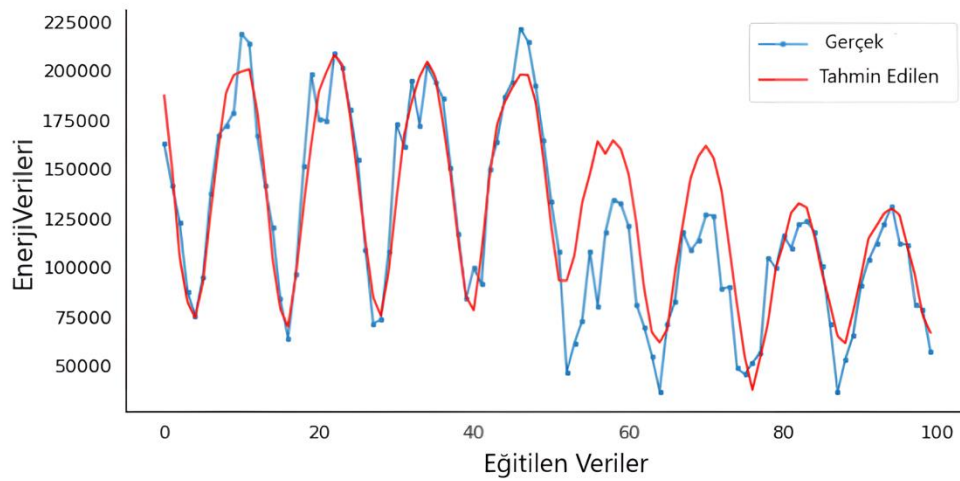
Şekil 2. Betimsel istatistik

Şekil 3'te LSTM yöntemi ile yapılan tahmin grafiği gösterilmiştir. Bir şehrin 100 aylık verilerini ve tahminleri görülmektedir. Bazı aylar tahmin ve gerçek veriler birbirine çok yakın olsa dahi 40. Aydan itibaren bir bozulma olduğu görülmektedir. Özellikle santral veriminin yükseldiği yaz aylarında tahmin ile gerçek değer arasında farklar azaldığı görülürken kış aylarında yani enerji verilerinin düştüğü kısımda genel olarak farkların olduğu gözlemlenmiştir. Şekil 4'te kayıp oranları daha net görülmektedir. LSTM yöntemi ile tahmin edilen ve-

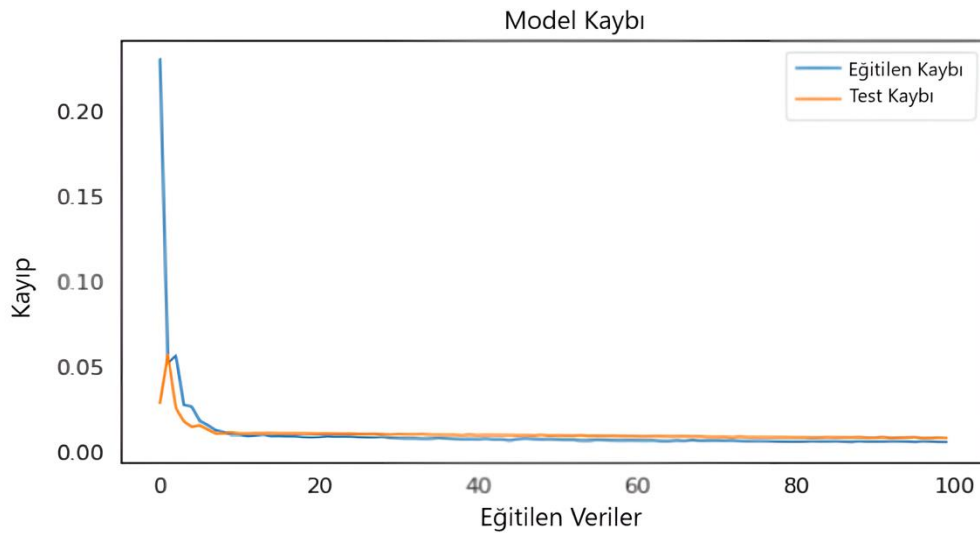
riler ile gerçek verilerin bir kısmı karşılaştırma yapabilmek için Tablo 1 ve 2'de gösterilmiştir. Tablo 1'de derin öğrenme tahmin sonucunda elde edilen enerji verileri gösterilmiştir. Tablo 2'de ise derin öğrenmede kullanılan gerçek veriler gösterilmiştir.

Eksik veriler, veri analizini, verilerin işlenmesini güçleştirir ve verimin düşmesine neden olabilir. Verilerin az olmasından kaynaklı oluşabilecek aşırı öğrenmeden kaçınmak için "data imputation" yöntemi kullanılarak 146 gözleme veri çoğaltma işlemi yapılmıştır.

Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini



Şekil 3. LSTM yöntemi ile yapılan tahmin



Şekil 4. LSTM yöntemi kayıp oranı

Tablo 1. Tahmin sonucunda elde edilen enerji verileri

80490.34
132247.87
159890.0
179192.93
199040.04
191766.15
183071.73
176731.84
134727.62
116132.65
106262.0
111794.60

Tablo 2. Gerçek zaman ve saha enerji verileri

2020.01	91337.31
2020.02	95706.96
2020.03	139865.95
2020.04	177376.23
2020.05	196894.64
2020.06	204093.73
2020.07	205666.77
2020.08	218475.59
2020.09	170661.52
2020.10	113350.90
2020.11	103350.91
2020.12	613350.92

Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini

Denklem 1’de hata oranının nasıl hesaplandığı gösterilmektedir. Ocak ayı hata oranı 2. Denklem hesabına göre yaklaşık %13 çıkarken, Mayıs ayı için bu değer %1 olarak karşımıza çıkmaktadır. Değerler çok değişkenlik göstermektedir. Bunun nedeni veri azlığından kaynaklıdır. Nitelikli veriler artırılarak tahmin edilen verilerin doğruluk oranı artırılabilir.

$$HO = \frac{\text{Gerçek Veriler} - \text{Tahmin Verileri}}{\text{Tahmin Verileri}} \times 100 \quad (1)$$

HO=Hata Oranı

$$\text{Ocak Ayı Hata Oranı} = \frac{91337.31 - 80490.34}{80490.34} \times 100 \quad (2)$$

SONUÇ

Sunulan çalışmada yapay sinir ağlarından LSTM yönetimi kullanılarak yenilenebilir enerji kaynaklarından güneş enerji santrallerinin geçmişteki üretim verileri ile gelecekte aylık elektrik üretim miktarı tahmin edilmeye çalışılmıştır. Çalışma sonucunda LSTM sinir ağı yöntemi ile enerji verilerinin tahmininde gerçeğe çok yakın büyük başarılar elde edildiği görülmüştür. Çalışma ile güneş enerji santrallerine yatırım yapmak isteyen veya güneş enerji santrali olan yatırımcıların gelecek dönemlerde ne kadar elektrik üreteceği öngörülebilmiştir. Buna örnek verilecek olunursa; güneş enerji santrali yatırımı yapmak isteyen bir yatırımcı, santralde kullanmak istediği güneş paneli çeşidine, panel gücüne, inverter çeşidine, inverter gücüne, kurulum yapılacak santralin çevresinde bulunan orman, asfalt, kırsal arazi gibi yerlerin albedo etkilerine, kullanacağı kablo türüne, panel açısına, santral konumuna şehir bazlı bakarak gelecekte santralin, yılın hangi ayı olursa olsun ne kadar elektrik üretebileceğini bu çalışma ile görebilme şansı yakalayabilecektir. Bu sayede kullanacağı santral ürünlerinde değişiklik yapabilecektir. Aynı zamanda güneş enerji santrali olan bir yatırımcı santralin hangi şehirde olduğunu, santral sahasında kullandığı malzemeleri ve santral yaşını yapılmış olan algoritmaya girerek gelecek aylarda ne kadar elektrik üretebileceğini görebilecektir.

Bu yöntem yenilenebilir enerji kaynaklarının birçoğuna uygulanabilir ve bu sayede santrallerdeki üretim miktarları bir ay önceden tahmin edilebilir. Örneğin; rüzgâr santrallerinde rüzgâr hızı, hava durumu, rüzgâr kanadı malzemesi veya hidroelektrik santrallerinde yıllık yağış oranına bağlı olarak enerji üretim tahmini yapılabileceği sonucuna varılmıştır. Yapılan çalışmanın bulgularına göre hata oranı %1 ile %17 arasında olduğu saptanmıştır. Bu sonucun yapay zekâ algoritmalarına oranla çok daha düşük kaldığı sonucuna ulaşılmıştır.

KAYNAKLAR

- Acaroğlu, H., Güllü, M. (2022). Climate change caused by renewable and non-renewable energy consumption and economic growth: A time series ARDL analysis for Turkey. *Renewable Energy*, 193: 434-447.
- Dam, M.M. (2014). Sera gazı emisyonlarının makroekonomik değişkenlerle ilişkisi: OECD ülkeleri için panel veri analizi. *Yayımlanmamış Doktora Tezi*. Adnan Menderes Üniversitesi SBE, Aydın.
- Konstantinou, M., Peratikou, S., Charalambides, A.G. (2021). Solar photovoltaic forecasting of power output using lstm networks. *Atmosphere*, 12(1): 124; DOI: 10.3390/atmos12010124.
- Landi, F., Baraldi, L., Cornia, M., Cucchiara, R. (2021). Working memory connections for LSTM. *Neural Networks*, 144: 334-341.
- Moor, J. (2006). The Dartmouth College artificial intelligence conference: The next fifty years. *Ai Magazine*, 27(4): 87-87.
- AlShabi, M., Assad, M.E.H. (2021). Artificial intelligence applications in renewable energy systems. In: *Design and performance optimization of renewable energy systems*, 251-295.
- Pulver, A., Lyu, S. (2017). LSTM with working memory. In *Proceedings of the International Joint Conference on Neural Networks* 845-851, Piscataway, NJ: IEEE.
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404: 132306; DOI: 10.1016/j.physd.2019.132306.
- URL-1 (2020). Güneş. www.enerji.gov.tr/bilgi-merkezi-enerji-gunes (Erişim Tarihi: 10.11.2021)
- URL-2 (2015). Understanding LSTM Networks. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (Erişim Tarihi: 05.12.2021)
- Van Der Westhuizen, J., Lasenby, J. (2018). The unreasonable effectiveness of the forget gate. *arXiv preprint arXiv:1804.04849*.
- Yu, Y., Si, X., Hu, C., Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural Computation*, 31(7): 1235-1270.