



Short-Term Electricity Load Forecasting Using Artificial Intelligence (Artificial Neural Networks) Method and Meteorological Data for Sivas-Central 1st Organized Industrial Zone

Seyit Ahmet Keklikci^{1,a,*}, Yunis Torun^{2,b}

¹ Ahmetturgazi OSB Mahallesi 5.Cad. 10.Sk. No:2, Merkez/Sivas 58060, Türkiye

²Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği, Merkez/SİVAS 58140, Türkiye

*Corresponding author

Research Article

History

Received: 05/04/2025

Accepted: 02/05/2025

Copyright



This work is licensed under
Creative Commons Attribution 4.0
International License

ABSTRACT

The effective use of electricity, accurate prediction methods are becoming important for energy planning and prevention of imbalance costs. Efficient, high-quality, and safe electricity supply processes are also crucial for maintaining the supply-demand balance in the electricity market. Therefore, it is necessary for electricity producers and suppliers to make good planning, and there is a need to predict unrealized consumption values for planning activities. The aim of this study is to make short-term electricity load forecasting for Sivas-Central 1st Organized Industrial Zone using meteorological data and past consumption values. It has been observed in the literature that artificial intelligence, especially Long Short-Term Memory (LSTM) architectures, are effectively used in the energy forecasting field. In this study, an LSTM architecture was created using Matlab/Simulink to make load forecasts. In this architecture, four cases are used using different data sets for input data. In the first case, only days of the year are used as input data sets. For the second case, "Month, Day of Month, Working Day and Days of Year" are used. For the third case, additional "Holiday Days, Holiday, Weekend, Normal Day, Dollar" data is used in the second case. In the fourth case, additional "Meteorology" data is used in the third case. As a result, the RMSE values for the four cases are as follows; RMSE1: 1501.897, RMSE2: 1005.312, RMSE3: 1343.179, RMSE4: 9342.352. This study aims to provide effective solutions in supply-demand balance and energy management. This study deeply analyzes the effect of different data combinations on LSTM-based consumption estimation and offers an original contribution in terms of showing that using more data does not always provide better estimation accuracy. The aim is to provide significant contribution to energy suppliers and industrial zones for accurate energy management through the predictions made.

Keywords: Artificial Neural Networks; Energy Costs; Electricity Consumption; Load Forecasting; LSTM;

Yapay Zekâ (Yapay Sinir Ağları) Yöntemi ve Meteoroloji Verilerini Kullanılarak Sivas-Merkez 1. Organize Sanayi Bölgesinin Kısa Dönem Elektrik Enerjisi Yük Tahmini

Süreç

Geliş: 05/04/2025

Kabul: 02/05/2025

Öz

Elektrik enerjisinin efektif bir şekilde kullanılması, enerji planlaması ve dengesizlik maliyetlerinin önlenmesi için doğru tahminleme yöntemleri önem kazanmaktadır. Verimli, kaliteli ve güvenli elektrik tedarik süreçleri elektrik piyasasındaki arz - talep dengesinin korunması için de oldukça önemlidir. Bu nedenle elektrik üretici ve tedarikçilerinin iyi planlama yapması, planlama çalışmalarını için de gerçekleşmemiş tüketim değerlerinin tahminlenmesi ihtiyacı doğmaktadır. Bu çalışmanın amacı, meteoroloji verileri ve geçmiş tüketim değerlerini kullanarak Sivas-Merkez 1. Organize Sanayi Bölgesi'nin kısa dönem elektrik yük tahmini yapmaktır. Literatürde yapay zekâ ve özellikle Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM) mimarilerinin enerji tahmini alanında etkin bir şekilde kullanıldığı görülmüştür. Bu çalışmada yük tahmini yapabilmek için Matlab/Simulink aracılığıyla LSTM mimarisi oluşturulmuştur. Bu mimaride giriş verileri için farklı veri setleri kullanılarak dört durum incelenmiştir. Birinci durumda giriş veri seti olarak sadece yılın günleri kullanılmıştır. İkinci durum için "Ay, Ayın Günü, Mesai Günü ve Yılın Günleri" kullanılmıştır. Üçüncü durum için ikinci duruma ek "Bayram Günleri, Tatil, Hafta sonu, Normal Gün, Dolar" verileri kullanılmıştır. Dördüncü durumda ise üçüncü duruma ek olarak "Meteoroloji" verileri kullanılmıştır. Sonuç olarak RMSE değerleri dört için sırası ile şu şekildedir; RMSE1:1501,897, RMSE2:1005,312, RMSE3:1343,179, RMSE4:9342,352. Bu çalışma ile arz talep dengesi ve enerji yönetiminde etkili çözümler sunulması amaçlanmıştır. Bu çalışma, farklı veri kombinasyonlarının LSTM tabanlı tüketim tahminine etkisini derinlemesine analiz ederek, daha fazla veri kullanımının her zaman daha iyi tahmin doğruluğu sağlamayacağını göstermesi bakımından özgün bir katkı sunmaktadır. Yapılan tahminlemelerle enerji tedarikçilerinin ve sanayi bölgelerinin doğru enerji yönetimi yapabilmeleri için önemli bir katkı sağlanması amaçlanmaktadır.

Anahtar Kelimeler: Elektrik Tüketimi; Enerji maliyetleri; LSTM; Yapay Sinir Ağları; Yük Tahmini;

Giriş

Elektrik enerjisi, sanayiden hanelere kadar geniş bir yelpazede ihtiyaç duyulan modern yaşamın temel unsurları arasında yer almaktadır. Ancak, sürdürülebilir ve istikrarlı enerji yönetimi için talep tahmini kritik öneme sahiptir. Geleneksel yöntemler genellikle geçmiş verilere dayalı temel istatistiksel modellerle sınırlıdır ve bu modellerdeki belirsizlikler ve hata payları enerji üretimini ve dağıtımını olumsuz yönde etkileyebilmektedir. Bu bağlamda, uzun-kısa süreli hafıza tabanlı yapay sinir Ağları (LSTM) başta olmak üzere yapay zeka uygulamaları, elektrik yükü tahmini alanında umut verici bir çözüm sunmaktadır. LSTM ağları, zaman serisi verileri üzerinde güçlü performans sergileyerek enerjinin geçmiş davranışları hakkında bilgi depolama yeteneği ile öne çıkar. Sonuç olarak bu çalışma, enerji talebinin karmaşık ve dinamik doğasını anlamak için modern yapıların ve manevra kabiliyetinin nasıl kullanılabileceğine dair yeni bakış açıları sunmaktadır. Bu kapsamda, LSTM ağlarının geçmiş verilere dayalı olarak tahmin gücünü artırması ve bu sayede enerji sektörü için daha akıllı ve daha etkin çözümler sunması hedeflenmektedir [1].

Sivas-Merkez 1.OSB Müdürlüğü'nün T.C. Enerji Piyasası Düzenleme Kurumu'ndan (EPDK) almış olduğu elektrik dağıtım lisansı kapsamında, Organize Sanayide elektrik dağıtımı, perakende satışı ve Enerji Yönetim Birimi hizmetleri yürütülmektedir. Bu bağlamda enerji yönetimi için çalışmalara ihtiyaç duyulmaktadır. Elektrik piyasasında, arz ve talep arasındaki ilişkinin dengede tutulabilmesi için elektrik üreticisi ve tedarikçisi şirketlerin güvenilir, kaliteli ve ekonomik üretim yapabilmeleri gerekmektedir. Bu bağlamda, efektif bir planlama yapabilmek için gelecekteki elektrik yük talebinin, en düşük sapma değerinde tahmin edilmesi büyük önem taşımaktadır. Türkiye'de elektrik piyasasını Enerji Piyasaları İşletme A.Ş. (EPIAŞ) işletir ve yönetir. Elektrik üreticileri ve tüketicileri, EPIAŞ tarafından işletilen Gün Öncesi ve Gün İçi Piyasalarına katılarak alım-satım işlemleri gerçekleştirir. Gün Öncesi Piyasası; bir sonraki gün teslim edilmek üzere elektrik enerjisinin alış ve satış işlemlerinin yapıldığı, organize bir toptan elektrik piyasasıdır. Bu piyasada sunulan arz ve talep tekliflerinin kesişmesiyle, elektrik birim fiyatı olan Piyasa Takas Fiyatı (PTF) belirlenir. Saatlik olarak ilan edilen PTF, ilgili saatteki elektrik enerjisinin baz maliyetini yansıtır. Tüm bunlar göz önünde bulundurulduğunda elektrik tüketiminin saatlik olarak tahmin edilmesi önem arz etmektedir.

Makine öğrenimi, kısa vadeli yük tahmininde yaygın olarak kullanılmaktadır. XGBoost gibi algoritmalar, geçmiş yük, hava durumu ve tatil gibi çeşitli kaynaklardan elde edilen özellikleri kullanarak yüksek doğrulukta tahminler yapabilir [2].

Kısa dönem elektrik yük tahmini, enerji yönetimi ve arz-talep dengesinin sağlanması açısından büyük bir öneme sahiptir. Doğru tahminler, enerji üretim ve dağıtım şirketlerinin maliyetlerini optimize etmesine, enerji tedarik zincirinde istikrar sağlamasına ve elektrik

fiyatlarındaki dalgalanmaları kontrol altına almasına katkı sağlamaktadır. Geleneksel istatistiksel yöntemler genellikle zaman serisi verileriyle sınırlı kalırken, yapay zeka tabanlı modeller (özellikle Yapay Sinir Ağları (Artificial Neural Networks, ANN) ve Derin Öğrenme (Deep Learning) yaklaşımları vb.) daha yüksek doğruluk sağlayarak bu alanda önemli bir avantaj sunmaktadır. Son yıllarda, LSTM, CNN ve hibrit modeller gibi gelişmiş yapay zeka yöntemleri, elektrik yük tahmini çalışmalarında giderek daha fazla tercih edilir hale gelmiştir. Bu literatür özeti, farklı yapay zeka yaklaşımlarının kısa dönem elektrik yük tahmini üzerindeki etkilerini inceleyen güncel akademik çalışmalara odaklanmaktadır.

Yapay sinir ağlarıyla geliştirilen tahmin modellerine yönelik bir diğer çalışmada Özerdem ve arkadaşları, Parçacık Sürü Optimizasyonu (PSO) algoritmasını kullanarak ANN tabanlı sistemlerin performansını artırmayı hedeflemiştir. Çalışmalarında, PSO algoritmasıyla ANN'nin tahmin doğruluğunu önemli ölçüde iyileştirdiğini ve optimizasyon sürecinin tahmin hatasını ciddi şekilde azalttığını ortaya koymuştur [3]. Benzer şekilde, Bouktif gerçekleştirdiği bir çalışmada, LSTM modeli elektrik yükü tahmini, hiperparametre ayarlarıyla optimize edilmiş makine öğrenim modellerine kıyasla daha yüksek doğruluk göstermektedir. LSTM'nin uzun vadeli bağımlılıkları öğrenme yeteneği, kısa dönem yük tahminleri açısından önemli bir avantaj sağlamıştır [4]. Miao ve Nakamura'nın çalışmasında, geçmiş elektrik tüketim verileri ile meteorolojik değişkenleri birleştirerek ANN modellerinin doğruluğunu test etmiştir. Araştırma, mevsimsel ve hava durumu değişkenlerinin tahmin modeline entegre edilmesinin tahmin başarımını artırdığını ortaya koymuştur. Özellikle sıcaklık, nem ve rüzgar hızının elektrik tüketimi ile doğrudan ilişkili olduğu belirlenmiş ve ANN modellerinin hava durumu tahminleriyle entegre edilmesiyle daha güvenilir sonuçlar elde edilmiştir [5]. Sagwal ve Ramkumar tarafından yürütülen başka bir çalışmada, Tekrarlayan Sinir Ağları (RNN) ve Dikkat Mekanizmaları kullanılarak kısa dönem elektrik yük tahmini en verimli hale getirmeye çalışılmıştır. Çalışma kapsamında, elektrik fiyatlarındaki değişkenlik ve hava durumu faktörleri modele entegre edilmiş, sonuçlar ise fiyat ve meteorolojik değişkenlerin modele dahil edilmesinin tahmin doğruluğunu artırdığını göstermiştir [6]. Ghazal ve Janjua'nın çalışmasında, Convolutional Neural Networks (CNN) ile ANN modelleri bir araya getirilerek kısa dönem yük tahmini gerçekleştirilmiştir. Araştırma, CNN'nin zaman serisi verilerini daha iyi işlemesi sayesinde ANN'ye kıyasla daha hızlı ve daha doğru sonuçlar ürettiğini göstermiştir [7]. Benhra ve arkadaşları tarafından yapılan bir diğer çalışmada ise, meteorolojik değişkenlerin Random Forest ve ANN modelleriyle tahmin doğruluğuna etkileri irdelenmiştir. Araştırma, hava durumu faktörlerinin elektrik tüketim tahmininde belirleyici bir rol oynadığını ve özellikle sıcaklık ile nem gibi değişkenlerin yük tahmini doğruluğunu artırdığını ortaya koymuştur [8]. Shukla tarafından yapılan benzer bir araştırmada ise, ABD ve Hindistan'daki elektrik tüketim

modelleri analiz edilerek CNN, LSTM ve geleneksel tahmin yöntemleri karşılaştırılmıştır. Çalışma, hibrit modellerin farklı çevrelerde değişen performans gösterdiğini, ancak genel olarak ANN tabanlı yaklaşımların en başarılı sonuçları verdiğini ortaya koymuştur [9]. Nadali ve çalışma arkadaşları, enerji yönetimi alanında RNN ve LSTM tabanlı zaman serisi tahmin modellerinin etkinliğini araştırmıştır. Çalışma, geleneksel istatistiksel yöntemlerinin, RNN ve LSTM gibi derin öğrenme tabanlı yaklaşımlara kıyasla daha yüksek hata payına sahip olduğunu ortaya koymuştur. Özellikle LSTM'nin uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde, kısa dönem elektrik yük tahmini için daha doğru ve güvenilir sonuçlar ürettiği belirlenmiştir. Sonuçlar, LSTM'nin kısa vadeli tahmin uygulamalarında geleneksel yöntemlere kıyasla daha başarılı olduğunu göstermektedir [10].

Bu çalışmaların genel çerçevesi değerlendirildiğinde, LSTM ve CNN tabanlı derin öğrenme modellerinin, geleneksel zaman serisi analizlerine kıyasla daha yüksek doğruluk sağladığı görülmektedir. Hava durumu verilerinin kullanımı tahmin başarısını artırabilmekte, ancak veri kalitesi, ölçeklendirme süreçleri ve değişken seçimi gibi faktörlerin dikkatli bir şekilde ele alınması gerekmektedir. Hibrit modellerin kullanımı, tahmin doğruluğunu iyileştirme potansiyeline sahip olmakla beraber, bölgesel ve ekonomik değişkenler model performansını doğrudan etkileyebilmektedir. Gelecek çalışmalarda, tahmin modellerinin performansını iyileştirmek ve genelleme yeteneğini artırmak amacıyla yeni aktivasyon fonksiyonlarının ortaya konulması, hiper-parametre optimizasyonunun derinleştirilmesi ve transfer öğrenme tekniklerinin daha kapsamlı analiz edilmesi önerilmektedir.

Yük tahmini; elektrik enerjisi üretimi, alımı, satımı ve altyapı geliştirme gibi kararların alınmasına katkı sağlamaktadır. Ekonomik büyümeyi desteklemek ve gelecekteki elektrik enerjisi taleplerini karşılamak için yapılan tahminler, elektrik güç yönetimi ve planlaması için oldukça önemlidir. Elektrik yük tahmini, enerji santrallerinin planlanması ve işletilmesi için hayati öneme sahiptir. Doğru tahminler, enerji sistemlerinin verimli yönetilmesine olanak tanır ve gelecekteki projeler için avantajlar sağlar [11], [12].

Araştırmanın Önemi

Elektrik enerjisi, modern toplumların temel ihtiyaçlarından biri haline gelmiştir. Sürekli artan talepler, enerji yönetim sistemlerinin etkinliğinin artırılmasını gerekli kılmaktadır. Bu bağlamda, kısa vadeli elektrik yükü tahmini, enerji sağlayıcıları ve planlamacıları için kritik bir karar destek mekanizmasıdır. Doğru tahminler, enerji arzını taleple uyumlu hale getirmede, kaynakları verimli kullanmada ve maliyetleri düşürmede hassas bir rol oynar. Ayrıca geleneksel istatistiksel yöntemlerin yanı sıra yapay zeka uygulamaları da bu alana önemli katkılar sağlıyor. Bu araştırmanın amacı, LSTM yöntemi başta olmak üzere yapay sinir ağları teknolojisinin kısa vadeli elektrik yükü tahminindeki etkinliğini meteorolojik verilerle entegre ederek incelemektir. LSTM, özellikle zaman serisi verilerini

anlamada etkilidir ve geçmiş verileri göz önünde bulundurarak gelecekteki eğilimleri tahmin etme kapasitesine sahiptir. İklim değişikliklerinin ve hava olaylarının elektrik talebi üzerindeki etkilerini anlamak için derinlemesine bir analiz yapmak gerekmektedir. Araştırmanın önemi, bu tür yenilikçi yaklaşımların enerji sektörü üzerindeki etkisi ile ilgilidir. LSTM tabanlı modellenmiş tahminler, dalgalanmaların tahmin edilmesine, talep yoğunluklarının belirlenmesine ve enerji kaynaklarının optimizasyonuna olanak tanır. Bu çerçevede hem teorik hem de pratik açıdan elde edilen bulgular, enerji yönetiminde yenilikçi çözümler arayan paydaşlar için değerli ön görüler sunacaktır.

Materyal ve Metot

Elektrik yük tahmini kısa, orta ve uzun dönem için yapılabilmektedir. Saatlik ve günlük tahminler kısa dönem, aylık ve yıllık tahminler ise orta ve uzun dönem tahminler olarak sınıflandırılmaktadır. Özellikle enerji sektöründe artan rekabet koşulları nedeniyle kısa dönem yük tahminleri üretici firmalar için kritik bir öneme sahiptir. Yanlış yük tahminleri ciddi mali sonuçlar doğurabilir. Yetersiz tahminler, talebin karşılanamamasına ve mobil ünitelerin devreye alınarak maliyetlerin yükselmesine neden olurken; aşırı tahminler ise gereksiz birimlerin çalıştırılmasıyla işletme maliyetlerini artırmaktadır.

Enerji talep tahmininde kullanılan belirli matematiksel ve istatistiksel teknikleri kapsar. İki temel yaklaşım, zaman serisi analizi ve makine öğrenimi teknikleridir. Zaman serisi analizi, geçmiş enerji tüketimi verilerine dayanarak kısa dönemli tahminler oluştururken, işletme modellerini veya mevsimsel varyasyonları hesaba katar. Bu bağlamda, basit hareketli ortalamalar gibi yöntemler ön plana çıkar. Geçmiş veri noktalarının belirli bir kombinasyonunu kullanarak gelecekteki değerleri tahmin etmeye çalışırken, ihtiyaç duyulan parametrelerin belirlenmesi, modelin doğruluğunu büyük ölçüde etkileyen kritik bir aşamadır. Öte yandan, makine öğrenimi teknikleri, enerji yük tahmini için oldukça etkili bir yaklaşım sunar. Bu yaklaşım, geçmiş olayların zaman içindeki bağımlılıklarını öğrenerek, enerji talep tahminini daha isabetli hale getirir. Kısa dönemli dalgalanmaları algılama becerisi, bu yöntemi klasik yöntemlerden ayıran bir özelliktir. Sonuç olarak hem zaman serisi analizi hem de makine öğrenimi yöntemleri, kısa dönem elektrik enerjisi yük tahmininde kullanılabilecek önemli araçlardır. İyi bir tahmin yöntemi seçimi, enerji yönetiminde etkili stratejilerin geliştirilmesine ve kaynakların verimli kullanılmasına katkıda bulunur.

Uzun Kısa Süreli Bellek (LSTM) ağları, zaman serisi verileri ile ilgili karmaşık işlevleri öğrenebilme yetenekleri sayesinde, yapay zeka literatüründe dikkat çekici bir yere sahiptir. LSTM, geleneksel yapay sinir ağlarının birçok sınırlamasını aşarak, özellikle ardışık veri işleme görevlerinde etkili çözümler sunar [13]. Bu özelliği, elektrik enerjisi yük tahmini gibi dinamik sistemlerin modellenmesinde kritik bir avantaj sağlar. LSTM ağlarının temel yapısı, giriş, unutma ve çıkış kapıları içerir. Giriş kapısı, yeni bilgilerin ağına iç belleğine kaydedilmesini

kontrol ederken, unutmaya kapısı, geçmiş bilgilerden hangilerinin silineceğine dair karar verir. Çıkış kapısı, iç bellekteki bilgilerin hangi kısmının dışa aktarılacağını belirler. Bu mekanizmalar, zaman içindeki bağımlılıkları anlamada ve uzun dönemli ilişkileri yakalamada son derece etkilidir. Bu nedenle, meteorolojik veriler gibi mevsimsel ve zamanla değişen dizilerde, LSTM'nin kullanımı özellikle uygun görünmektedir, çünkü elektrik enerjisi yükü, çevresel değişkenlerden doğrudan etkilenmektedir. LSTM'nin bir diğer önemli avantajı ise öğrenme sürecindeki esnekliğidir. Düzensiz ve karmaşık zaman serisi verilerini analiz edebilme kapasitesi, elektrik yük tahmininde kullanılan meteorolojik verilerin dinamik doğasına uyum sağlamasına olanak tanır. Bu bağlamda, LSTM uygulamaları, sadece geçmiş verilerden öğrenmekle kalmayıp, aynı zamanda olası gelecekteki durumları da değerlendirme yeteneğine sahiptir. Sonuç olarak, yapay zeka ve özellikle LSTM yöntemleri, kısa dönem elektrik enerjisi yük tahmini gibi karmaşık ve çok değişkenli sistemlerin daha doğru bir şekilde modellenmesine ve tahmin doğruluğunun artmasında katkıda bulunmaktadır [14].

Yapay Zeka Tekniklerinin Yük Tahmininde Kullanımı

Kısa dönem yük tahmini amacıyla geliştirilen pek çok farklı istatistiksel yöntem bulunmaktadır. Bu yöntemler arasında Regresyon Analizi, Zaman Serisi Analizi, Uzman Sistemler, Bulanık Mantık ve Yapay Sinir Ağları sayılabilir. Literatürde yük tahmini ile ilgili istatistiksel yöntemler ve yapay zekâ algoritmaları kullanılarak yapılan birçok çalışma bulunmaktadır. Bu çalışmalardan bazıları özetlenmiştir. Buitrago ve Asfour çalışmalarında, lineer olmayan oto-regresif yapay sinir ağları yöntemini kullanarak 24 saatlik yük tahmini yapmışlardır. Giriş verisi olarak elektrik tüketim ve sıcaklık değerleri kullanılmıştır. Çalışmada geri beslemeli YSA başarıyla uygulanmıştır [15]. Yapay Sinir Ağlarının (YSA) en belirgin avantajları arasında yüksek boyutlu veri kümesiyle başa çıkma yetenekleri ve verilerdeki karmaşık ilişkileri öğrenebilme kabiliyeti yer almaktadır. Yapay sinir ağları, özellikle sonuç odaklı proseslerde doğrusal olmayan ilişkilere sahip verilerde umut vadeden bir modelleme tekniğidir [16]. Özellikle elektrik yük tahmini gibi dinamik süreçlerde, YSA'lar geçmiş verilere dayanarak gelecekteki trendleri tahmin etme yetenekleriyle öne çıkarlar. Uzun Kısa Süreli Bellek (LSTM) modelleri, YSA'ların bir alt grubu olarak, ardışık

verilerin analizi için spesifik olarak geliştirilmiştir. LSTM'ler, özellikle zaman serisi verileri üzerinde yüksek doğruluk sağlamak amacıyla, geçmiş verileri saklayıp unutmaya mekanizmalarını etkin bir şekilde kullanarak öğrenme sürecini optimize ederler.

Tahmin modellerinin oluşturulmasında geniş bir veri seti girdi olarak kullanılmaktadır. T.C. Tarım ve Orman Bakanlığı Sivas Meteoroloji Müdürlüğünden 2022 ve 2023 yıllarına ait günlük toplam yağış, saatlik bulutluluk miktarı, saatlik nispi nem ve saatlik sıcaklık verileri alınmıştır. Verilerin bir kısmı ham haliyle, diğer kısmı ise belirli düzenleme ve işleme süreçlerinden geçirilerek kullanıma hazır hale getirilmektedir. Bu çalışmada, hatalı veya eksik veriler tespit edildiğinde, eksik alanlar önceki ve sonraki değerler kullanılarak interpolasyon yöntemiyle doldurulmuştur. Ayrıca, saatlik sıcaklık verileri ağırlıklı ortalama yöntemiyle dönüştürülmüştür. Çalışmada ağırlıklı saatlik sıcaklık değerleri için verilen saat UTC (Koordine Edilmiş Evrensel Saat)'dir. Türkiye saatine çevirmek için kışın 2 saat, yaz saatine göre ise 3 saat eklenmiştir. Sivas-Merkez 1.Organize Sanayi Bölge Müdürlüğünden 2022 ve 2023 yıllarına ait saatlik tüketim ve üretim verileri alınmıştır. Elektrik enerjisi talep tahmini, geçmişteki ve mevcut verilerin analiz edilerek talep değişim eğilimlerinin belirlenmesi ve bu eğilimler doğrultusunda gelecekteki enerji ihtiyacının öngörülmesine dayanır. Elektrik yükünü etkileyen başlıca etmenler arasında sıcaklık, nem, rüzgâr gibi meteorolojik parametreler ile önceki yıllara ait enerji tüketim verileri yer almaktadır. Yapay Sinir Ağları (YSA) makina öğrenmesi gerçekleştirebilirler. Yapay sinir ağlarının ana amacı, bilgisayar sistemlerinin öğrenme yeteneği kazanmasını sağlamaktır. Öğrendikleri olayları analiz ederek benzer durumlarda akılcı kararlar alabilirler. Uzun Kısa Süreli Bellek (Long Short Term Memory - LSTM), derin öğrenme kapsamında kullanılan özel bir yapay tekrarlayan sinir ağı (RNN) türüdür. Klasik ileri beslemeli sinir ağlarının aksine, LSTM yapıları geri besleme bağlantılarına sahiptir ve bu sayede yalnızca tekil veri noktalarını (örneğin anlık tüketim değerleri) değil, aynı zamanda zamanla değişen veri dizilerini (örneğin sıcaklık veya nem gibi) işleyebilir. Bu çalışmada kullanılan LSTM birimi; bir hücre yapısı ile birlikte giriş kapısı, çıkış kapısı ve unutmaya kapısından oluşmaktadır. Hücre, belirli zaman aralıklarındaki bilgileri hafızada tutarken; kapılar, bu bilginin hücreye girişini, çıkışını ve unutulmasını kontrol eder.




Fig. 1. The Long Short Term Memory network (LSTM) structure

Yukarıdaki Şekil 1'de LSTM Diyagramının her satırı bir düğümün çıktısından başkalarının girişlerine kadar tüm vektörü taşır. Sarı kutular sinir ağı katmanları öğrenilirken, pembe daireler vektör eklenmesi gibi noktasal işlemleri temsil eder. Birleştirilen satırlar birleştirme hattını, çizgi çatallaştırma ise kopyalanan içeriği ve kopyaları farklı yere gideceklerini belirtir. Şekil 1'deki LSTM mimarisinde X_t giriş h_t çıkış verilerini ifade etmektedir. LSTM'nin işleyiş formülleri aşağıdaki gibidir [17].

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (1)$$

$$\tilde{C}_t = \tanh(W_c h_{t-1} + U_c x_t + b_c) \quad (2)$$

$$C_t = C_{t-1} * f_t + \tilde{C}_t * i_t \quad (3)$$

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (4)$$


- Sigmoid Fonksiyonu Eşitlik 5'deki gibi ifade edilir [18]. Bu fonksiyon girdi değerini sıfır ile bir arasında tutarak bir yakınsama yapar. Yapay sinir ağları modellerinde aktivasyon fonksiyonu şeklinde karşımıza çıkmaktadır. Ağın

doğrusal olmayan değişken durumlarını öğrenmeyi sağlar ve Turing evrenselliği gibi önemli özellikler gösterir [19]. LSTM ağlarında kullanımı oldukça yaygındır.

$$\sigma(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{1 + e^x} \quad (5)$$


- Hiperbolik Tanjant Fonksiyonu ($\tanh x$) aşağıdaki Eşitlik 6 formülde ifade edilmiştir. Zaman seri tahminleme analizinde verimli sonuçlara ulaşmak için geliştirilmiştir. Bu fonksiyon doğrusal olmayan dönüşümleri gerçekleştirmek için önemli rol oynamaktadır. Yapay Sinir Ağları ve LSTM'de yaygın olarak kullanılmaktadır [20], [21].

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (6)$$



Şekil 2. Sigmoid Fonksiyon Grafiği

Fig. 2. Sigmoid Function Graph



Şekil 4. Hiperbolik Tanjant ($\tanh x$) Fonksiyon Grafiği
Fig. 4. Hyperbolic Tangent ($\tanh x$) Function Graph

Bu araştırmada kullanılan LSTM modelinin performansını belirleyen temel parametreler detaylı bir şekilde ele alınmıştır. Modelin öğrenme kapasitesini belirleyen hücre sayısı, katman derinliği ve öğrenme oranı gibi temel ayarlar özenle düzenlenmiştir. Aşırı öğrenmeyi (overfitting) önlemek amacıyla dropout oranı belirlenmiş ve modelin daha iyi genelleme yapabilmesi için uygun bir optimizasyon yöntemi kullanılmıştır. Bu parametrelerin doğru şekilde ayarlanması, modelin kısa dönem elektrik yük tahmininde yüksek doğrulukla çalışmasını sağlamıştır.

İstatistiksel Analiz

Bu çalışmada, Matlab/Simulink aracılığıyla LSTM mimarisine ait ölçüm verileri giriş olarak işlenmiş ve tahminlerin doğruluğunu değerlendirebilmek için çeşitli

istatistiksel analizler yapılmıştır. Standart sapma ve ortalama değerlerin hesaplanması, modelin tahmin sonuçlarının ne kadar güvenilir olduğunu ve tahminlerin genel eğilimlerini anlamamıza yardımcı olmuştur. Ayrıca, tahminleme değerlerinin ölçüm değerlerine olan yüzde değişim oranlarının hesaplanması, modelin tahminlerindeki sapmaların büyüklüğünü ve doğruluğunu objektif bir şekilde değerlendirmemize olanak tanımıştır. Bu analizler, modelin performansını daha ayrıntılı bir şekilde incelememize ve hangi faktörlerin tahmin doğruluğunu etkilediğini belirlememize yardımcı olmuştur.

Tablo 1’de yer alan 2023 yılına ait bir yıllık; Sivas ili meteoroloji verileri [22], döviz kuru verileri [23] ve Sivas ili Organize Sanayi Bölgesi tüketim verileri [24] LSTM mimarisinin girdileri olarak kullanılmıştır.

Tablo 1. Giriş (LSTM için Öğrenme) Verileri.

Table 1. Input (Learning for LSTM) Data.

Yıl	Ay	Gün	Resmi Tatil	Dini Bayram	C.tesi	Pazar	Günlük Yağış (kg/m ²)	Günlük Güneşlenme (saat)	Günlük Nispi Nem (%)	Günlük Ortalama Sıcaklık (°C)	Dolar Satış (/\$)	Günlük Tüketim (kWh)
2023	1	1	1	0	0	1	0	7	72	-2	19	76238
2023	1	2	0	0	0	0	0	7	68	-2	19	259662
2023	1	3	0	0	0	0	0	5	70	-2	19	305014
2023	1	4	0	0	0	0	0	2	45	3	19	311751
2023	1	5	0	0	0	0	0	5	72	2	19	316531
2023	1	6	0	0	0	0	0	4	78	1	19	312444
2023	1	7	0	0	1	0	0	1	68	2	19	238682
2023	1	8	0	0	0	1	0	0	73	0	19	114067
2023	1	9	0	0	0	0	0	7	62	-2	19	290314
2023	1	10	0	0	0	0	0	7	60	-2	19	329626
2023	1	11	0	0	0	0	0	7	54	0	19	327959
2023	1	12	0	0	0	0	0	4	42	2	19	332327
2023	1	13	0	0	0	0	0	7	50	0	19	324710

2023	1	14	0	0	1	0	0	3	68	1	19	265126
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
2023	2	1	0	0	0	0	3	0	85	-1	19	349430
2023	2	2	0	0	0	0	0	4	69	-4	19	357596
2023	2	3	0	0	0	0	0	7	63	-4	19	347281
2023	2	4	0	0	1	0	0	0	76	-3	19	278373
2023	2	5	0	0	0	1	0	0	79	-2	19	169115
2023	2	6	0	0	0	0	33	0	95	-1	19	232092
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.

Bulgular ve Tartışmalar

Bu çalışmada 2023 yılına ait 365 adet günlük elektrik tüketimi ve meteoroloji verileri işlenmiştir. Verilerin %89,86'sı LSTM modelinin öğrenmesi için ve %10'u tahminleme ile karşılaştırma yapmak için düzenlenmiştir. Oluşturulan tahminleme modelleri ve tüm algoritma MATLAB/Simulink aracı ile test edilmiştir. Eğitim ve kayıp verileri Şekil 5'de sunulmuştur. Görüldüğü üzere ilk 125 eğitim adımından sonra öğrenme yavaşlamıştır. Öğrenme 150 adımdan sonra tamamlanmaya yaklaşmıştır. Verilerin geniş parametrede olması nedeniyle öğrenme adım sayısı 500 de sonlandırılmasının uygun olacağı değerlendirilmiştir.


Şekil 6'da Loss (Kayıp) eğrisi Modelin tahmin yapma yeteneğinin iyileştiğini veya kötüleştiğini görselleştirmektedir. Loss eğrisi zamanla azalırsa model öğreniyor demektir. Loss eğrisi, modelin eğitim süreci boyunca her bir epoch'ta (eğitim döngüsünde) hesaplanan kayıp (hata) değerlerini grafiksel olarak gösterir. Genellikle Training Loss (Eğitim Kaybı) modelin eğitim verisi üzerindeki hatası ve Validation Loss (Doğrulama Kaybı) Modelin daha önce görmediği doğrulama verisi üzerindeki hatası şeklinde iki ayrı gösterimi vardır. Kayıp fonksiyonu (loss function), modelin tahmin ettiği değer ile gerçek değer arasındaki farkı ölçer. Regresyon (tahmin) problemlerinde en yaygın kullanılan kayıp fonksiyonu Eşitlik 7'de MSE (Mean Squared Error - Ortalama Kare Hatası) ifade edilmiştir.

$$MSE = \frac{1}{n} \sum_{t=1}^n (x_t - \hat{x}_t)^2 \quad (7)$$


Şekil 7'de 365 güne ait gerçekleşmiş tüketim değerleri ile son 37 günün tahminlenen değerleri yer almaktadır. Geçmiş tüketim ve diğer girdi verileri ile eğitilen model sayesinde tahminleme gerçekleştirilmiştir.

Şekil 8'de ise son 37 günün gerçekleşen ve tahminlenen tüketimleri daha detaylı olarak yer almaktadır. Ayrıca tahminlemeden kaynaklanan farkların gün bazındaki değerleri görülmektedir. Eşitlik 8'de ise RMSE (Root Mean Square Error-Kök Kare Ortalama Hatası) ifade edilmektedir. Bu eşlikte x_t ölçülen değer iken $\hat{x}_t$ tahmin edilen değerdir. Tahminlemenin doğruluğunu değerlendirmek için kullanılmaktadır. Daha düşük bir RMSE değeri, modelin gerçek değerlere daha yakın tahminlerde bulunduğunu göstermektedir. RMSE, hataların büyüklüğünü vurgular ve büyük hatalara daha fazla ağırlık verir, bu da modelin büyük hatalara karşı duyarlılığını artırır [25].

Farklı veri setleri ile dört durum incelenmiştir. Birinci durumda giriş veri seti olarak sadece yılın günleri kullanılmıştır. İkinci durum için giriş veri setinde "Ay, Ayın Günü, Mesai Günü ve Yılın Günleri" kullanılmıştır. Üçüncü durum için ise giriş veri setinde "Ay, Ayın Günü, Mesai Günü, Yılın Günleri, Bayram Günleri, Tatil, Hafta sonu, Normal Gün, Dolar" kullanılmıştır. Dördüncü durumda "Tablo 1'de yer alan Tüm veriler" giriş veri seti olarak kullanılmıştır. Tablo 2'de ölçülen değerler ile dört farklı durum için tahminlenen değerler listelenmiştir. Tablo 3'te ise ölçülen değer ile tahminlenen değerler arasındaki farklar ile RMSE değerleri incelenmiştir.




Şekil 5. Giriş Verileri ile Gün Bazında Modelin Eğitim Grafiği
Fig. 5. Training Graph of the Model Based on Day with Input Data




Şekil 6. Giriş Verileri ile Gün Bazında Modelin Kayıp Grafiği

Fig. 6. Loss Graph of the Model by Day with Input Data



Şekil 7. Gün Bazında Gerçekleşen ve Tahminlenen Tüketim Grafiği

Fig. 7. Realized and Estimated Consumption Graph on a Daily Basis



Şekil 8. Son 37 Günün Gerçekleşen ve Tahminlenen Tüketim Grafiği

Fig. 8. Actual and Estimated Consumption Graph of the Last 37 Days

Tablo 2. Ölçülen Değerler ve Tahminlenen Değerler Sonuç Tablosu.

Table 2. Measured Values and Estimated Values Result Table.

Yıl	Ay	Gün	Ölçülen Tüketim (kWh)	Durum-1 Tahmini Tüketim (kWh)	Durum-2 Tahmini Tüketim (kWh)	Durum-3 Tahmini Tüketim (kWh)	Durum-4 Tahmini Tüketim (kWh)
2023	11	25	389337	390241,44	391445,39	394766,49	386510,37
2023	11	26	231240	234105,97	232209,83	233786,74	241058,45
2023	11	26	424233	421533,08	422739,39	421700,30	411852,21
2023	11	28	464852	464577,51	465355,53	466304,21	455739,72
2023	11	29	471783	472734,28	472074,01	472196,52	464529,05
2023	11	30	470134	470356,89	469882,46	470132,90	465986,17
2023	12	1	456380	457404,89	455467,68	454501,68	448421,08
2023	12	2	391671	392028,62	391383,30	392150,67	380324,25
2023	12	3	233121	234789,62	233426,63	232846,08	227251,63
2023	12	4	371185	371183,49	371163,78	369273,03	355428,07
2023	12	5	396030	397885,6	395978,29	396513,40	378274,07
2023	12	6	408790	410161,32	408835,67	409279,99	392123,75
2023	12	7	411337	412411,68	411381,72	411772,43	395782,00
2023	12	8	425604	427200,95	426282,67	426212,94	409492,14
2023	12	9	347041	346959,59	347239,47	347599,50	338664,03
2023	12	10	206358	207558,18	207218,61	206105,77	210773,63
2023	12	11	384778	384210,65	384444,18	384201,42	380524,40
2023	12	12	422018	423365,04	422515,82	423243,64	419660,48
2023	12	13	408175	409243,17	408546,95	408540,75	410518,94
2023	12	14	422635	424063,71	423187,18	423251,17	417503,63
2023	12	15	406880	408003	407744,14	407385,24	403545,51
2023	12	16	337071	336829,13	337184,67	337123,74	333954,90
2023	12	17	197014	198846,26	198002,87	196893,68	208966,86
2023	12	18	372507	372273,19	373106,50	372699,76	360517,23
2023	12	19	422014	423193,41	423294,46	423650,67	413542,81
2023	12	20	424587	425886,99	425614,62	425638,03	419722,36
2023	12	21	426284	427764,41	427181,60	427153,99	423815,05
2023	12	22	426608	428127,78	427952,44	427560,46	423778,34
2023	12	23	334624	334483,61	334871,09	335057,68	337871,70
2023	12	24	180102	183276,56	182331,74	180780,32	199168,35
2023	12	25	379288	378999,68	379018,35	378645,27	374021,10
2023	12	26	407280	408794,47	407991,41	408280,73	403994,44
2023	12	27	400935	401927,7	401523,08	401342,46	400843,66
2023	12	28	404136	405303,39	404853,11	404586,66	403094,24
2023	12	29	396544	397775,03	397749,24	397004,76	394451,69
2023	12	30	325993	325630,64	326119,10	326105,99	326415,26
2023	12	31	170225	174416,56	173537,26	171784,41	188288,79

Tablo 3. Ölçülen Değerler ve Tahminlenen Değerler Farkı ile RMSE Sonuç Tablosu.

Table 3. RMSE Result Table Containing the Decency Between the Measured Values and the Estimated Values.

Yıl	Ay	Gün	Durum-1 Tahmin Sapması	Durum-2 Tahmin Sapması	Durum-3 Tahmin Sapması	Durum-4 Tahmin Sapması
2023	11	25	-904,44	-2108,39	-5429,49	2826,63
2023	11	26	-2865,97	-969,83	-2546,74	-9818,45
2023	11	26	2699,92	1493,61	2532,70	12380,80
2023	11	28	274,49	-503,53	-1452,21	9112,28
2023	11	29	-951,28	-291,01	-413,52	7253,95
2023	11	30	-222,89	251,54	1,10	4147,83
2023	12	1	-1024,89	912,33	1878,33	7958,92
2023	12	2	-357,62	287,70	-479,67	11346,75
2023	12	3	-1668,61	-305,63	274,92	5869,37
2023	12	4	1,51	21,22	1911,97	15756,93
2023	12	5	-1855,60	51,71	-483,40	17755,93
2023	12	6	-1371,32	-45,67	-489,99	16666,25
2023	12	7	-1074,68	-44,72	-435,43	15555,00
2023	12	8	-1596,95	-678,67	-608,94	16111,87
2023	12	9	81,41	-198,47	-558,50	8376,97
2023	12	10	-1200,18	-860,61	252,23	-4415,63
2023	12	11	567,35	333,82	576,58	4253,60
2023	12	12	-1347,03	-497,82	-1225,64	2357,52
2023	12	13	-1068,17	-371,95	-365,75	-2343,94
2023	12	14	-1428,72	-552,18	-616,17	5131,37
2023	12	15	-1123,00	-864,14	-505,24	3334,50
2023	12	16	241,87	-113,67	-52,74	3116,10
2023	12	17	-1832,26	-988,87	120,32	-11952,86
2023	12	18	233,81	-599,50	-192,76	11989,77
2023	12	19	-1179,41	-1280,46	-1636,67	8471,19
2023	12	20	-1299,99	-1027,62	-1051,03	4864,65
2023	12	21	-1480,41	-897,60	-869,98	2468,95
2023	12	22	-1519,78	-1344,44	-952,46	2829,66
2023	12	23	140,39	-247,09	-433,68	-3247,70
2023	12	24	-3174,56	-2229,74	-678,32	-19066,35
2023	12	25	288,32	269,65	642,73	5266,90
2023	12	26	-1514,47	-711,41	-1000,73	3285,56
2023	12	27	-992,70	-588,08	-407,46	91,34
2023	12	28	-1167,39	-717,11	-450,66	1041,76
2023	12	29	-1231,03	-1205,24	-460,76	2092,31
2023	12	30	362,36	-126,10	-112,99	-422,26
2023	12	31	-4191,56	-3312,26	-1559,41	-18063,79
RMSE Değerleri			1501,897	1005,312	1343,179	9342,352

Sonuçlar ve Öneriler

Bu çalışmada, LSTM (Uzun Kısa Süreli Bellek) modeli kullanılarak farklı durumlar için enerji tüketimi tahminlemesi yapılmıştır. Çalışmanın sonuçları, LSTM tabanlı modellerin enerji tüketimi tahmininde üstün performans sergilediğini göstermektedir. Tahminleme doğruluk oranları incelenmiştir. Dört farklı veri seti ile yapılan tahmin sonuçları, modelin performansını karşılaştırmak amacıyla Kök Ortalama Kare Hatası (RMSE) metriği ile değerlendirilmiştir. Ortalama olarak Durum 1'de %99,6 , Durum 2'de %99,75 , Durum 3'te %99,74 ve Durum 4'te %97,6 oranlarında doğru tahminleme gerçekleşmiştir. Modelin yüksek tahminleme doğruluğu ile çalıştığı gözlemlenmiştir. Elde edilen sonuçlara göre özellikle zamana bağlı değişkenleri etkili bir şekilde öğrenebildiğini göstermektedir. Farklı veri setleri ile yapılan testlerde, modelin doğruluğunun kullanılan veri türüne göre değiştiği görülmüştür. Daha fazla değişken içeren veri setlerinin, modelin tahmin başarısını artırdığı gözlemlenmiştir. Bununla birlikte, bazı durumlarda fazla veri girdisinin modelde aşırı öğrenmeye sebep olabileceği de tespit edilmiştir. En verimli tahminleme sonuçları; RMSE değeri en düşük olan Durum 2'de elde edilmiştir.

Beklediği üzere, daha fazla veri girdisi içeren Durum 3 ve Durum 4 senaryolarında, tüketim tahmininde belirli bir iyileşme gözlenmiştir. Ancak, meteorolojik verilerin de dahil edildiği Durum 4'te beklenenin aksine tahmin doğruluğunda ciddi bir düşüş yaşanmıştır. Bu durumun birkaç olası sebebi olabilir:

Meteorolojik Değişkenlerin Tüketim Üzerindeki Doğrudan Etkisi irdeleyecek olursak; tüketim verisinin mevsimsel döngüler ve ekonomik faktörler gibi belirgin kalıplarla şekillendiği düşünüldüğünde, hava durumu değişkenlerinin doğrudan bir etkisinin olmaması veya bu etkinin bölgesel ve sektörel bazda farklılık göstermesi tahmin modelinin hata oranını artırmış olabilir. Özellikle sıcaklık, nem ve güneşlenme süresi gibi meteorolojik değişkenler, enerji tüketimi ile doğrusal olmayan ve kompleks bir ilişkiye sahip olabilir. Bu nedenle, bu tür değişkenlerin modele doğrudan eklenmesi beklenen iyileştirmeyi sağlamamış olabilir. Eğer meteorolojik veriler doğru değilse veya modelin ihtiyaç duyduğu şekilde işlenmemişse, tahmin performansı olumsuz etkilenebilir.

Veri setinin dengesizliği ve gürültü içermesi konusunda meteorolojik veriler, özellikle günlük bazda değişkenlik gösterdiği için, modelin öğrenme sürecinde ek bir gürültü kaynağı oluşturmuş olabilir. Bu durum, modelin tüketim tahminine odaklanmasını zorlaştırarak aşırı öğrenme (overfitting) veya yetersiz öğrenme (underfitting) problemlerine yol açmış olabilir. Özellikle Dolar kuru ve hava durumu gibi dışsal faktörlerin tüketim üzerindeki etkileri, daha uzun dönem verileri ile daha anlamlı hale gelebilirken, kısa vadede tahmin performansını artırmak yerine düşürebilir.

Veri dönüşümlerinin ve normalizasyonun etkisinde ise LSTM modelleri, girdilerin ölçeklendirilmesine ve zaman

serisi içindeki dinamik değişimlere oldukça duyarlıdır. Meteorolojik veriler ve ekonomik faktörlerin farklı ölçeklerde olması, modelin bazı girdileri daha baskın algılamasına neden olmuş olabilir. Eğer bu değişkenler uygun bir ön işleme (normalizasyon, standartlaştırma) ile modele dahil edilmemişse, tahmin performansını olumsuz yönde etkileyerek yüksek hata değerine sebep olmuş olabilir. Daha fazla veri girişi, modelin karmaşıklığını artırabilir ve aşırı uyuma yol açabilir. Bu durum, modelin eğitim verilerine çok iyi uyum sağlarken, yeni veriler üzerinde düşük performans göstermesine neden olabilir. Model, tüketimi etkileyen ana kalıpları öğrenmek yerine, aşırı duyarlı olduğu değişkenlere gereğinden fazla ağırlık verebilir.

Değişkenler arasındaki çoklu doğrusallık, model karmaşıklığı ve çok sayıda değişkenin modele eklenmesi, modelin daha fazla ilişki öğrenmesini sağlarken aynı zamanda modelin karmaşıklığını da artırır. Eğer bazı değişkenler yüksek oranda birbirleriyle ilişkili ise (örneğin sıcaklık ve güneşlenme süresi gibi), modelin karar mekanizması bu ilişkileri doğru şekilde öğrenemeyebilir. Bu durum, modelin tüketim tahminleme doğruluğunu düşürmesine sebep olabilir. Meteorolojik faktörlerin tüketim üzerindeki etkisi, bölgeye, mevsime, sektöre ve ısınma tercihlerine bağlı olarak değişkenlik gösterebilir. Örneğin, sıcaklık değişimleri soğuk iklimlerde ısıtma ihtiyacını artırırken, sıcak iklimlerde soğutma ihtiyacına bağlı tüketim artışı yaşanabilir. Model, bu gibi doğrusal olmayan ve mevsimsel bağımlılıkları yeterince iyi öğrenemediğinde, tahmin hatası yükselir.

Sonuç olarak, Durum 2'nin en iyi tahmin performansını göstermesi, tüketim tahmininde en anlamlı değişkenlerin seçiminde dikkat edilmesi gerektiğini ortaya koymaktadır. Daha fazla veri girişi her zaman daha iyi tahmin performansı sağlamayabilir. İlerideki çalışmalarda, meteorolojik değişkenlerin tüketim tahminine olan etkilerini daha iyi anlamak için dış faktörlerin yeterince araştırılması, daha uzun süreli veri analizi ve farklı derin öğrenme modelleri ile detaylandırılabilir. Modelin aşırı uyumunu önlemek için daha basit modeller veya düzenleme teknikleri kullanılabilir. Bu faktörler, enerji tüketimi tahminlerinde daha iyi sonuçlar elde etmenize yardımcı olabilir. Tahminleme oranının artırılması için yıl içerisinde farklı dönemlerde devreye giren elektrik üretim santrallerinin, devreye girdiği tarih ve güç bilgisinde model için giriş verisi olarak işlenilmesinin daha verimli olacağı düşünülmektedir. Böylece öğrenmenin ve tahmin performansının artması öngörülmektedir.

Teşekkür

Bu çalışma için tasarlanan modelde kullanılan meteorolojik verileri sağlayan Meteoroloji İşleri Genel Müdürlüğüne, enerji tüketim verilerini sağlayan Sivas-Merkez 1.OSB Müdürlüğü'ne teşekkür ederiz.

Kaynakça

- [1] B. L. Aylak, O. Oral, ve K. Yazici, "Yapay Zeka ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı", *El-Cezeri Fen ve Mühendislik Dergisi*, 2020, doi: 10.31202/ecjse.776314.
- [2] E. A. Madrid ve N. Antonio, "Short-term electricity load forecasting with machine learning", *Information (Switzerland)*, c. 12, sy 2, 2021, doi: 10.3390/info12020050.
- [3] O. C. Ozerdem, E. O. Olaniyi, ve O. K. Oyedotun, "Short term load forecasting using particle swarm optimization neural network", *Procedia Comput Sci*, c. 120, ss. 382-393, Oca. 2017, doi: 10.1016/J.PROCS.2017.11.254.
- [4] T. Ahmad, C. Huanxin, D. Zhang, ve H. Zhang, "Smart energy forecasting strategy with four machine learning models for climate-sensitive and non-climate sensitive conditions", *Energy*, c. 198, s. 117283, May. 2020, doi: 10.1016/J.ENERGY.2020.117283.
- [5] D. Miao ve M. Nakamura, "Optimizing Energy Management Systems with Fine-Grained Interval Demand Forecasting", *2024 IEEE Sustainable Power and Energy Conference, ISPEC 2024*, ss. 19-23, 2024, doi: 10.1109/ISPEC59716.2024.10892557.
- [6] R. Sagwal, J. Ramkumar, ve S. N. Singh, "Exploring the Efficacy of Feature Selection and Attention Enhanced Deep Learning in Multivariable Electricity Price Forecasting", *Conference Proceedings - 13th IEEE Power and Energy Society: Innovative Smart Grid Technologies - Asia, ISGT Asia 2024*, 2024, doi: 10.1109/ISGTASIA61245.2024.10876326.
- [7] T. M. Ghazal, J. I. Janjua, W. Abushiba, M. Ahmad, T. Abbas, ve K. Ateeq, "Cutting-Edge Predictive Methods for Enhancing Short-Term Load Prediction", *2024 International Conference on Electrical and Computer Engineering Researches (ICECER)*, ss. 1-6, Ara. 2024, doi: 10.1109/ICECER62944.2024.10920448.
- [8] Z. Marzak, S. Mouatassim, J. Benhra, ve R. Benabbou, "Contribution to Predicting Electricity Load using Random Forest", *2024 3rd International Conference on Embedded Systems and Artificial Intelligence (ESAI)*, ss. 1-14, Ara. 2024, doi: 10.1109/ESAI62891.2024.10913864.
- [9] A. Shukla, "Advanced Machine Learning and Features Based Data Analytics of Electricity Consumption in USA and India", içinde *Advanced Network Technologies and Intelligent Computing*, P. and P. K. K. and B. R. and D. D. Verma Anshul and Verma, Ed., Cham: Springer Nature Switzerland, 2025, ss. 333-344.
- [10] S. Nadali, T. H. Yong, ve D. Glover, "Dynamic Energy Management: Predictive Maximum Demand Control with Short-Term Power Forecasting", *2025 IEEE Texas Power and Energy Conference, TPEC 2025*, 2025, doi: 10.1109/TPEC63981.2025.10907159.
- [11] M. R. Haq ve Z. Ni, "A new hybrid model for short-term electricity load forecasting", *IEEE Access*, c. 7, 2019, doi: 10.1109/ACCESS.2019.2937222.
- [12] A. Bielecki, J. A. Shohan, O. Faruque, ve S. Y. Foo, "Forecasting of Electric Load Using a Hybrid LSTM-Neural Prophet Model", 2022, doi: 10.3390/en15062158.
- [13] C. Hu, Q. Wu, H. Li, S. Jian, N. Li, ve Z. Lou, "Deep Learning with a Long Short-Term Memory Networks Approach for Rainfall-Runoff Simulation", *Water* 2018, Vol. 10, Page 1543, c. 10, sy 11, s. 1543, Eki. 2018, doi: 10.3390/W10111543.
- [14] S. Muzaffar ve A. Afshari, "Short-Term Load Forecasts Using LSTM Networks", *Energy Procedia*, c. 158, ss. 2922-2927, Şub. 2019, doi: 10.1016/J.EGYPRO.2019.01.952.
- [15] J. Buitrago ve S. Asfour, "Short-Term Forecasting of Electric Loads Using Nonlinear Autoregressive Artificial Neural Networks with Exogenous Vector Inputs", *Energies* 2017, Vol. 10, Page 40, c. 10, sy 1, s. 40, Oca. 2017, doi: 10.3390/EN10010040.
- [16] S. Agatonovic-Kustrin ve R. Beresford, "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research", *J Pharm Biomed Anal*, c. 22, sy 5, ss. 717-727, Haz. 2000, doi: 10.1016/S0731-7085(99)00272-1.
- [17] C. Ren, L. Jia, ve Z. Wang, "A CNN-LSTM Hybrid Model Based Short-term Power Load Forecasting", *Proceedings - 2021 Power System and Green Energy Conference, PSSEC 2021*, ss. 182-186, Ağu. 2021, doi: 10.1109/PSSEC51302.2021.9542404.
- [18] G. Mourgas-Alexandris, A. Tsakyridis, N. Passalis, A. Tefas, K. Vysokinos, ve N. Pleros, "An all-optical neuron with sigmoid activation function", *Opt Express*, c. 27, sy 7, s. 9620, Nis. 2019, doi: 10.1364/OE.27.009620.
- [19] J. Kilian ve H. T. Siegelmann, "The Dynamic Universality of Sigmoidal Neural Networks", *Inf Comput*, c. 128, sy 1, ss. 48-56, Tem. 1996, doi: 10.1006/INCO.1996.0062.
- [20] A. Farzad, H. Mashayekhi, ve H. Hassanpour, "A comparative performance analysis of different activation functions in LSTM networks for classification", *Neural Comput Appl*, c. 31, sy 7, ss. 2507-2521, Tem. 2019, doi: 10.1007/S00521-017-3210-6/TABLES/11.
- [21] M. H. Essai Ali, A. B. Abdel-Raman, ve E. A. Badry, "Developing Novel Activation Functions Based Deep Learning LSTM for Classification", *IEEE Access*, c. 10, ss. 97259-97275, 2022, doi: 10.1109/ACCESS.2022.3205774.
- [22] M. G. M, "İllerimize Ait Genel İstatistik Verileri", 2017.
- [23] "EVDS | Tüm Seriler". Erişim: 03 Nisan 2025. [Çevrimiçi]. Erişim adresi: <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>
- [24] "Elektrik Birimi | Sivas-Merkez 1. Organize Sanayi Bölge Müdürlüğü | SİVAS OSB". Erişim: 03 Nisan 2025. [Çevrimiçi]. Erişim adresi: <https://sivasosb.org.tr/kurumsal/elektrik-birimi/>
- [25] T. Chai ve R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature", *Geosci Model Dev*, c. 7, sy 3, ss. 1247-1250, Haz. 2014, doi: 10.5194/GMD-7-1247-2014.