

HİDROELEKTRİK ENERJİ ÜRETİMİNİN TAHMİNİ: DERİN ÖĞRENME YAKLAŞIMI İLE ARIMA MODELİNİN KARŞILAŞTIRILMASI*

Betül GÜNEY¹, Burcu KOCARIK GACAR², Mehmet SANDAL³

Öz

Bu çalışmanın amacı Türkiye'deki hidroelektrik santrallerden elde edilen elektrik üretim verileri için günlük üretim potansiyelinin tahmin edilmesidir. Bu amaçla 2022-2024 yılları arasında Türkiye'nin yedi coğrafi bölgesinin her birinden en yüksek hidroelektrik enerji üretimi gerçekleştirilen ikişer santral seçilerek toplam 14 santrale ait saatlik üretim verileri kullanılmıştır. Veri düzenleme ve tahmin yöntemlerinin uygulanması süreçlerinde Python programlama dili kullanılmıştır. Çalışmada Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli ile derin öğrenme yöntemi olan Uzun-Kısa Vadeli Bellek (LSTM) algoritmasının tahmin performansları karşılaştırılmıştır. Elde edilen bulgular, elektrik üretiminin LSTM modeli ile daha yüksek doğrulukta tahmin edilebildiğini göstermiştir. Bu doğrultuda LSTM modeli kullanılarak 2025 yılına ilişkin hidroelektrik üretim tahminleri gerçekleştirilmiştir. Türkiye'de hidroelektrik santrallerine yönelik elektrik üretim tahmininde klasik zaman serisi modelleri ile derin öğrenme yaklaşımlarını karşılaştırmalı olarak ele alan çalışmaların sınırlı sayıda olduğu gözlenmektedir. Bu çalışma, iki farklı yaklaşımın performansını aynı veri kümesi üzerinde nicel ölçütlere göre değerlendirerek mevcut literatüre karşılaştırmalı ampirik bulgular sunmaktadır. Elde edilen bulguların enerji planlaması ve üretim öngörüsü çalışmalarına yöntemsel katkı sağlayabileceği değerlendirilmektedir.

Anahtar Kelimeler: Hidroelektrik Santrali, Enerji Tahmini, Derin Öğrenme, Zaman Serileri Analizi.

JEL Sınıflandırması: C10, C40

FORECASTING HYDROELECTRIC ENERGY PRODUCTION: A COMPARISON OF DEEP LEARNING APPROACH AND ARIMA MODEL

Abstract

The aim of this study is to estimate the daily generation potential of hydroelectric power plants in Türkiye using electricity production data. For this purpose, hourly production data from a total of 14 hydroelectric power plants were used, with two plants selected from each of Türkiye's seven geographical regions based on the highest generation levels for the period 2022–2024. The Python programming language was employed in the processes of data preprocessing and the implementation of forecasting methods. In the study, the forecasting performance of the Autoregressive Integrated Moving Average (ARIMA) model and the deep learning-based Long Short-Term Memory (LSTM) algorithm were compared. The findings indicate that electricity generation can be predicted with higher accuracy using the LSTM model. Accordingly, hydroelectric generation forecasts for the year 2025 were produced using the LSTM model. It is observed that studies comparing classical time series models and deep learning approaches for hydroelectric generation forecasting in Türkiye are limited. By evaluating the performance of these two approaches on the same dataset using quantitative metrics, this study provides comparative empirical evidence to the existing literature. The findings are expected to offer methodological contributions to energy planning and generation forecasting studies.

Keywords: Hydroelectric Power Plants, Energy Forecasting, Deep Learning, Time Series Analysis.

JEL Classification: C10, C40

* Bu çalışma, TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri (2023/2) Destek Programı kapsamında desteklenmiştir.

¹ Öğrenci., Manisa Celal Bayar Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, e-posta: betulgn01@gmail.com.tr, ORCID iD: <https://orcid.org/0009-0008-1768-2841>

² Dr. Öğr. Üyesi, Manisa Celal Bayar Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, e-posta: burcu.kocarik@cbu.edu.tr, ORCID iD: <https://orcid.org/0000-0001-5944-4456>

³ Dr. Öğr. Üyesi, Manisa Celal Bayar Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, e-posta: mehmet.sandal@cbu.edu.tr, ORCID iD: <https://orcid.org/0000-0001-7396-0801>

1. GİRİŞ

Enerji sistemleri, modern ekonomilerin sürdürülebilirliği ve toplumsal refahın devamlılığı açısından stratejik bir öneme sahiptir. Elektrik enerjisi bu sistemlerin merkezinde yer almaktadır. Ekonomik faaliyetlerin ana girdisi olan elektrik enerjisinin kullanımı teknolojiye bağlı olarak hızla artmıştır. Enerji ve özellikle elektrik enerjisi günümüzde sosyal hayatın da vazgeçilmez bir parçası haline gelmiştir. Elektrik enerjisi, en küçük yerleşim birimine kadar ulaşmış olan dağıtım şebekeleri sayesinde tüketicinin hayatını oldukça kolaylaştırmaktadır. Bu durum toplam enerji tüketimi içinde elektrik enerjisi tüketiminin payını hızlı bir şekilde artırmıştır. Bu noktada elektrik enerjisi tüketimi sosyal refahın ve ekonomik gelişmenin önemli göstergelerinden biridir. Kişi başı elektrik enerjisi üretimi ya da tüketimi ilgili ülkenin hayat standardını yansıtmaları bakımından önemlidir. Türkiye'nin önemli yenilenebilir enerji kaynaklarından birini hidroelektrik santraller (HES) oluşturmaktadır.

HES, akan suyun enerji potansiyelinden yararlanarak elektrik üretimi yapan bir sistemdir. Baraj ya da akarsulara kurulan bir yapı olan HES, yenilenebilir bir enerji kaynağı olan hidroelektrik enerjiyi üretmektedir. Hidroelektrik enerji, suyun potansiyel ve kinetik enerjisinin elektrik enerjisine dönüştürülmesi esasına dayanmaktadır. Hidroelektrik enerji üretimi; yağış rejimi, su akışı ve rezervuar seviyeleri gibi doğal ve değişken girdilere bağlı olması nedeniyle önemli ölçüde belirsizlik içermektedir. Bu durum, elektrik üretiminin sürekliliğinin sağlanması, arz-talep dengesinin korunması ve enerji planlamasının etkin şekilde yürütülebilmesi açısından geleceğe yönelik güvenilir üretim tahminlerini gerekli kılmaktadır. Bu bağlamda, HES sisteminin işletilmesinde üretim tahminine dayalı analitik yaklaşımlar kritik bir rol oynamaktadır.

HES planlaması ve yönetiminde zaman serileri analizi, gelişen yöntemlerle birlikte önemli bir rol oynamaktadır. Literatürde hidroelektrik santrallerin üretim tahminine yönelik farklı modelleme yaklaşımlarının kullanıldığı çeşitli çalışmalar bulunmaktadır. Bununla birlikte, Türkiye ölçeğinde hidroelektrik üretim verileri kullanılarak klasik zaman serisi modelleri ile derin öğrenme yaklaşımlarının karşılaştırmalı olarak ele alındığı çalışmalar sınırlı sayıdadır. Bu çalışmada, Türkiye'deki hidroelektrik santrallerden elde edilen elektrik üretim verileri kullanılarak günlük üretimin tahmin edilmesi ve klasik zaman serisi modeli ile derin öğrenme yaklaşımının performanslarının karşılaştırılması amaçlanmaktadır. Çalışmada, zaman serileri tahminlerinde yaygın olarak kullanılan Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli ile derin öğrenme yaklaşımlarından biri olan Uzun-Kısa Vadeli Bellek (LSTM) algoritmasının tahmin performansları karşılaştırılmıştır.

2. LİTERATÜR TARAMASI

Hidroelektrik enerji üretiminin tahminine yönelik çalışmalar, farklı modelleme yaklaşımlarının geliştirilmesiyle birlikte literatürde geniş bir yer edinmiştir. Bu çalışmalar genel olarak klasik zaman serisi modelleri ile makine öğrenmesi ve derin öğrenme temelli yöntemler etrafında şekillenmektedir.

Enerji üretimi ve tüketimi üzerine yapılan çalışmalar da literatürde geniş bir yer tutmaktadır. Çınar ve Öz (2017), 1965-2015 yılları için jeotermal, hidroelektrik ve termik enerji tüketiminin ekonomik büyüme üzerindeki etkisini araştırmıştır. Durağan olmayan özellikler trendden arındırılarak Hodrick-Prescott filtrelemesi ile durağanlaştırılmıştır. Çalışma enerji tüketiminin ekonomik gelişme üzerinde anlamlı bir etkisi olduğunu ortaya koymuştur. Kuşkaya ve Bilgili (2020), hidroelektrik enerji kullanımı ile CO₂ emisyonu arasındaki ilişkiyi incelemiştir. Çalışmada toplam biyokütle enerji tüketimi, fosil yakıt tüketim toplamı, sanayi üretim endeksi, nükleer enerji tüketimi, hidroelektrik enerji tüketimi ve toplam CO₂ salınımı değişkenleri ile dalgacık uyumu yöntemi kullanılmıştır. Hidroelektrik tüketiminin emisyon azaltıcı etkisi belirlenmiştir. Zarfl vd. (2019) hidroelektrik barajların habitat değişimi ve biyolojik çeşitlilik kaybı gibi önemli ekolojik etkiler yaratabileceğini göstermiştir. Ayrıca,

hidroelektrik yatırımlarında çevresel sürdürülebilirlik ile enerji üretimi arasında denge kurulmasının önemi belirtilmiştir.

Hidroelektrik enerji sistemlerinin yapısı ve potansiyeline yönelik çalışmalar da literatürde yer almaktadır. Kankal ve Akçay (2019), Türkiye’de hidroelektrik gelişimini inceleyerek Doğu Karadeniz Havzası için hidroelektrik potansiyel dağılımını ortaya koymuştur. Çalışmada, 2017 yılı için bölgenin en yüksek hidroelektrik potansiyeline sahip olan illerinin sırasıyla Rize (%18,5), Trabzon (%26) ve Giresun (%32) olduğu belirlenmiştir. Özdemir vd. (2020) ise Türkiye’deki hidroelektrik santrallerini güçlerine göre sınıflandırmış ve özellikle akarsu tipi santralleri incelemiştir. Çalışmada türbinlerin çalışma özellikleri ve türbin ile generatör seçim kriterlerini değerlendirilmiştir. Şavkar (2024) çalışmada yenilenebilir enerji kaynakları ve bu kaynakların önemli bileşenlerinden biri olan hidroelektrik enerjiyi incelemiştir. Yenilenebilir enerji kaynakları içinde Türkiye açısından hidroelektrik enerjinin önemini ele almıştır. Hidroelektrik sistemlerin işletilmesi ve rezervuar yönetimine yönelik çalışmalar da bulunmaktadır. Oral vd. (2017), hidroelektrik santral rezervuar verilerini enerji üretimi amaçlı değerlendirmiştir. Çalışmada, örnek olarak alınan göle giren ve enerji üretimi sırasında santrale geçen su hacmi elde edilerek santral gölünde biriktirilen toplam su miktarı tespit edilmiştir. Göl kotu ölçüsü hesaplanarak, göl işletme eğrisi yardımıyla hidroelektrik santralin net düşüşü belirlenmiştir.

Hidroelektrik enerji üretiminin tahminine yönelik çalışmalar literatürde farklı modelleme yaklaşımları ile ele alınmıştır. Klasik modelleme yaklaşımları da hidroelektrik üretim tahmininde kullanılmaktadır. Güler vd. (2024), Türkiye’de 1985-2022 sürecinde hidroelektrik üretim değerlerini üstel ve polinom regresyon modelleri ile analiz etmiştir. Çalışmada MAPE değerlerine göre polinom regresyon yönteminin tahminleme açısından daha elverişli olduğu belirlenmiştir. Zaman serisi temelli klasik tahmin modelleri enerji üretimi tahmininde uzun süredir kullanılmaktadır. Özellikle Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli, enerji üretimi ve tüketimi tahmininde yaygın olarak tercih edilen yöntemlerden biridir. Pao ve Tsai (2011), yenilenebilir enerji üretim tahmininde ARIMA modelinin kısa dönemli öngörülerde başarılı sonuçlar verdiğini göstermiştir. Benzer şekilde Ediger ve Akar (2007), Türkiye’nin elektrik talebini tahmin etmek amacıyla ARIMA modelini kullanmış ve modelin güvenilir sonuçlar ürettiğini ortaya koymuştur. Makas ve Karaatlı (2016), Antalya Havzası’nda bir hidroelektrik santralin yıllık üretimini Yapay Sinir Ağları kullanarak tahmin etmiş ve aylık ortalama debi, nispi nem ve yağış verilerinden yararlanmıştır. Çalışmada, 2007-2014 tarihleri arasındaki veriler ile 2015 yılı elektrik üretimi tahmin edilmiştir.

Son yıllarda ise enerji üretimi tahmininde derin öğrenme yaklaşımları ön plana çıkmıştır. Özellikle Uzun-Kısa Vadeli Bellek (LSTM) ağları, doğrusal olmayan ilişkileri modelleme kapasitesi sayesinde zaman serisi tahminlerinde yüksek performans sağlamaktadır (Hochreiter & Schmidhuber, 1997). Kong vd. (2017), elektrik yük tahmininde LSTM modelinin klasik zaman serisi yöntemlerine kıyasla daha düşük hata oranları sağladığını göstermiştir. Benzer şekilde Sagheer ve Kotb (2019), enerji tüketimi tahmininde LSTM modelinin geleneksel istatistiksel yöntemlere göre daha başarılı sonuçlar ürettiğini ortaya koymuştur. Wang vd. (2022), LSTM tabanlı model kullanarak hidroelektrik baraj deformasyon tahmin modeli oluşturmuştur. Sistem güvenliği açısından set barajının çökme değeri etkili bir şekilde tahmin edilmiştir. Zhou vd. (2020), su girişi, su çıkışı ve sıcaklık gibi çok değişkenli zaman serilerini modellemek ve hidroelektrik santrallerinin güç üretimini tahmin etmek amacıyla DeepHydro yöntemini önermiştir. Deneysel sonuçlar, önerilen yöntemin güç üretimini etkili bir şekilde tahmin edebileceğini ve iyi performans gösterebileceğini göstermiştir. Bulut (2021) Türkiye’nin aylık hidroelektrik üretim tahminini LSTM tabanlı derin öğrenme modeli ile yapmıştır. Çalışmada, gerçek üretim verileri ve çeşitli LSTM modelleri kullanılarak gelecek yıl aylık üretim öngörüsü gerçekleştirilmiştir. Çetin ve Işık (2022), Humartaş Enerji firması santralleri verileri ile santral bazında

üretim tahmininde LSTM modelini kullanmıştır. Çalışmada, tahmin sonuçlarına göre düşük hata oranları elde edilmiştir. Bilgili vd. (2022), Türkiye’deki nehir tipi hidroelektrik santrallerde bir gün öncesi enerji üretimini tahmin etmek amacıyla LSTM modelini kullanmıştır. Ayrıca, tahmin doğruluğunu artırmak için bulanık temelli yöntemlerle (Bulanık C-Ortalamalar (FCM) ile Uyarlamalı Nöro-Bulanık Çıkarım Sistemi (ANFIS), Çıkarımlı Kümeleme (SC) ile ANTIS ve Izgara Bölümleme (GP) ile ANFIS) karşılaştırmalar yapmıştır. Ma vd. (2023) ise farklı zaman ölçeklerinde su seviyesi tahmini için optimize edilmiş GRU-LSTM modeline dayalı yeni bir hibrit model önermiştir. Model, hidroelektrik santral su seviyesi tahminini gerçekleştirmiştir. Nebati vd. (2021), Türkiye’nin elektrik tüketimini zaman serisi ve regresyon analizi yöntemleri ile tahmin etmiştir. Çalışma, elde edilen sonuçların resmi verilerle uyumlu olduğunu göstermiştir.

Literatürde hidroelektrik üretim tahmini hem klasik istatistiksel modeller hem de derin öğrenme temelli yaklaşımlar kullanılarak ele alınmıştır. Bununla birlikte, Türkiye ölçeğinde hidroelektrik üretim verileri üzerinden klasik zaman serisi modelleri ile derin öğrenme yöntemlerinin karşılaştırmalı olarak incelendiği çalışmaların sınırlı olduğu görülmektedir. Bu doğrultuda, klasik zaman serisi modelleri ile derin öğrenme yaklaşımlarının karşılaştırmalı olarak değerlendirilmesi, enerji üretim tahmininde model performanslarının ortaya konulması açısından önem taşımaktadır. Bu durum, mevcut çalışmanın literatüre katkısını ortaya koymaktadır.

3. YÖNTEM

Resmi enerji sektörü verilerine göre, 2024 yılı sonu itibarıyla Türkiye’de toplam 764 hidroelektrik santral (HES) bulunmaktadır. Bu santrallerin 146’sı barajlı, 616’sı ise akarsu tipi elektrik üretimi gerçekleştirmektedir. Aynı dönem itibarıyla Türkiye’nin toplam elektrik enerjisi kurulu gücü 116.000 MW olup, bunun yaklaşık %27,8’i hidrolik enerji kaynaklarından oluşmaktadır (TEİAŞ, 2024; EPDK, 2024; DSİ, 2025).

Bu çalışma kapsamında, Türkiye’nin yedi coğrafi bölgesinin her birinde en yüksek hidroelektrik üretim kapasitesine sahip ilk iki santral seçilmiştir. Bu doğrultuda toplam 14 santrale ait saatlik hidroelektrik üretim verileri kullanılmıştır. Saatlik üretim verileri günlük üretim serilerine dönüştürülmüş olup, veriler Enerji Piyasaları İşletme A.Ş. (EPİAŞ) veri tabanından temin edilmiştir. Analizler 2022–2024 dönemini kapsamaktadır.

Çalışma kapsamındaki santraller sırasıyla Karakaya Barajı (Diyarbakır), Keban Barajı (Elazığ), Atatürk Barajı (Adıyaman/Şanlıurfa), Deriner Barajı (Artvin), Yukarı Kaleköy Barajı (Bingöl), Berke Barajı (Adana), Borçka Barajı (Artvin), Oymapınar Barajı (Antalya), Ermenek Barajı (Karaman), Gökçekaya Barajı (Ankara), Uluabat Barajı (Bursa), Akköprü Barajı (Muğla), Aksu Barajı (Antalya) ve Eşen Barajı (Muğla) şeklindedir.

Tahmin performansı karşılaştırması sonucunda en başarılı model belirlenmiş ve bu model kullanılarak 2025 yılına ilişkin hidroelektrik üretim tahminleri gerçekleştirilmiştir. Veri düzenleme ve tahmin yöntemlerinin uygulanması süreçlerinde Python programlama dili kullanılmış, analizler Google Colab ortamında yürütülmüştür. Bu kapsamda, hidroelektrik üretim serilerinin analiz edilmesi ve tahminlenmesinde kullanılan zaman serisi ve derin öğrenme yöntemlerine ilişkin süreç aşağıda sunulmaktadır.

3.1. Zaman Serileri Analizi

Zaman serileri analizi, hidroelektrik enerji üretimi ve su kaynaklarının uzun dönem davranışlarını incelemek için başvurulan bir yöntemdir. Zaman içinde meydana gelen veriler bir zaman serisi oluşturur. Zaman serisinde ardışık veriler genellikle bağımsız değildir. Bu durum, geçmiş verilere

dayanarak geleceğin tahmin edilmesi sürecinde önemli bir öngörü avantajı sağlamaktadır (Akgül, 1994). Zaman serisi analizinde kullanılan yöntemlerden biri olan ARIMA, otoregresif hareketli ortalama modelleri grubunda yer almakta olup Box-Jenkins yaklaşımı olarak da bilinmektedir (Makridakis, 1976).

3.1.1. ARIMA

ARIMA, bir zaman serisini modellemek ve gelecekteki değerlerini geçmiş gözlemlerden yararlanarak tahmin etmeyi amaçlayan bir yöntemdir. Bir ARIMA modeli otoregresif terim AR(p), ve hareketli ortalama MA(q) ve fark alma terimi I(d) olmak üzere üç ana bileşenden oluşmaktadır. Bu model, serideki trend ve rastgele dalgalanmaları dikkate alarak klasik bir zaman serisi modeli olarak ARIMA (p,d,q) parametreleri ile ifade edilir (Akgül, 1994; Zhang, 2003).

Modelde p parametresi mevcut gözlem ile geçmiş gözlemler arasındaki ilişkiyi temsil ederken, q parametresi geçmiş hata terimlerinin modele etkisini ifade etmektedir. d parametresi ise seriyi durağan hale getirmek için uygulanan fark alma derecesini (I) göstermektedir (Montanari vd., 2013; Box vd., 2015). ARIMA modeli denklem (1) ile sunulmuştur.

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t \quad (1)$$

Denklem (1)'de p değeri, fark alınmış serinin gecikme sayısını ve modelin otoregresif (AR) sırasını göstermektedir. Benzer şekilde q parametresi, gecikmeli hata terimlerinin sayısını ve modelin hareketli ortalama (MA) sırasını ifade etmektedir (Makridakis, 1976; Zhang, 2003). Ayrıca c sabit terimi, ϕ_i otoregresif (AR) katsayıları, y_{t-i} geçmiş gözlemleri, θ_j hareketli ortalama (MA) katsayılarını, e_{t-j} geçmiş hata terimlerini ve e_t hata terimini göstermektedir.

Zaman serisi analizinde ARIMA gibi geleneksel istatistiksel yöntemler, serideki doğrusal bileşenleri modellemek için sıklıkla kullanılmaktadır. Ancak doğrusal olmayan ve karmaşık yapılara sahip verilerin modellemesinde klasik yöntemler yetersiz kalabilmektedir. Bu durumlarda makine öğrenmesi tabanlı yaklaşımlar öne çıkmaktadır.

3.2. Yapay Sinir Ağları ve Derin Öğrenme Yaklaşımı

Makine öğrenmesi, belirli bir performans ölçütünü en üst düzeye çıkarmayı amaçlayan ve geçmiş veriler üzerinden çıkarım yapabilen algoritmik bir süreçtir (Alpaydın, 2020). Bu yöntem, verideki örüntüleri ve ilişkileri analiz ederek otomatik karar mekanizmalarının geliştirilmesini sağlamaktadır (Şişmanoğlu vd., 2020).

Makine öğrenmesinin bir alt alanı olan yapay sinir ağları (YSA), veriler arasındaki karmaşık ve doğrusal olmayan ilişkileri öğrenebilen model tabanlı bir mimaridir. YSA, insan sinir sisteminin (nöronların) yapısından esinlenerek algoritmalar aracılığıyla öğrenme gerçekleştiren bir yapıya sahiptir (Yılmaz, 2025). Geleneksel yöntemlerle tanımlanması güç olan veri setlerindeki gizli örüntüler, yapay sinir ağlarının örneklerden öğrenme yeteneği sayesinde ortaya çıkarılabilmektedir (Demirkıran vd., 2022). Bu süreçte, girdi ve çıktı verileri arasındaki bağlantı ağırlıkları aracılığıyla öğrenme gerçekleştirilmektedir (Metin vd., 2020).

Derin öğrenme ise yapay sinir ağlarının çok katmanlı yapılarından oluşan bir yaklaşımdır. Bu yöntemde, biyolojik nöronların işleyişine benzer biçimde tasarlanan yapay nöronlar farklı kaynaklardan gelen giriş sinyallerini işleyerek çok katmanlı bir yapı içerisinde çıktı üretmektedir (Şişmanoğlu vd., 2020; Akbulut ve Adem, 2023). Geleneksel makine öğrenmesi yöntemlerine kıyasla derin öğrenme,

sahip olduğu çok katmanlı mimari sayesinde yüksek boyutlu ve karmaşık veri yapılarının analizinde daha etkin bir performans sergilemektedir (Varürer vd., 2025).


Zaman serisi verilerinin modellenmesinde ise tekrarlayan yapay sinir ağları (Recurrent Neural Networks – RNN) önemli bir yere sahiptir. RNN mimarileri, geçmiş zaman adımlarına ait bilgileri ağ yapısı içerisinde tutarak ardışık bağımlılıkları modelleyebilmektedir. Ancak özellikle derin sinir ağları ve RNN yapılarında görülen ve modelin erken katmanlarının ya da uzak dönemli bağımlılıkların yeterince öğrenilememesiyle sonuçlanan bir optimizasyon problemi olan “sönümlenen gradyan” nedeniyle yetersiz kalabilmektedir. Bu sorunu gidermek amacıyla geliştirilen Uzun-Kısa Vadeli Bellek (Long Short-Term Memory – LSTM) ağı, özel hafıza hücreleri ve kapı mekanizmaları (giriş kapısı, unutma kapısı ve çıkış kapısı) aracılığıyla bilginin hangi kısmının saklanacağına, güncelleneceğine veya silineceğine karar verebilmektedir (Hochreiter & Schmidhuber, 1997). Bu yapı sayesinde LSTM modelleri hem kısa dönemli hem de uzun dönemli bağımlılıkları etkin biçimde öğrenebilmekte ve doğrusal olmayan zaman serilerinde yüksek tahmin performansı sağlayabilmektedir.

Hidroelektrik enerji üretim verileri; meteorolojik koşullar, su akışı, bakım çalışmaları ve mevsimsel değişkenlik gibi çok sayıda faktörden etkilenmektedir. Bu değişkenlerin etkisi doğrusal olmayan ve zaman içinde birikimli yapılar oluşturabilmektedir. Bu nedenle çalışmada, doğrusal olmayan veri yapısını modelleyebilmek ve serideki uzun dönemli bağımlılıkları dikkate alarak daha tutarlı ve kararlı tahminler elde etmek amacıyla LSTM mimarisi tercih edilmiştir.

3.2.1. LSTM

Çeşitli sınıflandırma ve tahmin problemlerinde derin öğrenme algoritmaları yaygın olarak kullanılmaktadır. Bir derin öğrenme yöntemi olan LSTM ağı, Hochreiter ve Schmidhuber (1997) tarafından önerilmiş olup özellikle zaman serisi tahmin problemlerinde etkili sonuçlar vermektedir.

LSTM mimarisi, bilgiyi uzun süre saklayabilen bir bellek hücresi (cell state) ve bu hücreyi kontrol eden kapı (gate) mekanizmalarından oluşmaktadır. Bu kapılar sayesinde model, hangi bilginin korunacağına, hangi bilginin unutulacağına ve hangi bilginin çıktı olarak üretileceğine karar verebilmektedir. Böylece bir sinir ağı modelinde farklı katmanlar ve bu katmanları birbirine bağlayan geçişler kullanılarak zamanla değişen gözlemler analiz edilebilmektedir. LSTM, zaman serilerindeki uzun dönemli bağımlılıkları öğrenebilme kapasitesine sahiptir (Hochreiter & Schmidhuber, 1997). Mimari ağ yapısı Şekil 1’de sunulmuştur.



Şekil 1: LSTM Algoritmasının Yapısı

Kaynak: (Kara, 2019: 889)

Bir LSTM hücresi üç temel kapı (katman) mekanizmasından oluşmaktadır: giriş kapısı (input gate), unutma kapısı (forget gate) ve çıkış kapısı (output gate). Giriş kapısı yeni bilginin hücre durumuna ne ölçüde ekleneceğini belirlerken, unutma kapısı önceki hücre durumundan hangi bilginin silineceğine

karar vermektedir. Çıkış kapısı ise hücre durumuna bağlı olarak üretilecek gizli durumun (hidden state) belirlenmesini sağlamaktadır (Kara, 2019).

Algoritmanın her zaman adımında x_t (mevcut giriş verisi) ve h_{t-1} (bir önceki gizli durum) girdi olarak alınmakta ve kapı mekanizmaları aracılığıyla hücre durumu güncellenmektedir. Bu yapı sayesinde model, geçmiş bilgiyi kontrollü biçimde taşıyabilmekte ve uzun dönemli bağımlılıkları etkili şekilde öğrenebilmektedir. Unutma kapısında aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmakta ve denklem (2)'de tanımlanan f_t değeri hesaplanmaktadır.

$$f_t = (G_f \cdot x_t + G_{f,h} \cdot h_{t-1} + s_f) \quad (2)$$

Sonraki adımda giriş kapısı devreye girmekte ve hücre durumuna eklenecek yeni bilgi belirlenmektedir. İlk olarak denklem (3)'te verilen i_t değeri hesaplanarak yeni bilginin hücre durumuna hangi oranda aktarılacağı belirlenmektedir. Ardından denklem (4)'te tanımlanan aday hücre durumu $\tilde{C}_t$, tanh aktivasyon fonksiyonu kullanılarak hesaplanmaktadır. Son olarak mevcut hücre durumu C_t 'nin güncellenmesi denklem (5)'te gösterildiği şekilde gerçekleştirilmektedir. Çıkış kapısında çıktı değerleri denklem (6) ve (7)'de gösterildiği şekilde hesaplanmaktadır.

$$i_t = (G_i \cdot x_t + G_{i,h} \cdot h_{t-1} + s_i) \quad (3)$$

$$\tilde{C}_t = \tanh(G_{c,x} \cdot x_t + G_{c,h} \cdot h_{t-1} + s_c) \quad (4)$$

$$C_t = C_{t-1} \cdot f_t + i_t \cdot \tilde{C}_t \quad (5)$$

$$o_t = (G_o \cdot x_t + G_{o,h} \cdot h_{t-1} + s_o) \quad (6)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

Aşamalar iteratif olarak devam etmektedir. Bu süreçte ağırlık (G) ve sapma (s) parametreleri, model çıktıları ile gerçek eğitim verileri arasındaki hata fonksiyonunu en aza indirecek şekilde güncellenerek model eğitilmektedir (Yılmaz & Orman, 2021).


Bu çalışmada, hidroelektrik enerji üretim verilerinin tahmini için model kurulmadan önce ham veri normalizasyon işlemine tabi tutulmuştur. Bu doğrultuda veri seti Min-Max ölçeklendirme yöntemi kullanılarak [0,1] aralığına normalize edilmiştir. Modelin eğitim ve test aşamalarında kullanılmak üzere veri seti %80 eğitim ve %20 test verisi olacak şekilde ayrılmıştır.

LSTM modelinde karmaşık örüntüleri yakalayabilmek amacıyla iki gizli katmanlı bir mimari tercih edilmiş ve her bir katmanda 50 nöron kullanılmıştır. Modelin eğitim sürecinde aşırı öğrenme (overfitting) problemini azaltmak amacıyla her katmanda %20 oranında seyreltme (Dropout) uygulanmıştır. Ayrıca model optimizasyonunda “Adam” algoritması, aktivasyon fonksiyonu olarak “ReLU” ve kayıp fonksiyonu olarak “Ortalama Karesel Hata (MSE)” kullanılmıştır.

4. BULGULAR

Türkiye'nin her bölgesinden seçilen hidroelektrik santralleri ve bu santrallerin 2022, 2023 ve 2024 yıllarındaki toplam elektrik üretim miktarları Şekil 2'de sunulmuştur. Buna göre coğrafi bölgelerden eşit sayıda seçilen santraller arasında en yüksek hidroelektrik enerjisi üretiminin sırasıyla Karakaya, Keban, Atatürk, Deriner ve Yukarı Kaleköy santrallerinde gerçekleştiği görülmektedir. Eşen, Aksu ve Akköprü santralleri ise diğer santraller arasında en düşük üretime sahip santrallerdir. Bu

durumda Güneydoğu ve Doğu Anadolu bölgelerindeki santrallerin üretim potansiyelinin yüksek olduğunu söylenebilir. Bununla birlikte Marmara ve Ege bölgelerindeki santrallerden elde edilen üretimin diğer coğrafi bölgelere göre daha düşük olduğu söylenebilir. Ayrıca Güneydoğu Anadolu, Doğu Anadolu, Karadeniz ve Akdeniz’de 2024 yılındaki elektrik üretimi 2023 yılına göre artış göstermiştir.



Şekil 2: Hidroelektrik Santrallerin Yıllık Toplam Üretim Miktarı

Zaman serileri yöntemlerine göre gerçekleştirilen tahmin için serinin geçmiş değerleri esas alınmaktadır. Bu nedenle analizlerin güvenilirliği ve modelin doğruluğunu sağlamak için serinin istatistiksel özelliklerinin zamanla değişmemesi beklenmektedir. Bu amaçla serilerin durağanlıkları kontrol edilmektedir. Çalışmada hidroelektrik santral üretim verilerinin durağanlıklarını incelemek için Dickey ve Fuller (1981) tarafından önerilen Genişletilmiş Dickey-Fuller (ADF) testi gerçekleştirilmiştir. ADF testinde serinin birim kök içerip içermediği test edilerek durağanlık belirlenmektedir. Bu test ile “serinin birim kök içerdiği yani durağan olmadığı” yönündeki yokluk hipotezi sınanmaktadır. Böylece ADF test istatistiği için hesaplanan p değerinin anlamlılık seviyesinden küçük olması durumunda yokluk hipotezi reddedilerek serinin durağan olduğu sonucuna ulaşılmaktadır. Her bir santrale ait üretim verilerinin ADF birim kök testi sonuçları Tablo 1’de sunulmuştur. Buna göre ADF birim kök testi sonucunda tüm seriler için p olasılık değerlerinin %1, %5 veya %10 anlamlılık seviyelerinden daha düşük olduğu görülmektedir. Bu durumda yokluk hipotezi reddedilerek tüm serilerin düzey değerlerinde durağan olduğu sonucuna ulaşılmıştır.


Tablo 1: ADF Birim Kök Testi Sonuçları

<i>Hidroelektrik Santral</i>	<i>ADF Test İstatistiği</i>	
	<i>Sabit</i>	<i>Sabit ve Trendli</i>
Karakaya	-2,993** (0,036)	-3,478** (0,042)
Keban	-3,123** (0,025)	-3,526** (0,037)
Atatürk	-3,341** (0,013)	-3,729** (0,021)
Deriner	-4,772* (>0,001)	-4,785* (>0,001)
Yukarı Kaleköy	-7,306* (>0,001)	-7,305* (>0,001)
Berke	-4,059* (0,001)	-4,041* (0,008)
Borçka	-4,363* (>0,001)	-4,363* (0,003)
Oymapınar	-2,706*** (0,073)	-2,453 (0,352)
Ermenek	-4,156* (0,001)	-4,167* (0,005)
Gökçekaya	-4,001* (0,001)	-4,025* (0,008)
Uluabat	-4,160* (0,001)	-4,162* (0,005)
Akköprü	-3,803* (0,003)	-4,179* (0,005)
Aksu	-4,258* (0,001)	-4,297* (0,003)
Eşen	-3,888* (0,002)	-4,248* (0,004)


Not: ADF testi için belirlenen p olasılık değeri parantez içerisinde yer almaktadır. *, ** ve *** sırasıyla %1, %5 ve %10 anlamlılık düzeyinde serinin durağan olduğunu ifade etmektedir.

Çalışmada ARIMA modelini oluşturmak için en uygun parametreleri belirlemek amacıyla Python’da yer alan pmdarima kütüphanesi kullanılmıştır. En düşük AIC kriterine göre belirlenen parametrelere (p,q,d) göre ARIMA modelleri oluşturulmuştur.


Hidroelektrik santrallerin üretim verileri esas alınarak elde edilen ARIMA ve LSTM tahmin sonuçları test verileri üzerinden karşılaştırılmış ve bulgular Şekil 3-9’da sunulmuştur.




Şekil 3: Atatürk ve Karakaya HES için ARIMA ve LSTM tahmin sonuçları (Güneydoğu Anadolu Bölgesi)




Şekil 4: Keban ve Yukarı Kaleköy HES için ARIMA ve LSTM tahmin sonuçları (Doğu Anadolu Bölgesi)




Şekil 5: Deriner ve Borçka HES için ARIMA ve LSTM tahmin sonuçları (Karadeniz Bölgesi)




Şekil 6: Oymapınar ve Berke HES için ARIMA ve LSTM tahmin sonuçları (Akdeniz Bölgesi)



Şekil 7: Ermenek ve Gökçekaya HES için ARIMA ve LSTM tahmin sonuçları (İç Anadolu Bölgesi)



Şekil 8: Uluabat ve Aksu HES için ARIMA ve LSTM tahmin sonuçları (Marmara Bölgesi)



Şekil 9: Akköprü ve Eşen 1 HES için ARIMA ve LSTM tahmin sonuçları (Ege Bölgesi)

Şekil 3–9 incelendiğinde, ARIMA modeli için her bir santralin üretim serisine en uygun parametre kombinasyonları belirlenerek tahminlerin gerçekleştirildiği görülmektedir. LSTM modeli ise her bir üretim serisi için ayrı ayrı eğitilmiştir. Test verileri ile tahmin sonuçları karşılaştırıldığında, LSTM modeli tarafından elde edilen tahminlerin gerçek değerlere daha yakın olduğu görülmektedir. Oymapınar ve Ermenek hidroelektrik santrali gibi üretim serilerinde dalgalanmanın görece düşük olduğu durumlarda ARIMA modeli genel üretim trendini başarılı biçimde yakalayabilmektedir. Ancak üretim oynaklığının yüksek olduğu serilerde ARIMA tahminlerinin gerçek değerlerden belirgin biçimde sapabildiği gözlemlenmektedir.

Üretim verilerine hangi modelin daha yakın tahminler ürettiğini belirlemek amacıyla Ortalama Karesel Hatanın Karekökü (RMSE) ve Ortalama Mutlak Hata (MAE) ölçütleri kullanılmıştır. Bu performans kriterleri, tahmin edilen değerler ile gerçek değerler arasındaki sapmayı nicel olarak ölçmekte ve daha düşük hata değerine sahip modelin veriye daha iyi uyum sağladığını göstermektedir (Sevinç ve Kaya, 2021). Bu kapsamda ARIMA ve LSTM modellerine ilişkin hesaplanan RMSE ve MAE değerleri Tablo 2’de sunulmuştur.


Tablo 2: Test Verisi İçin ARIMA ve LSTM modeline göre RMSE ve MAE Sonuçları

HES	ARIMA		LSTM	
	RMSE	MAE	RMSE	MAE
Karakaya	6777,18	5563,68	3933,80	3067,66
Keban	4334,74	3662,85	2753,80	2165,61
Atatürk	7749,90	5980,54	4725,74	3544,71
Yukarı Kaleköy	4052,52	3740,27	1806,42	1273,75
Deriner	4921,86	4010,56	1984,22	1439,03
Borçka	2494,39	2022,98	1101,48	837,32
Oymapınar	1642,21	841,67	1159,82	856,94
Berke	2117,14	1581,41	1651,95	1337,35
Ermenek	816,38	605,73	733,81	590,02
Gökçekaya	322,32	244,83	188,52	160,09
Uluabat	633,06	573,17	263,73	201,88
Aksu	224,58	141,94	78,36	38,14
Akköprü	663,07	613,27	95,88	42,47
Eşen	100,26	57,21	52,55	45,09

Tablo 2’de 14 farklı santrale ait test verileri üzerinden ARIMA ve LSTM modellerinin performansları karşılaştırılmıştır. Tüm santrallerde ARIMA modeline ait RMSE değerlerinin LSTM modeline kıyasla daha yüksek olduğu görülmektedir. Özellikle Atatürk, Karakaya ve Keban gibi üretim hacmi yüksek santrallerde iki model arasındaki hata farkının daha belirgin olduğu dikkat çekmektedir. Benzer şekilde Deriner, Yukarı Kaleköy, Borçka, Akköprü ve Düzce Aksu santrallerinde de LSTM modelinin daha düşük hata değerleri ile daha başarılı sonuçlar ürettiği gözlemlenmiştir.

Bununla birlikte Ermenek ve Oymapınar santrallerinde modeller arasındaki performans farkının görece daha sınırlı olduğu görülmektedir. Özellikle Oymapınar hidroelektrik santralinde ARIMA modeli için hesaplanan MAE değerinin LSTM modeline kıyasla daha düşük olması, üretim serisinin yapısal özelliklerinin model performansı üzerinde belirleyici olabileceğini göstermektedir. Bu durum, üretim dalgalanmasının görece düşük olduğu serilerde klasik zaman serisi modellerinin de rekabetçi performans sergileyebileceğine işaret etmektedir.

Çalışmanın son aşamasında, her bir santrale ait üretim verileri kullanılarak LSTM modeli aracılığıyla 2025 yılı hidroelektrik üretimine ilişkin tahmin aralıkları hesaplanmış ve sonuçlar Şekil 10’da sunulmuştur.



Şekil 10: LSTM Modeli 2025 Yılı Toplam Enerji Üretim Tahmini

Çalışmada yer alan 14 hidroelektrik santral için 2022–2024 dönemine ait üretim verileri esas alınarak LSTM modeli ile 2025 yılına ilişkin üretim tahmin aralıkları hesaplanmıştır. Elde edilen sonuçlara göre en yüksek üretim tahmininin Karakaya hidroelektrik santralinde yaklaşık 5.865.250–6.329.104 MWh aralığında gerçekleşmesi beklenmektedir. Son üç yıllık üretim ortalaması en düşük olan Eşen hidroelektrik santralinde ise 2025 yılı üretiminin yaklaşık 14.523–18.214 MWh aralığında olacağı tahmin edilmektedir. Üretim kapasitesi yüksek olan santrallerde tahmin aralığının daha geniş, üretim düzeyi görece düşük olan santrallerde ise daha dar olduğu görülmektedir. Bununla birlikte üretim miktarının mevsimsel koşullar, su rejimindeki değişimler, kapasite artış veya azalışları ve teknik aksaklıklar gibi dışsal faktörlerden etkilenebileceği dikkate alınmalıdır.

SONUÇ

Bu çalışmada, Türkiye’deki hidroelektrik santrallerin günlük üretim verileri kullanılarak bu verileri en iyi temsil eden tahmin modelinin belirlenmesi amaçlanmıştır. Bu kapsamda, Türkiye’nin yedi coğrafi bölgesinde en yüksek üretim kapasitesine sahip 14 hidroelektrik santral seçilmiş ve Enerji Piyasaları İşletme A.Ş. (EPİAŞ) veri tabanından elde edilen saatlik üretim verileri günlük serilere dönüştürülerek analiz edilmiştir. Üretim serilerinin durağanlık özellikleri Augmented Dickey-Fuller (ADF) birim kök testi ile incelenmiş ve tüm serilerin durağan olduğu belirlenmiştir.

Üretim verilerini en iyi temsil eden modelin belirlenmesi amacıyla klasik zaman serisi modeli olan ARIMA ile derin öğrenme yaklaşımı olan LSTM modelleri karşılaştırılmıştır. RMSE ve MAE performans ölçütlerine göre yapılan değerlendirmede, genel olarak 14 santral için LSTM modelinin ARIMA modeline kıyasla daha düşük hata değerleri ürettiği ve daha yüksek tahmin performansı sergilediği görülmüştür. Özellikle üretim dalgalanmalarının yüksek olduğu serilerde LSTM modelinin uzun dönemli yapıyı daha başarılı şekilde yakaladığı belirlenmiştir. Buna karşılık, Oymapınar ve Ermenek gibi üretim oynaklığının görece düşük olduğu santrallerde modeller arasındaki performans farkının azaldığı gözlemlenmiştir. Bu durum, üretim serisinin yapısal özelliklerinin model performansı üzerinde belirleyici olduğunu göstermektedir.

Çalışmanın son aşamasında, LSTM modeli kullanılarak her bir santral için 2025 yılına ilişkin üretim tahmin aralıkları hesaplanmıştır. Üretim kapasitesi yüksek olan Karakaya, Keban ve Atatürk gibi santrallerde tahmin aralıklarının diğer santrallere göre daha geniş olduğu görülmüştür. Ayrıca Oymapınar, Akköprü ve Aksu dışındaki santrallerde 2025 yılı üretiminin 2024 yılına kıyasla daha düşük gerçekleşebileceği öngörülmüştür. Bununla birlikte üretim miktarlarının; mevsimsel yağış rejimi, çevresel koşullar, su akışı, bakım-onarım faaliyetleri ve teknik aksaklıklar gibi dışsal faktörlerden etkilenebileceği dikkate alınmalıdır.

Genel olarak değerlendirildiğinde, doğrusal olmayan ve dalgalı yapıya sahip üretim serilerinde LSTM modelinin uzun dönemli bağımlılıkları daha etkin biçimde yakalayabildiği ve tahmin performansının ARIMA modeline kıyasla daha yüksek olduğu sonucuna ulaşılmıştır. Bununla birlikte üretim değişkenliğinin düşük olduğu ve serinin daha düzenli bir yapı sergilediği durumlarda ARIMA modelinin özellikle kısa dönemli tahminlerde rekabetçi sonuçlar üretebildiği görülmektedir.

Gelecekte yapılacak çalışmalarda, modele meteorolojik değişkenler (yağış, sıcaklık, nem vb.) ve hidrolik göstergelerin dahil edilmesi, tahmin doğruluğunu artıracak önemli bir geliştirme alanı olarak değerlendirilmektedir. Bu tür bütünsel modelleme yaklaşımları, enerji planlaması, yatırım kararları ve kaynak yönetimi açısından önemli öngörüler sağlayabilir.

Etik Beyan

“Hidroelektrik Enerji Üretiminin Tahmini: Derin Öğrenme Yaklaşımı ile ARIMA Modelinin Karşılaştırılması” başlıklı çalışmanın yazılması ve yayınlanması süreçlerinde Araştırma ve Yayın Etiği kurallarına riayet edilmiş ve çalışma için elde edilen verilerde herhangi bir tahrifat yapılmamıştır. Çalışma için etik kurul izni gerekmemektedir.

Katkı Oranı Beyanı

Çalışmadaki yazarların tümü çalışmanın yazılmasından taslağın oluşturulmasına kadar tüm süreçlere katkı yapmış ve nihai halini okuyarak onaylamıştır.

Çatışma Beyanı

Yapılan bu çalışma gerek bireysel gerekse kurumsal/örgütsel herhangi bir çıkar çatışmasına yol açmamıştır.

KAYNAKÇA

- Akbulut, S. ve Adem, K. (2023). Derin Öğrenme ve Makine Öğrenmesi Yöntemleri Kullanılarak Gelişmekte Olan Ülkelerin Finansal Enstrümanlarının Etkileşimi ile BIST 100 Tahmini. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(1), 52-63. <https://doi.org/10.28948/ngumuh.1131191>
- Akgül, I. (1994). Zaman Serisi Analizi ve Öngörü Modelleri. *Öneri*, 1(1),52-69. <https://doi.org/10.14783/maruoneri.698511>
- Alpaydin, E. (2020). *Introduction to Machine Learning*. MIT Press.
- Bilgili, M., Keiyinci, S., ve Ekinci, F. (2022). One-Day Ahead Forecasting of Energy Production from Run-of-River Hydroelectric Power Plants with a Deep Learning Approach. *Scientia Iranica*, 29(4),1838-1852. <https://doi.org/10.24200/sci.2022.58636.5825>
- Box, G. E., Jenkins, G. M., Reinsel, G. C. and Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Wilson, G. T. (2016). Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1, Book Review, *Journal of Time Series Analysis*, 37(5). <https://doi.org/10.1111/jtsa.12194>
- Bulut, M. (2021). Hydroelectric Generation Forecasting with Long Short Term Memory (LSTM) Based Deep Learning Model for Turkey. arXiv preprint arXiv:2109.09013.
- Çetin, Ö. ve Isık, A. H. (2022). Derin Öğrenme ile Güneş Enerjisi Santrallerinde Aylık Elektrik Üretim Tahmini. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(Ek/Suppl.1), 382-387. <https://doi.org/10.29048/makufebd.1144631>
- Çınar, M. ve Öz, R. (2017). Enerji Tüketimi ve Ekonomik Büyüme İlişkisine Yenilenebilir Enerji Bağlamında Bir Öneri. *International Journal of Academic Value Studies*, 3(13),40-54. <https://doi.org/10.23929/javs.350>
- Devlet Su İşleri (DSİ) (2025). “2024 Yılı Resmi Su Kaynakları İstatistikleri”, <https://www.dsi.gov.tr/>, (10.01.2025).

- Günay, B., Kocarık Gacar, B. & Sandal, M. (2026). Hidroelektrik Enerji Üretiminin Tahmini: Derin Öğrenme Yaklaşımı ile ARIMA Modelinin Karşılaştırılması. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 28(52), 687-706.
- Demirkıran, S., Beyoğlu, A., Terzioğlu, M. K., ve Yaşar, A. (2022). Sürdürülebilir Kalkınma Odaklı Dijitalleşme Belirleyicilerinin Verimlilik Üzerindeki Etkilerinin Yapay Sinir Ağları ile Sınıflandırılması. *Verimlilik Dergisi*, 30-47. <https://doi.org/10.51551/verimlilik.988286>
- Dickey, D. A. and Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica: Journal of the Econometric Society*, 1057-1072. <https://doi.org/10.2307/1912517>
- Ediger, V. Ş. and Akar, S. (2007). ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey. *Energy Policy*, 35(3),1701–1708. <https://doi.org/10.1016/j.enpol.2006.05.009>
- Enerji Piyasası Düzenleme Kurumu (EPDK) (2024). “Elektrik Piyasası Sektör Raporu”, <https://www.epdk.gov.tr>, (10.01.2025).
- Enerji Piyasaları İşletme A.Ş. (EPIAŞ) (2025). “Gerçek Zamanlı Elektrik Üretimi”, <https://seffaflik.epias.com.tr/electricity/electricity-generation/ex-post-generation/real-time-generation>, (07.01.2025).
- Hochreiter, S. and Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8),1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Güler, E., Yerel Kandemir, S., and Aladağ, Z. (2024). Hidroelektrik Enerji Üretiminin Dematel ve Regresyon Yöntemleri ile Değerlendirilmesi. *Endüstri Mühendisliği Dergisi*, 35(3),437-464. <https://doi.org/10.46465/endustrimuhendisligi.1533179>
- Kankal, M. ve Akçay, F. (2019). Doğu Karadeniz Havzası Hidroelektrik Enerji Durumunun İncelenmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 8(2),892-901. <https://doi.org/10.28948/ngumuh.598239>
- Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(4),882-892. <https://doi.org/10.29109/gujsc.571831>
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., and Zhang, Y. (2017). Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network. *IEEE Transactions on Smart Grid*, 10(1), 841–851. <https://doi.org/10.1109/TSG.2017.2753802>
- Kuşkaya, S. ve Bilgili, F. (2020). Hidroelektrik Enerji Tüketiminin Çevre Üzerine Etkisinin Sürekli Dalgacık Uyumlu Modeli ile Araştırılması: ABD Örneği. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (55), 263-284. <https://doi.org/10.18070/erciyesiibd.565196>
- Ma, X., Hu, H., and Ren, Y. (2023). A Hybrid Deep Learning Model Based on Feature Capture of Water Level Influencing Factors and Prediction Error Correction for Water Level Prediction of Cascade Hydropower Stations Under Multiple Time Scales. *Journal of Hydrology*, 617, 129044. <https://doi.org/10.1016/j.jhydrol.2022.129044>
- Makas, Y. ve Karaatlı, M. (2016). Yapay Sinir Ağlarıyla Hidroelektrik Enerji Üretiminin Çok Dönemli Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3), 757-772. <https://izlik.org/JA54NA68PG>
- Makridakis, S. (1976). A Survey of Time Series, *International Statistical Review*, 44(1), 29-70. <https://doi.org/10.2307/1402964>

- Günay, B., Kocarık Gacar, B. & Sandal, M. (2026). Hidroelektrik Enerji Üretiminin Tahmini: Derin Öğrenme Yaklaşımı ile ARIMA Modelinin Karşılaştırılması. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 28(52), 687-706.
- Metin, N., Karadağ, K., ve Terzioğlu, M. K. (2020). MLP/RBF Ağ Mimarileriyle Hibrit MGARCH-ANN Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 78-93. <https://izlik.org/JA93WM99UE>
- Montanari, A., Young, G., Savenije, H. H., Hughes, D., Wagener, T., Ren, L. L., et al. (2013). Panta Rhei - Everything Flows: Change in Hydrology and Society - the IAHS Scientific Decade 2013–2022. *Hydrological Sciences Journal*, 58(6), 1256-1275. <https://doi.org/10.1080/02626667.2013.809088>
- Nebati, E. E., Taş, M., ve Ertaş, G. (2021). Türkiye’de Elektrik Tüketiminde Talep Tahmini: Zaman Serisi ve Regresyon Analizi ile Karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (31)348-357. <https://doi.org/10.31590/ejosat.998277>
- Sagheer, A. and Kotb, M. (2019). Unsupervised Pre-Training of a Deep LSTM-Based Stacked Autoencoder for Multivariate Time Series Forecasting Problems. *Scientific Reports*, 9(1), 19038. <https://doi.org/10.1038/s41598-019-55320-6>
- Sevinç, A. ve Kaya, B. (2021). Derin Öğrenme ve İstatistiksel Modelleme Yöntemiyle Sıcaklık Tahmini ve Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1222-1228. <https://doi.org/10.31590/ejosat.1014106>
- Şavkar, E. (2024). Yenilenebilir Enerji Zemininde Hidroelektrik Enerji ve Türkiye Potansiyeli. *Oğuzhan Sosyal Bilimler Dergisi*, 6(1), 51-58. <https://doi.org/10.55580/oguzhan.1484562>
- Şişmanoğlu, G., Koçer, F., Önde, M. A., ve Sahingoz, O. K. (2020). Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 434-445. <https://doi.org/10.17798/bitlisfen.571386>
- Oral, F., Behçet, R., ve Aykut, K. (2017). Hidroelektrik Santral Rezervuar Verilerinin Enerji Üretimi Amaçlı Değerlendirilmesi. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 6(2), 29-38. <https://doi.org/10.17798/bitlisfen.308545>
- Özdemir, M. S., Dalcı, A., ve Ocak, C. (2020). Akarsu Tipi Hidroelektrik Santraller ve Bu Santrallerde Kullanılan Türbin-Generatörler. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 69-75. <https://doi.org/10.46387/bjesr.798387>
- Pao, H. T. and Tsai, C. M. (2011). Modeling and Forecasting the CO₂ Emissions, Energy Consumption, and Economic Growth in Brazil. *Energy*, 36(5), 2450–2458. <https://doi.org/10.1016/j.energy.2011.01.032>
- Türkiye Elektrik İletim A.Ş. (TEİAŞ) (2024). “Türkiye Elektrik Kurulu Güç istatistikleri”, <https://www.teias.gov.tr>, (10.01.2025).
- Varürer, İ., Özaydın, Ö., ve Çemrek, F. (2025). BIST100 Endeksi Fiyatının LSTM, CNN-LSTM ve BILSTM Modelleri ile Tahmin Edilmesi. *Ekonomi ve Yönetim Araştırmaları Dergisi*, 14(2), 1-24. <https://izlik.org/JA39JZ57FD>
- Yılmaz, M.C. ve Orman, Z. (2021). LSTM Derin Öğrenme Yaklaşımı ile Covid-19 Pandemi Sürecinde Twitter Verilerinden Duygu Analizi, *Acta Infologica*, 5(2), 359-372. <https://doi.org/10.26650/acin.947747>
- Yılmaz, H. (2025). Yapay Sinir Ağları Yöntemiyle BIST 100 Endeksi Tahmini. *Business & Management Studies: An International Journal*, 13(3), 1240-1259. <https://doi.org/10.15295/bmij.v13i3.2621>

- Günay, B., Kocarık Gacar, B. & Sandal, M. (2026). Hidroelektrik Enerji Üretiminin Tahmini: Derin Öğrenme Yaklaşımı ile ARIMA Modelinin Karşılaştırılması. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 28(52), 687-706.
- Wang, S., Yang, B., Chen, H., Fang, W., and Yu, T. (2022). LSTM-Based Deformation Prediction Model of the Embankment Dam of the Danjiangkou Hydropower Station. *Water*, 14(16), 2464. <https://doi.org/10.3390/w14162464>
- Zarfl, C., Berlekamp, J., He, F., Jähnig, S. C., Darwall, W., and Tockner, K. (2019). Future Large Hydropower Dams Impact Global Freshwater Megafauna. *Scientific Reports*, 9(1),18531. <https://doi.org/10.1038/s41598-019-54980-8>
- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)
- Zhou, F., Li, L., Zhang, K., Trajcevski, G., Yao, F., Huang, Y., et al. (2020). Forecasting the Evolution of Hydropower Generation. *In Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 2861-2870).

Extended Abstract

Forecasting Hydroelectric Energy Production: A Comparison of Deep Learning Approach and ARIMA Model

The use of electrical energy, which constitutes a fundamental input for economic activities, has increased substantially with rapid technological advancements, urbanization, and industrial expansion. This trend has significantly increased the share of electricity consumption within total energy demand worldwide. In developing and emerging economies such as Türkiye, ensuring a stable, reliable, and sustainable electricity supply has become a strategic priority. Within this context, hydroelectric power plants (HPPs) represent one of the major renewable energy sources contributing to national energy security and sustainability goals.

Hydroelectric power plants generate electricity by converting the potential and kinetic energy of water into electrical energy through turbine-generator systems. Although characterized by relatively high initial investment and infrastructure costs, HPPs offer long operational lifespans and comparatively low marginal production costs. In addition, hydroelectric generation plays a critical role in balancing electricity supply and demand due to its operational flexibility. However, hydroelectric production is inherently influenced by hydrological variability, seasonal precipitation patterns, reservoir levels, and climatic conditions. These factors introduce uncertainty and volatility into generation patterns, thereby increasing the importance of accurate production forecasting for effective energy planning and system management.

Against this background, the present study aims to predict the daily electricity generation potential of hydroelectric power plants in Türkiye using a deep learning approach and to compare its performance with a conventional time series method. To ensure regional representation, the two highest-producing hydroelectric power plants in each of Türkiye's seven geographical regions were selected, resulting in a total of 14 plants. The selected plants include major facilities such as Karakaya, Keban, and Atatürk dams, as well as medium-scale plants with varying production characteristics. Hourly generation data obtained from the Enerji Piyasaları İşletme A.Ş. (EPIAŞ) transparency platform were converted into daily production series to enhance modeling stability and reduce high-frequency noise. The analysis covers the 2022-2024 period, and forecasts were generated for 2025. Data preprocessing, normalization, model training, and performance evaluation were conducted using the Python programming language within the Google Colab environment.

To evaluate forecasting performance, the Autoregressive Integrated Moving Average (ARIMA) model-one of the most widely used classical time series approaches-and the Long Short-Term Memory (LSTM) neural network-a deep learning architecture designed to capture long-term dependencies-were compared. Prior to model implementation, the Augmented Dickey-Fuller (ADF) unit root test was applied to assess the stationarity of the production series. The results indicated that all series were stationary, thereby satisfying the assumptions required for ARIMA modeling. Model performance was assessed using two widely accepted accuracy metrics: Root Mean Square Error (RMSE) and Mean Absolute Error (MAE), which quantify the deviation between predicted and actual values.

The empirical findings demonstrate that the LSTM model generally outperformed the ARIMA model across all 14 hydroelectric power plants in terms of both RMSE and MAE. The superiority of LSTM was particularly evident in production series exhibiting higher volatility and nonlinear patterns. Due to its gated memory structure, LSTM was able to capture long-term dependencies and complex temporal dynamics more effectively than the linear ARIMA framework. In contrast, for plants characterized by relatively stable and less volatile production patterns-such as Oymapınar and Ermenek-the performance gap between ARIMA and LSTM narrowed. This suggests that classical time series models may remain competitive in environments where structural variability is limited and linear dynamics dominate.

Based on the superior predictive accuracy of LSTM, production forecasts for 2025 were generated using this model. The estimated prediction intervals were wider for high-capacity plants such as Karakaya, Keban, and Atatürk, reflecting greater variability and uncertainty associated with larger-scale production systems. Moreover, projections indicate that production levels in 2025 may decline compared to 2024 for most plants, except for Oymapınar, Akköprü, and Aksu. These differences highlight the heterogeneous production structures and regional hydrological characteristics of the selected facilities.

Despite the strong forecasting performance achieved by the LSTM model, hydroelectric generation remains highly sensitive to external factors such as seasonal precipitation patterns, hydrological flows, reservoir management strategies, maintenance activities, and unexpected operational constraints. Therefore, future research may benefit from incorporating exogenous meteorological and hydrological variables-such as precipitation, temperature, humidity, and inflow data-into multivariate modeling frameworks. Such extensions could further improve forecasting robustness and practical applicability.

Overall, the findings of this study provide methodological insights into the comparative performance of classical time series and deep learning models in hydroelectric production forecasting. By demonstrating the advantages of LSTM in capturing nonlinear and volatile generation patterns, this research contributes to the literature on energy forecasting and offers practical implications for energy planning, investment decision-making, and sustainable resource management in Türkiye.
