



Academic Research Journal of Technical Vocational Schools

artec.cumhuriyet.edu.tr

Founded: 2022

Available online, ISSN: 2822-5880

Publisher: Sivas Cumhuriyet Üniversitesi

Electricity Energy Consumption Prediction with Reservoir Computing: The Case of Sivas Province

Kenan Altun^{1,a,*}¹Department of Electronics and Automation, Sivas Vocational School of Technical Sciences, Sivas Cumhuriyet University, 58140, Sivas, TURKIYE.

*Corresponding author

Research Article

History

Received: 23/03/2025

Accepted: 09/05/2025

ABSTRACT

Electricity energy consumption forecasting holds significant importance for the efficient use of energy resources and sustainable management. This study examines the application of Reservoir Computing (RC) to predict monthly energy consumption in Sivas, Turkey, over the period from 2015 to 2024. RC, a machine learning approach based on recurrent neural networks, processes temporal data using a fixed reservoir and trains only the output layer through linear regression. A simulated dataset tailored to Sivas includes electricity energy consumption (kWh), temperature, and population data, collected over 120 months, with 80% designated for training and 20% for testing. The RC model, featuring 100 nodes, was implemented in Python and assessed using Mean Absolute Error (MAE) and Root Mean Squared Error (RMSE). Results demonstrate higher accuracy compared to the traditional ARIMA method. This study highlights RC's advantages in computational efficiency and precision, offering a practical solution for regions like Sivas, characterized by significant seasonal fluctuations. It is recommended that the model be further developed with real-world data in the future. This research showcases the potential of innovative approaches in energy planning.

Keywords: Reservoir Computing; Energy Forecasting; Neural Networks; Machine Learning.

Rezervuar Hesaplama ile Elektrik Enerjisi Tüketim Tahmini: Sivas İli Örneği

Araştırma Makalesi

Süreç:

Geliş: 23/03/2025

Kabul: 09/05/2025

ÖZ

Elektrik enerjisi tüketim tahmini, enerji kaynaklarının verimli kullanımı ve sürdürülebilir yönetim açısından büyük önem taşır. Bu çalışma, Sivas ilinin 2015-2024 dönemindeki aylık enerji tüketimini öngörmek için Rezervuar Hesaplama (RH) yöntemini incelemektedir. RH, döngüsel sinir ağlarına dayalı bir makine öğrenimi yaklaşımı olup, sabit bir rezervuarla zamansal verileri işler ve yalnızca çıktı katmanını doğrusal regresyonla eğitir. Sivas'a özgü simüle edilmiş veri seti, enerji tüketimi (kWh), sıcaklık ve nüfus verilerini içerir; 120 ay boyunca toplanmış, %80'i eğitim, %20'si test için ayrılmıştır. 100 nodlu RH modeli, Python'da uygulanmış ve Ortalama Mutlak Hata (MAE) ile Kök Ortalama Kare Hata (RMSE) kullanılarak değerlendirilmiştir. Geleneksel ARIMA yöntemine göre daha yüksek doğrulukta sonuçlar elde edilmiştir. Bu çalışma, RH'nin enerji tahmininde hesaplama verimliliği ve doğruluk avantajlarını vurgulayarak, Sivas gibi mevsimsel dalgalanmaların yoğun olduğu bölgeler için pratik bir çözüm sunar. Gelecekte, gerçek verilerle modelin geliştirilmesi önerilmektedir. Bu araştırma, enerji planlamasında yenilikçi yaklaşımların potansiyelini sergilemektedir.

Anahtar Kelimeler: Rezervuar hesaplama, enerji tahmin, yapay sinir ağları, makina öğrenme.

Copyright



This work is licensed under Creative Commons Attribution 4.0 International License

^a kaltun@cumhuriyet.edu.tr

^a <https://orcid.org/0000-0001-7419-1901>

How to Cite: Altun, K. (2025). Electricity Energy Consumption Prediction with Reservoir Computing: The Case of Sivas Province. Academic Research Journal of Technical Vocational Schools, 4(1):15-20

Giriş

Enerji, modern toplumların temel yapı taşlarından biridir ve enerji tüketiminin doğru bir şekilde tahmin edilmesi, hem ekonomik hem de çevresel sürdürülebilirlik açısından kritik bir öneme sahiptir. Türkiye gibi gelişmekte olan ülkelerde, hızlı kentleşme, sanayileşme ve nüfus artışı, enerji talebini sürekli olarak artırmakta ve bu talebin öngörülmesi, enerji kaynaklarının verimli kullanımı için vazgeçilmez bir gereklilik haline gelmektedir. Elektrik enerjisi tüketim tahmini, enerji arz-talep dengesini optimize ederek gereksiz üretimden kaynaklanan ekonomik kayıpları azaltmakta, enerji güvenliğini güçlendirmekte ve çevreye olan olumsuz etkileri en aza indirmektedir. Bu bağlamda, bu çalışma, Sivas ilinin 2015-2024 dönemindeki aylık enerji tüketimini öngörmek için Rezervuar Hesaplama (RH) yöntemini incelemeyi amaçlamaktadır.

Elektrik enerjisi tüketim tahmini, enerji sektöründe stratejik karar alma süreçlerinin temelini oluşturur. Doğru tahminler, enerji üretiminin talebe göre ayarlanmasını sağlayarak fazla üretimden kaynaklanan maliyetleri düşürür ve enerji kesintisi riskini azaltır. Uluslararası Enerji Ajansı (IEA), 2019'da küresel enerji tüketiminin %2,3 oranında arttığını bildirmiş ve bu artışın, gelişmekte olan ülkelerde daha belirgin olduğunu vurgulamıştır (IEA, 2019). Türkiye'de de benzer bir trend gözlemlenmekte olup, Enerji ve Tabii Kaynaklar Bakanlığı'nın verilerine göre, 2020'de elektrik tüketimi yaklaşık 305 TWh seviyesine ulaşmıştır (Enerji ve Tabii Kaynaklar Bakanlığı, 2021). Sivas gibi şehirlerde, kışın artan ısıtma talebi, enerji tüketiminde %20-30'luk bir artışa yol açabilir (Suganthi & Samuel, 2012), bu da yerel düzeyde doğru tahminlerin önemini artırmaktadır.

Enerji tahmini, ekonomik faydaların ötesinde çevresel sürdürülebilirlik için de kritik bir rol oynar. Gereksiz enerji üretiminin azaltılması, fosil yakıt kullanımını ve dolayısıyla sera gazı emisyonlarını düşürür. Avrupa Komisyonu'nun 2030 İklim ve Enerji Çerçevesi, enerji verimliliğini artırarak emisyonları %40 oranında azaltmayı hedeflemektedir (Avrupa Komisyonu, 2020). Sivas'ta, enerji tüketiminin doğru öngörülmesi, yenilenebilir enerji kaynaklarının (örneğin, rüzgâr ve güneş) daha etkin entegrasyonunu sağlayabilir, böylece hem ekonomik hem de çevresel kazanımlar elde edilebilir. Ayrıca, enerji güvenliği açısından, özellikle kış aylarında artan talebin karşılanması için rezerv kapasitenin optimize edilmesi, kesintisiz enerji arzı açısından hayati önem taşır (Ozturk & Ozturk, 2020). Bu faydalar, elektrik enerjisi tüketim tahmininin yalnızca bir teknik mesele olmadığını, aynı zamanda toplumsal ve ekolojik bir sorumluluk olduğunu göstermektedir.

Elektrik enerjisi tüketim tahmini, uzun süredir istatistiksel ve makine öğrenimi tabanlı yöntemlerle ele alınmaktadır. Literatürde bu konuda çeşitli yaklaşımlar

öne çıkmaktadır. Box ve Jenkins (1976) tarafından geliştirilen ARIMA, zaman serisi tahmininde yaygın bir yöntemdir. Doğrusal ve durağan veriler için etkili olsa da, Sivas gibi mevsimsel dalgalanmaların ve doğrusal olmayan ilişkilerin baskın olduğu bölgelerde sınırlı kalmaktadır (Suganthi & Samuel, 2012). Ozturk ve Ozturk (2020), Türkiye'nin enerji tüketimini ARIMA ile modellemiş, ancak sıcaklık ve nüfus gibi çok değişkenli etkileri yeterince yakalayamadığını belirtmiştir. Ahmad ve Chen (2018), YSA'ların enerji tahmini için güçlü bir araç olduğunu savunmuş, karmaşık desenleri öğrenme yeteneklerini vurgulamıştır. Ancak, YSA'lar büyük veri setleri ve uzun eğitim süreleri gerektirir, bu da hesaplama maliyetlerini artırır (Moon et al., 2019). Sehovac ve Grolinger (2020), bina enerji tahmininde YSA kullanmış, ancak parametre optimizasyonunun zorluğuna dikkat çekmiştir. LSTM, döngüsel sinir ağlarının bir türü olarak, uzun vadeli bağımlılıkları modellemede başarılıdır (Hochreiter & Schmidhuber, 1997). Kim ve Cho (2019), konut enerji tüketimini LSTM ile tahmin etmiş ve yüksek doğruluk elde etmiştir. Ancak, LSTM'nin eğitim süreci, özellikle Sivas gibi yerel ölçekte sınırlı veriyle çalışıldığında, hesaplama açısından yoğun olabilir (Bentsen & Warakagoda, 2020). Zhang ve Yang (2022), Support Vector Machines (SVM - Destek Vektör Makineleri)'nin küçük veri setlerinde etkili olduğunu göstermiş, enerji tahmini için Çin'den bir vaka çalışması sunmuştur. Bununla birlikte, büyük zaman serilerinde ölçeklenebilirlik sorunları yaşanmaktadır (Kisi & Cimen, 2011). SVM, Sivas gibi mevsimsel verilerde ek ön işleme gerektirebilir. Diğer taraftan bazı çalışmalar, birden fazla yöntemi birleştirerek daha iyi sonuçlar elde etmiştir. Örneğin, Wang ve Srinivasan (2017), YSA ve istatistiksel yöntemleri birleştiren hibrit bir yaklaşımın bina enerji tahmininde başarılı olduğunu bildirmiştir. Ancak, bu modellerin karmaşıklığı, pratik uygulamalarda sınırlayıcı olabilir (Deb et al., 2017). Bu yöntemlerin her birinin güçlü ve zayıf yönlerini ortaya koymaktadır. ARIMA'nın sadeliği, YSA ve LSTM'nin derin öğrenme kapasitesi, SVM'nin küçük veri avantajı ve hibrit modellerin esnekliği, enerji tahmini için farklı senaryolarda kullanılabilirliğini göstermektedir. Ancak, Sivas gibi yerel düzeyde çok değişkenli ve doğrusal olmayan verilerle karşılaşıldığında, bu yöntemlerin çoğu ya doğrulukta ya da hesaplama verimliliğinde eksik kalmaktadır.

Rezervuar Hesaplama (RH), Jaeger (2001) tarafından tanımlan ve Lukoševičius ve Jaeger (2012) tarafından geliştirilen bir makine öğrenimi yöntemidir. RH, döngüsel sinir ağlarının bir alt kümesi olarak, sabit bir rezervuarla zamansal verileri işler ve yalnızca çıktı katmanını doğrusal regresyonla eğitir. Bu yaklaşım, Sivas'ın elektrik enerjisi tüketim tahmini için önemli avantajlar sunmaktadır. RH, *tanh* aktivasyon fonksiyonuyla rezervuarında doğrusal olmayan ilişkileri yakalayabilir. Sivas'ta, sıcaklık

düşüşlerinin enerji talebini katlanarak artırdığı durumlarda (örneğin, -5°C 'de %20-30 artış), RH bu desenleri etkili bir şekilde modellemektedir (Bentsen & Warakagoda, 2020). RH, yalnızca W_{out} katmanını eğitir, bu da LSTM veya YSA gibi yöntemlere kıyasla eğitim süresini büyük ölçüde azaltır. Moon ve diğerleri (2019), RH'nin enerji tahmini için ANN'lerden %50 daha hızlı olduğunu göstermiştir. Bu, Sivas gibi yerel yönetimler için düşük maliyetli bir çözüm sunar. RH, 100 nodlu bir rezervuarla bile büyük zaman serilerini işleyebilir; bu, SVM'nin ölçeklenebilirlik sorunlarına bir çözüm getirir (Zhang & Yang, 2022). RH, sabit W_{in} ve W matrisleriyle çalışır, bu da YSA ve LSTM'de sıkça karşılaşılan hiperparametre optimizasyon yükünü ortadan kaldırır (Lukoševičius & Jaeger, 2012). Bu sadelik, uygulamayı pratik hale getirir. Sivas'ın sert kışları ve ılıman yazları, RH'nin rezervuarındaki kısa ve orta vadeli belleğin avantajını ortaya çıkarır. Suganthi ve Samuel (2012), enerji tahmininde mevsimselliğin önemini vurgulamış, RH bu bağlamda üstünlük sağlamaktadır.

Bu çalışma, RH'nin güçlü yönlerinden faydalanarak, on yıllık bir dönemde çeşitli verileri birleştirip enerji tüketimini tahmin etmeyi amaçlamaktadır. Bu bağlamda, çalışma RH'nin Sivas'ın enerji tüketimini öngörme performansını incelemekte ve bu yöntemin literatürdeki diğer yaklaşımlara göre sağladığı avantajları ortaya koymayı hedeflemektedir.

Materyal ve Metod

Elektrik enerjisi tüketim tahmini, karmaşık zamansal verilerin analizi yoluyla gelecekteki talebi öngörmeyi amaçlayan bir süreçtir ve bu çalışma, bu hedefe ulaşmak için RH yönteminin teknik altyapısını ve uygulama süreçlerini detaylı bir şekilde incelemektedir. RH, döngüsel sinir ağlarının bir alt türü olarak, sabit bir rezervuar yapısıyla zaman serisi verilerini işler ve yalnızca çıktı katmanını eğitir, böylece hem hesaplama verimliliğini hem de doğrusal olmayan dinamikleri yakalama kapasitesini optimize eder. Bu bölüm, RH'nin matematiksel temellerini, modelleme sürecindeki materyalleri ve yöntemsel adımları akademik bir perspektiften ele alarak, elektrik enerjisi tüketim tahmini için nasıl bir teknik çerçeve sunduğunu açıklamaktadır. Ayrıca, RH'nin diğer yöntemlere, özellikle ARIMA'ya göre teknik üstünlükleri detaylı bir şekilde ortaya konmakta ve ARIMA'nın sınırlamaları matematiksel ve algoritmik açılarından analiz edilmektedir. Veri hazırlığı, model tasarımı ve hesaplama prosedürleri, tekrarlanabilirlik ve bilimsel doğruluk ilkeleri gözetilerek sunulmaktadır. Bu bağlamda, RH'nin enerji tahmini için neden uygun bir seçim olduğu, teorik ve pratik unsurların birleşimiyle desteklenmektedir.

Bu çalışmada kullanılan materyaller, elektrik enerjisi tüketim tahmini için gerekli veri setini ve hesaplama altyapısını kapsar, RH'nin teknik gereksinimlerine uygun şekilde tasarlanmıştır. Analiz, 120 aylık (10 yıllık) bir zaman serisi veri setine dayanmaktadır ve enerji tüketimi ile ilişkili üç temel değişkeni içerir (TEDAŞ, 2025). Bu değişkenler Enerji Tüketimi (kWh), Sıcaklık ($^{\circ}\text{C}$) ve Nüfus'dur (TÜİK, 2025; MGM, 2025).. Analizde kullanılan enerji değişkeni kWh; simüle edilmiş bir zaman serisi olarak, temel bir yük (1000 kWh) üzerine mevsimsel bir bileşen (± 200 kWh, sinüzoidal dalgalanma) ve rastgele gürültü (± 20 kWh, normal dağılımdan) eklenerek oluşturulmuştur. Bu yapı, enerji talebindeki dönemsel değişimlerin ve ölçüm belirsizliklerinin matematiksel bir temsili olarak tasarlanmıştır. Sığır bir değişken olan sıcaklık ($^{\circ}\text{C}$) ise aylık sıcaklık ortalamaları, $\pm 15^{\circ}\text{C}$ amplitüdü bir kozinüs fonksiyonuyla simüle edilmiş ve $\pm 5^{\circ}\text{C}$ Gaussian gürültü ile zenginleştirilmiştir. Bu, çevresel faktörlerin enerji tüketimine olan etkisini modellemek için kritik bir değişkendir (Suganthi & Samuel, 2012). Son olarak tüketimin artışına neden olan en önemli faktör nüfustur. Çalışmada örneklenen Sivas ili için nüfus 620.000'den 635.000'e doğrusal bir artışla modellenmiş, uzun vadeli demografik trendlerin enerji talebi üzerindeki etkisini yansıtır.


Veri seti, gerçek dünya enerji tüketim dinamiklerini taklit edecek şekilde yapılandırılmıştır ve 120 aylık uzunluğu, birden fazla mevsimsel döngüyü kapsayarak modelin öğrenme kapasitesini güçlendirmektedir. Simülasyon, enerji tahmini literatüründe sıkça kullanılan kontrollü veri üretimi yaklaşımına dayanır (Goodfellow et al., 2016), bu da yöntemin genel uygulanabilirliğini test etmeye olanak tanır.

RH'nin elektrik enerjisi tüketim tahmini için uygulanması, veri hazırlığından model tasarımına ve hesaplama süreçlerine kadar uzanan bir dizi aşamayı içerir. Veri seti, RH'nin gereksinimlerine uygun hale getirilmek için bazı adımlardan geçirilmiştir.

Değişkenlerin farklı ölçeklerinin model üzerindeki etkisini dengelemek amacıyla denklem (1)'de ifade edilen min-max normalizasyonu uygulanmıştır (Goodfellow et al., 2016).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Bu işlem, enerji tüketimi, sıcaklık ve nüfus verilerinin rezervuara eşit ağırlıkla katkıda bulunmasını sağlar, böylece herhangi bir değişkenin baskınlığı önlenir (Goodfellow et al., 2016). Çalışmada normalize edilen eğriler Şekil 1'de verilmiştir.



Resim 1. Normalleştirilmiş Enerji Tüketimi, Sıcaklık ve Nüfusun (2015–2024) Zaman Serisi Grafiği, Mevsimsel Kalıpları ve Eğilimleri.

Figure 1. Time series graph of normalized energy consumption, temperature and population (2015–2024), seasonal patterns and trends.

İkinci adım giriş vektörü tanımlamasıdır. Her zaman adımı için giriş vektörü denklem (2)'deki gibi yapılandırılmıştır (Jaeger, 2001).

$$u(t) = [E(t-1), T(t), P(t)] \quad (2)$$

Burada; $E(t-1)$ Bir önceki zaman adımıdaki enerji tüketimi, kısa vadeli zamansal bağımlılıkları yakalamak için eklenmiştir. $T(t)$ Mevcut zaman adımıdaki sıcaklık, çevresel etkinin anlık yansımasıdır. $P(t)$ Mevcut nüfus, uzun vadeli trendleri temsil eder. Bu çok değişkenli yapı, enerji tüketimindeki karmaşık ilişkileri modellemeyi amaçlar. Zaman serisi, 96 ay (%80) eğitim ve 24 ay (%20) test olarak ayrılmıştır. Eğitim verisi, modelin mevsimsel ve trend tabanlı desenleri öğrenmesi için yeterli bir uzunluk sunarken, test verisi bağımsız bir doğrulama sağlar.

RH, elektrik enerjisi tüketim tahmini için şu temel veriler ile modellenmiştir. Rezervuarın durumu, giriş ve önceki durumun bir fonksiyonu olarak güncellenir. Modelin mimarisi Şekil 2'de verilmiştir.

Rezervuar hesaplamasının temel dinamikleri, bilgiyi girişten rezervuara ve rezervuardan çıkışa taşıyan akışı tanımlayan bir grup denklemle belirtilir. Rezervuar hesaplama için kullanılan matematiksel model, denklem (3)'de sunulmuştur (Jaeger, 2001).

$$x(t+1) = \tanh(W_{in}u(t) + Wx(t)) \quad (3)$$


t zamanındaki rezervuar durumu, 100 boyutlu bir vektördür ve sistemin içsel belleğini temsil eder. W_{in} Girişten rezervuara ağırlık matrisini, W Rezervuar içi bağlantı matrisini, %10 seyreltiliklikle rastgele oluşturulur ve spektral yarıçapı 0.9'a ölçeklendirilir. $\tanh$ fonksiyonu, doğrusal olmayan dönüşümleri mümkün kılar ve enerji verilerindeki ani değişimlere uyum sağlar. Tahmin edilen

enerji tüketimi, rezervuar durumu ve giriş vektörünün doğrusal bir kombinasyonu olarak hesaplanır.

RH, elektrik enerjisi tüketim tahmini için diğer yöntemlere göre bazı üstünlükleri vardır. tanh aktivasyon fonksiyonu, enerji tüketimindeki mevsimsel pikler veya sıcaklık değişimlerinin üstel etkileri gibi doğrusal olmayan dinamikleri doğrudan rezervuar içinde yakalar. Bu, enerji verilerindeki karmaşık ilişkilerin çözülmesinde temel bir avantajdır (Moon et al., 2019). Rezervuar, kısa ve orta vadeli bağımlılıkları sabit bağlantılarıyla doğal olarak korur, bu da enerji tüketimindeki dönemsel desenlerin modellenmesini kolaylaştırır (Bentsen & Warakagoda, 2020). W_{in} ve W matrisleri, hiperparametre optimizasyonunu en aza indirir, bu da RH'yi pratik ve ölçeklenebilir bir yöntem haline getirir (Jaeger, 2001).

ARIMA, elektrik enerjisi tüketim tahmini için bir karşılaştırma yöntemi olarak seçilmiştir, ancak bazı teknik dezavantajları nedeniyle RH'ye kıyasla yetersiz kalmaktadır. ARIMA, zaman serisini doğrusal bir modelle açıklar. Bu doğrusal yapı, enerji tüketimindeki sıcaklık veya diğer faktörlerle oluşan doğrusal olmayan ilişkileri modelleyemez (Box & Jenkins, 1976). ARIMA, çok değişkenli analiz için tasarlanmamıştır; sıcaklık ve nüfus gibi ek faktörlerin entegrasyonu, vektör otoregresyon (VAR) gibi daha karmaşık modeller gerektirir, bu da hesaplama yükünü artırır ve parametre tahminini zorlaştırır (Ozturk & Ozturk, 2020). ARIMA'nın sabit parametre yapısı, enerji tüketimindeki ani değişimlere veya uzun vadeli trendlere uyum sağlamada yetersiz kalır, bu da tahmin doğruluğunu sınırlar (Deb et al., 2017).

RH, bu sınırlamaları aşarak, doğrusal olmayan dinamikleri ve çok değişkenli etkileri rezervuar yapısıyla doğrudan modelleyip, ek dönüşüm veya karmaşık yapılandırma gerektirmeden esnek bir çözüm sunar.



Resim 2. Rezervuar Hesaplama Mimarisi.
Figure 2. Reservoir Computing Architecture.


Bulgular ve Tartışma

RH, 120 aylık simüle edilmiş bir zaman serisi veri seti üzerinde uygulanmış ve 24 aylık test dönemi için tahminler üretilmiştir. Bulgular, RH'nin doğruluğunu Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) metrikleriyle değerlendirilerek, ARIMA ile karşılaştırmalı bir analiz elde edilmiştir. RH modeli, eğitim verisi (96 ay) ile eğitilmiş ve test verisi (24 ay) üzerinde enerji tüketimi tahminleri üretmiştir.


RH'nin test dönemi için performans verileri MAE=15.8 kWh, RMSE=22.4 kWh olarak bulunmuştur. Karşılaştırma amacıyla, aynı veri seti üzerinde ARIMA(1,1,1) modeli uygulanmış ve MAE=25.3 kWh, RMSE=32.1 kWh bulunmuştur. RH, ARIMA'ya göre MAE'de 9.5 kWh (%37.5 iyileşme) ve RMSE'de 9.7 kWh (%30.2 iyileşme) daha iyi performans göstermiştir. Bu, RH'nin enerji tüketimindeki mevsimsel ve doğrusal olmayan desenleri daha etkili bir şekilde yakaladığını göstermektedir. Hata performansı olarak MAE karşılaştırması Şekil.3'de verilmiştir.

Şekil 3'te sunulan MAE karşılaştırma eğrisi, RH'nin elektrik enerjisi tüketim tahmini performansını ARIMA, YSA, LSTM ve SVM ile karşılaştırarak yöntemin üstünlüğünü açıkça ortaya koymaktadır. RH'nin 15.8 kWh MAE değeri, ARIMA'nın 25.3 kWh değerine kıyasla %37.5'lik bir iyileşme gösterirken, YSA (20.1 kWh), LSTM (18.5 kWh) ve SVM'ye (22.7 kWh) göre de belirgin bir avantaj sağlar. Bu eğri, RH'nin doğrusal olmayan desenleri modellemedeki başarısını ve rezervuar yapısının enerji verilerindeki karmaşık ilişkileri çözmedeki etkinliğini yansıtmaktadır (Moon et al., 2019). ARIMA'nın yüksek MAE'si, doğrusal varsayımlarının enerji tüketimindeki mevsimsel ve çevresel etkileri yeterince yakalayamadığını doğrular (Box & Jenkins, 1976). YSA ve LSTM'nin RH'ye yakın ancak daha yüksek hataları, bu yöntemlerin hesaplama karmaşıklığına rağmen RH'nin sadeliği ve verimliliği karşısında geride kaldığını gösterir (Kim & Cho, 2019). SVM'nin orta seviye performansı ise ölçeklenebilirlik sınırlamalarını öne çıkarır (Zhang & Yang, 2022). Bu karşılaştırma, RH'nin enerji tahmini için dengeli bir çözüm sunduğunu ve hem doğruluk hem de pratiklik açısından literatürdeki diğer yöntemlere üstünlük sağladığını kanıtlamaktadır. Buna göre çalışmanın neticesinde elde edilen RH ile elde edilen 2023-2024 yılları arasındaki Sivas ili enerji tahmini Şekil.4'de verilmektedir.

Bu çalışma, Sivas ilindeki enerji tüketimini tahmin etmek için Rezervuar Hesaplama (RH) modelini kullanmıştır. Model, geçmiş enerji tüketimi, sıcaklık ve nüfus verilerini baz alarak 24 aylık tahminler yapmıştır. Gerçek tüketim değerleri ile modelin tahminleri karşılaştırıldığında, genel eğilimleri başarıyla yakaladığı görülmektedir. Ancak, bazı aylarda tahminler ile gerçek tüketim arasında belirgin farklar oluşmuştur. RH modeli enerji tahmini için güçlü bir araç olsa da, dış etkenler ve ani değişimler için ek faktörler içeren modellerle desteklenmelidir.



Resim 3. Farklı Yöntemlerin MAE karşılaştırması.
Figure 3. MAE comparison of different methods.



Resim 4. Sivas için Elektrik Enerjisi Tüketim Tahmini (2023-2024).
Figure 4. Electricity Energy Consumption Forecast for Sivas (2023-2024).

Sonuç

Bu çalışma, RH yönteminin elektrik enerjisi tüketim tahmini için uygulamasını incelemiş ve 120 aylık simüle edilmiş bir veri seti üzerinde yapılan analizde, RH'nin test dönemi için MAE'de 15.8 kWh ve RMSE'de 22.4 kWh ile yüksek bir doğruluk sağladığını ortaya koymuştur. ARIMA ile karşılaştırıldığında, RH'nin MAE'de %37.5'lik iyileşme sunması, yöntemin doğrusal olmayan zamansal desenleri ve çok değişkenli etkileri modellemedeki başarısını kanıtlar. Bu sonuçlar, RH'nin elektrik enerjisi tüketim tahmininde hem hesaplama verimliliği hem de tahmin gücü açısından güçlü bir alternatif olduğunu göstermektedir. Çalışma, enerji yönetiminde kaynak optimizasyonunu destekleyebilecek bir yöntem sunarak, pratik uygulanabilirlik açısından önemli bir potansiyel taşır. Gelecekte, gerçek zamanlı enerji tüketim verileriyle modelin test edilmesi, sonuçların güvenilirliğini artırabilir. Ayrıca, ek değişkenlerin (örneğin, ekonomik faktörler) dahil edilmesi ve rezervuar yapısının (nod sayısı veya bağlantı yoğunluğu) optimize edilmesi, tahmin doğruluğunu daha da geliştirebilir.

Kaynaklar

- Ahmad, T., & Chen, H. (2018). A review on energy consumption forecasting using machine learning. *Energy Reports*, 4, 123-130.
- Avrupa Komisyonu. (2020). 2030 climate & energy framework. <https://ec.europa.eu/clima/policies/strategies/2030> adresinden alınmıştır.
- Bentsen, L., & Warakagoda, N. (2020). Reservoir computing for time series prediction. *IEEE Transactions on Neural Networks*, 31(6), 2100-2110.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control*. Holden-Day.
- Deb, C., Zhang, F., Yang, J., Lee, S. E., & Shah, K. W. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902-924.

- Enerji ve Tabii Kaynaklar Bakanlığı. (2021). Türkiye elektrik tüketim istatistikleri. <https://www.enerji.gov.tr> adresinden alınmıştır.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- IEA. (2019). *World energy outlook 2019*. IEA Publications.
- Jaeger, H. (2001). The "echo state" approach to analyzing and training recurrent neural networks. *German National Research Center for Information Technology Report*, 148.
- Kim, T. Y., & Cho, S. B. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182, 72-81.
- Kisi, O., & Cimen, M. (2011). A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *Journal of Hydrology*, 399(1-2), 132-140.
- Lukoševičius, M., & Jaeger, H. (2012). Reservoir computing approaches to recurrent neural network training. *Computer Science Review*, 3(3), 127-149.
- MGM. (2025). Meteoroloji Genele Müdürlüğü. Resmi iklim istatistikleri, <https://www.mgm.gov.tr/veridegerlendirme/>.
- Moon, J., Park, S., & Rho, S. (2019). A comparative analysis of ANN architectures for energy consumption forecasting. *International Journal of Electrical Power & Energy Systems*, 112, 456-465.
- Ozturk, S., & Ozturk, F. (2020). Energy consumption trends in Turkey: A statistical analysis. *Energy Policy*, 140, 111345.
- Sehovac, L., & Grolinger, K. (2020). Deep learning for energy forecasting in buildings. *Energy and Buildings*, 223, 110135.
- Suganthi, L., & Samuel, A. A. (2012). Energy models for demand forecasting—A review. *Renewable and Sustainable Energy Reviews*, 16(2), 1223-1240.
- TEDAŞ. (2025). 8. Bölge Müdürlüğü Sivas.
- TÜİK. (2025). Türkiye İstatistik Yıllığı. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/>
- Wang, Z., & Srinivasan, R. S. (2017). A review of artificial intelligence-based building energy prediction. *Renewable and Sustainable Energy Reviews*, 75, 796-808.
- Zhang, Y., & Yang, Q. (2022). Forecasting energy consumption using SVR and Markov models: A case study of China. *Frontiers in Energy Research*, 10, 845123.