

YAPAY SİNİR AĞLARINA DAYALI KISA DÖNEMLİ ELEKTRİK YÜKÜ TAHMİNİ

Eren KAMBER^{1*}, Sencer KÖRPÜZ², Melih CAN³, Hacer YUMURTACI AYDOĞMUŞ⁴, Mehmet GÜMÜŞ⁵

¹Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, İşletme Mühendisliği Bölümü, Antalya
ORCID No: <https://orcid.org/0000-0002-6426-9936>

²İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul
ORCID No: <https://orcid.org/0000-0001-9183-1253>

³Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, İşletme Mühendisliği Bölümü, Antalya
ORCID No: <https://orcid.org/0000-0002-8715-3143>

⁴Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Antalya
ORCID No: <https://orcid.org/0000-0003-3041-2797>

⁵Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Antalya
ORCID No: <https://orcid.org/0000-0003-2588-0270>

Anahtar Kelimeler	Öz
Kısa Dönemli Yük Tahmini, Yapay Sinir Ağı, Zaman Serileri, Uzun Kısa Dönemli Hafıza, Enerji Tahmini	Günümüzün vazgeçilemez unsurlarından olan elektrik enerjisi için kısa dönemli elektrik tahminleri, son yıllarda yüksek öneme sahip konular arasında yer almaktadır. Elektrik üretimi ile talebin dengelenmesi için elektrik talep fiyatlarının doğru tahmin edilmesi önemlidir. Söz konusu denge kurulabildiği takdirde tüketicilere rekabetçi fiyatlar sunulabilmektedir. Elektrik talebinde doğru tahminler yapabilmek için literatürde bazı teknikler kullanılmaktadır. Bu çalışmanın amacı, söz konusu tekniklerden yapay sinir ağını (YSA) uzun kısa dönemli bellek (Long Short-Term Memory - LSTM) mimarisine çalıştırarak kısa süreli elektrik talep tahmininde bulunmaktır. YSA metodolojisinin uygulanmasıyla elde edilen sonuçlar kök ortalama kare hatası değerlerine göre zaman serisi analizi (ARIMA) ile karşılaştırılmıştır. Bu bağlamda, İspanya'nın 2015-2016 yılları arasındaki elektrik verileri tahminleme yapmak için kullanılmıştır. Elektrik enerjisi üretim ve tüketim verileri, İletim Hizmeti Operatörü (TSO) verilerini içeren ve açık erişimli bir portal olan ENTSOE'den toplanmıştır.

SHORT TERM ELECTRICAL LOAD FORECASTING BASED ON ARTIFICIAL NEURAL NETWORKS

Keywords	Abstract
Short Term Load Forecasting, Artificial Neural Network, Time Series, Long Short Term Memory, Energy Forecasting	Short term electricity forecasts preserve its importance in recent years. It is important to forecast electricity demand prices because of balancing power generation and demand. If a balance can be achieved between power generation and demand, competitive prices can be presented to the consumers. In order to make proper forecasts in electricity demand, some techniques are being used related to literature. In this study, first goal was to make a short time electricity demand forecast by working artificial neural network (ANN) module with long short term memory (LSTM). After ANN methodology, results compared with time series analysis (ARIMA) by using root mean square error. In this context, Spain's electricity data was used to make forecasts that was the time line between 2015 and 2016. Electrical energy generation and consumption data was collected from ENTSOE that is a public portal for Transmission Service Operator (TSO) data.
Araştırma Makalesi	Research Article
Başvuru Tarihi : 03.11.2020	Submission Date : 03.11.2020
Kabul Tarihi : 28.07.2021	Accepted Date : 28.07.2021

*Sorumlu yazar; e-posta : eren.kamber@alanya.edu.tr

1. Giriş

Akıllı şebekelerin geliştirilmesiyle birlikte, enerji şirketlerine yük planlamasında yardımcı olabileceği ve aşırı elektrik üretimini azaltabileceği için doğru elektrik yükü tahmininin önemi giderek artmıştır (Bouktif, Fiaz, Ouni, ve Serhani, 2018). Güç kaynaklarının tüketici olan müşterinin taleplerine göre ayarlanması, sürdürülebilirlik düzeyinin yükseltilmesi ve kaynak tüketimi açısından en iyi seçeneklerin değerlendirilmesi için oldukça önemli bir gerekliliktir. Büyük ölçekte enerji depolaması yapmanın zorluğu bilinmekte olup, bu nedenle güç üretiminin gerçek zamanlı olarak taleple birlikte ayarlanması gerekmektedir. Dolayısıyla elektrik yükü tahmini doğru bir şekilde yapılmalıdır (Hernandez, Baladrón, Aguiar, Carro, Sánchez-Esguevillas ve Lloret, 2013). Elektrik talebinin, haftanın günleri, bir yılın ayları gibi çok farklı durumlarda ortaya çıkması basit istatistiksel yöntemlerle doğru bir tahmin yapılmasını oldukça zor kılmaktadır (Hernandez, Baladrón, Aguiar, Carro, Sánchez-Esguevillas, Lloret, Chinarro, Gómez, ve Cook, 2013).

Elektrik talebinin nasıl tahmin edilebileceğinin anlaşılması için ilk olarak yük tahmin problemlerinin sınıflandırılması gerekmektedir. Bridger, Ross ve Park (1986) yük tahmin sorunlarını araştırdığı çalışmada, üç ana kategori sunmuştur:

- Kısa dönemli tahminler (genellikle 1 saat ile 1 hafta arasında uygulanır),
- Orta dönemli tahminler (genellikle bir haftadan bir yıla kadar uygulanır),
- Uzun dönemli tahminler (bir yıldan uzun zaman çizelgeleri).

Bu ayırım doğrultusunda, bu çalışmada kısa dönemli yük tahmini problemi ele alınmıştır. Kısa dönemli tahminler, enerji piyasalarında yaşanan rekabet artışının bir sonucu olarak giderek daha önemli hale gelmiştir. Çoğunlukla değişen başarı seviyelerine sahip tahmin metodolojisi, yük tahmininde de deneyimlenmiştir (Rodrigues, Cardeira, ve Calado, 2014).

Literatürde yük tahmini ele alınan bir konu olmuş ve son yıllarda kısa dönemli yük tahmini için farklı modeller sunulmuştur. Başlıca modeller regresyon temelli yöntemler (Papalexopoulos ve Hesterberg, 1989; Haida ve Muto, 1994; Charytoniuk, Chen ve Van Olinda, 1998), Box Jenkins modeli (Hill, OConnor ve Remus, 1996), zaman serisi

yaklaşımları (Hagan ve Behr, 1987; Cho, Hwang ve Chen, 1995; Fan ve McDonald, 1994; Amjady, 2001), Kalman filtreleri (Irisarri, Widergren ve Yehsakul, 1982), uzman sistem teknikleri (Ho, Hsu, Chen, Lee, Liang, Lai ve Chen 1990; Rahman ve Hazim, 1996), bulanık mantık (Kiartzis ve Bakirtzis, 2000; Miranda ve Monteiro, 2000), bulanık-sinir ağı yapıları (Bakirtzis, Theocharis, Kiartzis ve Satsois, 1995; Srinivasan, Chang ve Liew, 1995) ve sinir ağı modelleridir.

Bazı çalışmalar, kısa dönemli yük tahmini için sinir ağları modeli üzerine odaklanmıştır (Hippert, Pedreira ve Souza, 2001; Carpinteiro, Reis ve Silva, 2004; Bouktif ve diğ., 2018; Le, Vo, Vo, Hwang, Rho ve Baik, 2019; Wang, Gan, Sun, Zhang, Lu ve Kang, 2019; Bouktif, Fiaz, Ouni, ve Serhani, 2020). Bunun yanında, bazı yazarlar ise zaman serileri ve regresyon modelleri (Gross ve Galiana, 1987) ile üssel ağırlıklı yöntemlere dayalı yaklaşımlar (Taylor, 2012) uygulamıştır. Ayrıca birçok araştırmacı, yük tahmin metodolojileri için karma modeller önermiştir (Feinberg ve Genethliou, 2005).

Yapılan yapay sinir ağı çalışmalarına bakıldığında Kong, Dong, Jia, Hill, Xu ve Zhang (2019)'in çalışmalarında toplu konut yükü dışında, tek bir enerji kullanıcısının elektrik yükünü tahmin etmek adına, derin öğrenmenin en son ve en popüler tekniklerinden biri olan LSTM ile tekrarlayan sinir ağı tabanlı bir çerçeve önerilmiştir. Önerilen çerçeve, kamuya açık bir dizi gerçek konut akıllı sayaç verisi üzerinde test edilmiş ve bunların performansı, yük tahmini alanındaki son teknoloji ürünler de dâhil olmak üzere çeşitli kıyaslamalarla kapsamlı bir şekilde karşılaştırılmıştır. Önerilen LSTM yaklaşımının, bireysel mesken haneleri için kısa vadeli yük tahmini görevinde listelenen diğer rakip algoritmalarından daha iyi performans gösterdiği sonucuna ulaşılmıştır. Le ve diğ. (2019) yapmış oldukları çalışmalarında elektrik enerjisi tüketimini tahmin etmek için EECP-CBL modeli olarak adlandırılan evrişimli sinir ağı ve iki yönlü uzun kısa süreli bellek kombinasyonunu kullanan bir elektrik enerjisi tüketimi tahmin modeli önerilmiştir. Deneyler, önerilen modelin tahmin performanslarını ve bireysel hane halkı elektrik tüketimi veri setinin son teknoloji modellerini çeşitli varyantlarla karşılaştırmak için yapılmış ve sonuç olarak evrişimli sinir ağı ve iki yönlü uzun kısa süreli bellek kombinasyonunu kullanan elektrik enerjisi tüketimi tahmin modeli çerçevesinin, gerçek zamanlı, kısa vadeli, orta vadeli ve uzun süreli bireysel hane halkı elektrik tüketimi

veri setinin çeşitli varyasyonlarında elektrik enerjisi tüketimi tahmini için çeşitli performans ölçütleri açısından son teknoloji yaklaşımlardan daha iyi performans göstermiştir. Bouktif ve diğ. (2018)'in yapmış oldukları çalışmada ise, Fransa metropolünün elektrik tüketimi verileri kullanılarak akıllı şebekelerin geliştirilmesi amaçlanmıştır; hem kısa vadeli (birkaç gün ila 2 hafta) hem de orta vadeli (birkaç hafta ila birkaç ay) zaman için doğru tahmin edilen, talep tahmini için uzun kısa süreli bellek ve tekrarlayan sinir ağları tabanlı tek değişkenli bir model oluşturulmuş ve optimize edilmiştir. Karşılaştırma amacıyla, enerji tahmin alanında yaygın olarak kullanılan makine öğrenimi yaklaşımlarının bir yelpazesini temsil eden yedi tahmin tekniği uygulanmıştır. İncelenen tüketim veri setinde en iyi performans gösteren model karşılaştırma modeli olarak kullanılmıştır. Ayrıca elektrik yükü tahminini tek değişkenli bir zaman serisi problemi olarak modellenmiş ve böylece yaklaşımın diğer zaman serisi verilerine uygulanabilirliği savunulmuştur. Hasan, Toma, Nahid, Islam ve Kim (2019)'nin yapmış oldukları çalışmalarında ise akıllı şebeke sistemlerinde elektrik hırsızlığı tespiti LSTM ve evrişimsel sinir ağı (Convolutional Neural Network - CNN) tabanlı bir yaklaşımla yapılmıştır. Bouktif ve diğ. (2020)'nin yapmış oldukları çalışmalarında ise elektrik yükü tahmini için meta sezgisel yaklaşımlar, çok sıralı LSTM ve tekrarlayan sinir ağı (Recurrent Neural Network - RNN) gibi derin öğrenme tekniklerini kullanmıştır. Elde edilen sonuçlara göre, meta-sezgisel arama algoritmalarıyla ayarlanan çok sıralı derin öğrenme modelinin, karşılaştırmalı makine öğrenme modellerinden ve girdileri ve hiperparametreleri sınırlı deneyim ve indirgenmiş deney sayısıyla oluşturulan LSTM modelinden daha doğru sonuçlar sağladığını göstermektedir. Muzaffar ve Afshari (2019)'un yapmış oldukları çalışmalarında ise sıcaklık, nem ve rüzgâr hızı gibi eksojen değişkenlere sahip bir elektrik yükü verisi toplanmış; toplanan veriler, LSTM ağını eğitmek için kullanılmıştır. Adil bir karşılaştırma için veriler, yükleme süresi serilerini modellemek için geleneksel yöntemlerde de kullanılmıştır. Eğitimli LSTM ağı ve geliştirilen modeller daha sonra 24 saat, 48 saat, 7 gün ve 30 günlük beklentiler üzerinde tahmin yapmak için kullanılmıştır. LSTM tarafından oluşturulan tahminler, tüm tahmin beklentileri için karekök ortalama hata (Root Mean Squared Error - RMSE) ve ortalama mutlak yüzde hatası (Mean Absolute Percentage Error - MAPE) kullanan geleneksel yöntemlerin sonuçlarıyla karşılaştırılmıştır. Sonuçlar LSTM tabanlı tahminin

diğer yöntemlerden daha iyi olduğunu ve tahminlerin doğruluğunu daha da iyileştirme potansiyeline sahip olduğunu göstermiştir. Son olarak Dudek, Pelka ve Smyl (2021) yapmış oldukları çalışmalarında ise ara dönem yük tahmini için karma ve hiyerarşik bir derin öğrenme modeli sunulmuştur. Model üstel düzeltme (Exponential Smoothing - ETS) ve LSTM'yi bir araya getirmeyi amaçlayan bir modeldir. 35 Avrupa ülkesi için aylık elektrik talep zaman serileri üzerinde gerçekleştirilen bir simülasyon çalışması, önerilen modelin yüksek performansını ve ARIMA ve ETS gibi klasik modellerin yanı sıra makine öğrenimine dayalı son teknoloji modellerle rekabet edebilirliğini doğrulamıştır.

Türkiye'deki yapay sinir ağı (YSA) çalışmaları incelendiğinde Topallı, Erkmn ve Topallı (2006) bir gün öncesinden (kısa dönem) toplam elektrik yükünün tahmini için sinir ağı yaklaşımı geliştirmişler ve sonuçları geleneksel ARMA zaman serisi yöntemiyle karşılaştırmışlardır. YSA'da tekrarlayan sinir ağlarının bir alt sınıfı olan Elman ağı yapısının kullanıldığı çalışmada ARMA'ya kıyasla daha iyi sonuçlar elde edilmiştir. Bozkurt, Biricik ve Tayşi (2017) de yine kısa dönem tahminleme için mevsimsel otoregresif entegre hareketli ortalama (SARIMA) ve YSA yöntemlerini karşılaştırmıştır. YSA modeli olarak Levenberg- Marguardt algoritması ile eğitilen çok katmanlı algılayıcı kullanılmıştır. Ünlü (2019) üretilmesi gereken aylık elektrik üretim miktarının tahminine yönelik LSTM derin öğrenme yöntemi ile destek vektör makinaları ve çok katmanlı nöronlar şeklinde iki makine öğrenme yöntemi kullanmıştır. LSTM ile elde edilen sonuçlar daha başarılı bulunmuştur. Reşat (2020) ise kısa dönemli enerji tahmini için ARIMA ve YSA yöntemleriyle geliştirilen melez bir model sunmuştur. Çalışmasında tütün sektöründe faaliyet gösteren bir işletmenin veri setlerini kullanmış, sonuç olarak melez modelin ARIMA'nın tek kullanımına kıyasla daha başarılı sonuçlar verdiği gösterilmiştir.

Literatürde elektrik tahminleme çalışmalarında başarılı sonuçlar veren YSA metodu bu çalışmada kısa dönem elektrik yükü tahmini için kullanılmıştır. Literatürde yer alan çalışmalardan farklı olarak YSA yapısında, tekrarlı sinir ağı mimarisi olan LSTM temel alınmış ve elde edilen sonuçlar zaman serisi analiz sonuçlarıyla karşılaştırılmıştır. Bu kıyaslama ile yöntemlerin birbirlerine üstünlüklerinin sunulması amaçlanmıştır. Elektrik enerjisi veri seti, 01 Ocak 2015 ve 31 Aralık 2018 tarihlerini kapsayan

İspanya'nın saatlik elektrik üretim ve tüketim verilerini içermektedir. Çalışmada, yöntemlerin kıyaslanabilmesi için 2 yıllık verilerin yeterli olması ve veri işlemenin uzun zaman alması sebepleriyle 2015 - 2016 yılı verileri kullanılmıştır.

Tahmin doğru yapıldığında, elektrik üretimi tüketici talepleri doğrultusunda dengelenebilecektir. Bu çalışmanın amacı, elektrik yüklemesinde LSTM ağlarının uygulanmasıyla başarılı tahminler yapmaktır. Böylece elektrik üretimine öncülük edebilecek bir tahmin modeli sunulabilecektir.

2. Bilimsel Yazın Taraması

2.1 Yapay Sinir Ağı

YSA, problemlere uyum sağlama ve deneyimlerle birlikte otomatik olarak öğrenme yeteneğini kullanan bir teknik olarak bilinmektedir (Hernández, Baladrón, Aguiar, Carro, Sánchez-Esguevillas ve Lloret 2013). Başka bir deyişle, yapay bir nöronun, merkezi sinir sisteminin biyolojik bir nöronunu kopyalayan matematiksel bir model olduğu ifade edilebilir. Giriş sinyalleri, doğrusal olmayan reaksiyonların gösterilmesini sağlamaktadır (Ryu, Noh ve Kim, 2017).

YSA ağ yapılarından çok katmanlı algılayıcı (Multi-Layer Perceptron - MLP) Rumelhart, Hinton ve Williams tarafından 1996 yılında sunulmuştur. Benzer diğer teknikler ise Radial Temel Fonksiyon Ağları (RBF) (Broomhead ve Lowe, 1988), Tekrarlayan Ağlar (Elman, 1990 ve 1991) ile Kendi Kendini Düzenleyen Haritalar (SOM) (Kohonen, 1990) şeklindedir.

Literatürde YSA ile ilgili yapılmış çok sayıda çalışma bulunmaktadır. Park, El-Sharkawi, Marks, Atlas ve Damborg (1991), tek çıkış nöronlu bir YSA sistemini saatlik, toplam ve en yüksek yük tahmini için çalıştırmıştır. Ho, Hsu ve Yang (1992) 24 saat öncesinden en yüksek yük tahminini sunmak için önemli bir çalışma gerçekleştirmiştir. Lee, Cha ve Park (1992), bir günü üç döneme ayıran ve her dönem için yükü tahmin eden bir YSA modeli önermiş, Lu, Wu ve Vemuri (1993) ise yapmış oldukları çalışmada, iki yardımcı programın üç YSA modeli ile sistemlerini incelemiş ve sistemlerin birbirine bağlı olduğunu belirtmiştir. Papalexopoulos, Hao ve Peng (1994), girdi olarak belirtilen sıcaklığın doğrusal olmayan bir fonksiyon olarak gösterildiği yardımcı bir programı YSA'na eklemiş ve resmi tatillerde yük performansını geliştirmek için önlemler sunmuştur. Srinivasan,


Liew ve Chang (1994), günün dört periyodunun her birinde beklenen yük değişimini ölçen dört bulanık sayıyı belirten nicel ve nitel veri olarak ön-uç işlemci üretmiştir. Çalışmada hava durumu verileri, yük tahmini için YSA'ya dahil edilmiştir. Bakirtzis, Petridis, Kiartzis, Alexiadis ve Maissis (1996) resmi tatillerle ilgili yeni bir yaklaşım önererek, çalışmada YSA problemini çözmek için bulanık mantık kullanmıştır. AlFuhaid, El-Sayed ve Mahmoud (1997), gelecek 24 saatlik yük taleplerini tahmin etmek için kademeli sinir ağı tasarlamıştır. Drezga ve Rahman'ın (1998 ve 1999) yapmış oldukları çalışmalarda tek çıkışlı YSA'ların sürekli olarak yük eğrilerini tahmin etmek için kullanıldığı görülmüştür. McMenemy ve Monforte (1998) ise 24 saatlik paralel sistemi ele almıştır. Aydinalp, Ugursal ve Fung (2002) YSA yöntemini uygulayarak yaygın ulusal konut enerji tüketimi için bir model önermiştir. Becalli, Cellura, Lo Brano ve Marvuglia (2004), bir banliyö bölgesinin günlük elektrik yükü profillerini tahmin etmek için, yük ve hava durumu verilerini içeren MLP ile birlikte YSA ile ilgili bir yaklaşım ortaya koymuştur.

YSA metodu birçok uygulamada iyi sonuç verse de yük tahmin problemlerinde doğru tahminler elde etmede zorluklarla karşılaşmaktadır. Bu zorlukları açıklamada başvuru bazı nedenler bulunmaktadır. Bunlardan ilki, yük serilerinin karmaşık olması ve birçok dönemselliğe yol açmasıdır. Hesaplanan zamandaki yük, hem önceki saatteki yüke hem de önceki günün aynı saatindeki yüküne veya bir önceki hafta aynı değerle aynı saatteki yüke bağlıdır. İkinci olarak, hava ile ilgili değişkenler gibi çok sayıda önemli dışsal değişken mevcuttur. Makalelerin çoğunda uygulamalarda hava değerleri kullanılmaktadır. Bununla birlikte, elektrik yükü tahmininde standart bir uygulama olarak, tahmini hava değerleri yerine kayıtlı hava değerlerine başvurulmaktadır. Hava tahmininin belirsizliği dikkate alınrsa, gerçekteki uygulamalarda tahmin hatalarına yol açacaktır (Hippert ve diğ., 2001).

YSA tabanlı modelleri projelendirmek için beş temel adım vardır. Söz konusu adımlar sırasıyla veri toplama, verileri ön işleme, ağ oluşturma, eğitim ve model performansını test etme şeklindedir. Veri toplandıktan sonra, YSA'nın daha verimli kullanılması amacıyla etkin veriler önden işlenmektedir (Rodrigues ve diğ., 2014).

MLP'si olan YSA'nın temel bir gösterimi Şekil 1'de verilmiştir. Görüldüğü gibi MLP, girdi, gizli ve çıktı katmanları olan üç katmanlı bir yapıyla

oluşmaktadır. Her katmanda, katman içi bağlantıları olmayan nöronlar bulunmaktadır (Ryu ve diğ., 2017).



Şekil 1. Çok Katmanlı Algılayıcı Yapısı (Ryu ve diğ., 2017)

YSA için kullanılan başka bir yöntem, bellek bloklarını tekrarlayan gizli katmanda tutan LSTM'dir. Bellek blokları, işlemdeki tüm verileri kontrol etmek için kapılar adı verilen belirli çoklayıcı birimlere katılarak ağı geçici durumunu tutan kendi kendine bağlantılarla bellek hücreleriyle oluşur. Orijinal yapı için tüm bellek bloklarının bir giriş kapısı ve bir çıkış kapısı vardır. Giriş kapısı, giriş aktivasyonlarının bellek hücresine akışını kontrol eder. Diğer yandan, çıkış kapısı, hücre aktivasyonlarının çıkış akışını ağı geri kalanına doğru kontrol eder. Bu işlemden sonra, unutmaya kapısı bellek bloğuna eklenir (Gers, Schmidhuber ve Cummins, 2000). Bahsedilen bu süreç, alt dizilere ayrılmayan sabit girdi akışlarının idare edilmesine yol açan LSTM modellerinin yetersizliğini göstermektedir. Unutmaya kapısı, hücrenin kendi kendini tekrarlayan bağlantısı nedeniyle hücreye girdi olarak yerleştirmeden önce hücrenin iç durumunu ölçmektedir. Böylece, uyarlamalı olarak hücrenin hafızasını unutmaya veya sıfırlamaktadır. Dahası, klasik LSTM yapısı, çıktılar için belirli bir zamanlama tahmini yapmak için, dahili hücrelerinden aynı hücredeki kapılara, gözetleme deliği bağlantılarına sahiptir (Gers, Schraudolph ve Schmidhuber, 2003).

2.2 Zaman Serileri

Zaman serisi analizi, yalnızca modellenen değişken üzerindeki verileri ifade eden farklı modelleme girişimleri sağlamaktadır. Buna göre, zaman serisi analizi, operatörü etkili değişkenleri atama ve bunlar arasında bir ilişki şekli sunma zahmetinden kurtarmaktadır. Univariate Box-Jenkins (UBJ) ARIMA analizi (Box ve Jenkins, 1976) tıp, çevre, finans ve mühendislik uygulamaları gibi farklı alanlarda tahmin modelleri oluşturmak için akademisyenler tarafından yaygın olarak ele alınmıştır. İdeal tek değişkenli tahminler, yalnızca birkaç katsayı ile temel, üzerinde anlaşmaya varılan modeller uygulanarak yapılabilir. Gerçek uygulamalarda, tek değişkenli ARIMA modelleri, tahmin hassasiyeti açısından çok serili regresyon modellerinde veri talebi ile daha iyi gerçekleştirilebilir (Pankratz, 1983).

Box ve Jenkins (1976), geçerli bir ARIMA modeli oluşturmak için sırasıyla tanımlama, tahmin ve teşhis kontrolü olarak adlandırılan üç adımdan oluşan klasik bir yol haritası sunmuşlardır. Model sentezi esnasında, mevcut zaman serisinin sonunda yer alan bir kısım, genellikle, gelecekteki bilinen veriler üzerinde model performansını test etmek için ayrılmaktadır. Tanımlama aşamasında, otokorelasyon fonksiyonları (acf) ve kısmi

otokorelasyon fonksiyonları (pacf), zaman serisi verileri için doğru bir şekilde bulunmuş ve bunlar, bilinmeyen oluşturma işlemi için öngörülen acf ve pacf olarak temsil edilmiştir. Bu fonksiyonların durağanlığı gösterilerek, ilk olarak zaman serilerinin hem mevsim olmayan hem de mevsimsel seviyeler için uygun dönüşümlerle sabit bir seriye dönüştürülmesi gerekmektedir. ARIMA modelleme, teorik acf ve pacf fonksiyonlarına en çok benzeyen bir veya daha fazla ARIMA modelini geçici olarak seçme amacıyla kılavuz olarak kullanılan, gelişmekte olan sabit seriler üzerine inşa edilmiştir. Genellikle, ARIMA modeli AR (otoregresif) ve MA (hareketli ortalamalar) bölümlerinin bir bileşimidir. ARIMA modelinde bu iki model mevsimsel ve mevsimsel olmayan parçalara sahip olabilmektedir. Uygun bir tahmin modeli, mevcut verileri ifade etmek için en az sayıda katsayıya sahip olan modeldir. Tahmin aşamasında, bu katsayılar model fonksiyonunu zaman serisi verilerine göre ayarlayarak ve kalan hatalar için kriterleri en aza indirerek tahmin edilmektedir. Yararlı bir model oluşturmak için, katsayılar yüksek istatistiksel kaliteye sahip olmalı, yüksek düzeyde ilişkilendirilemez olmamalı, belirli durağanlık ve ters döndürülebilirlik koşullarını karşılama gerekmektedir (Pankratz, 1983).

3. Yöntem

3.1 Veri Toplama

Araştırma ve yayın etiğine uyulan bu çalışmada kullanılan veriler Kaggle web sitesi üzerinden elde edilmiştir. Konuyla ilgili olarak Kaggle'da iki farklı veri tablosu paylaşılmıştır. Bunlardan biri, çeşitli enerji kaynakları (rüzgar, güneş, hidro, kömür vb.), saatlik elektrik enerjisi tüketim verileri ve saatlik elektrik fiyatları ile saatlik elektrik enerjisi üretim verilerini içermektedir. Diğer veri tablosu İspanya'nın 5 büyük şehri için saatlik hava durumu parametrelerini (sıcaklık, rüzgar, bulutlar vb.) içermektedir. Her iki veri tablosu da 2015'in başından 2018'in sonuna kadar olan döneme aittir.

Elektrik enerjisi üretimi ve tüketimi verileri, İletim Hizmeti Operatörü (TSO) verileri için halka açık bir portal olan ENTSOE'den toplanmıştır. Fiyat değerleri İspanya TSO Red Electric España'dan alınmış ve İspanya'nın en büyük 5 şehri için Açık Hava API'sinden hava durumu verileri toplanmıştır.

Elektrik enerjisi üretimi ve tüketim verileri, LSTM ve ARIMA modelleri için derinlemesine

kullanılmıştır. Bunların yanı sıra, gerekli karmaşık çok değişkenli modellerin sahip olduğu hesaplama zorlukları sebebiyle, çok değişkenli zaman serisi tahmini gibi gelecekteki çalışmalar için hava durumu verileri depolanmıştır.

3.2 Model Geliştirme

Saatlik elektrik enerjisi veri seti 35.040 zaman noktasına sahiptir ve her bir zaman noktası için üretim ve tüketim verileri bulunmaktadır. Bu verileri analiz etmek ve tahminde bulunmak için iki farklı model geliştirilmiştir. İlk model YSA tabanlı bir tahmin modeli, ikincisi bir ARIMA modelidir. Her ikisi yöntem çalıştırılarak aynı zaman dilimlerini tahmin etmek için test edilmiş ve elde edilen sonuçlar buna bağlı olarak karşılaştırılmıştır.

YSA ve ARIMA modellerini geliştirmek için Python bilimsel programlama dili kullanılmıştır. Açık kaynak kodlu ve çok popüler bir programlama dili olan Python, model geliştirmek için çok kullanışlı yöntemler içeren çok sayıda kütüphaneye sahiptir. Buna ek olarak, bu kitaplıklar dünya genelindeki akademik çalışmalarda yaygın olarak kullanıldığı için güvenilir yapıdadır ve olumlu yönde gelişmeye/geliştirilmeye devam etmektedir. Model geliştirmede en sık kullanılan kitaplıklar "numpy, pandas, matplotlib, scikitlearn" şeklinde sıralanabilmektedir. Bunlara ek olarak bu çalışmada, ARIMA modeli geliştirilirken istatistik modelleri kitaplığı, LSTM ağını geliştirmek için de keras ile tensorflow kullanılmıştır. Uygulamada JupyterLab ortamı kullanılarak bir iPythonNotebook oluşturulmuş ve tüm geliştirmeler bu platform üzerinde gerçekleştirilmiştir. Çalışmada kullanılan YSA ve ARIMA modellerinin detayları takip eden bölümlerde verilmiştir.

Kullanılan yöntemlerin performansları farklı istatistiksel ölçümler kullanılarak karşılaştırılmıştır. Ortalama mutlak hata (MAE) ve kök ortalama kare hatası (RMSE) "ortalama hata" kavramına dayanan yaygın olarak kullanılan ölçümler arasındadır (Türkan, Yumurtacı Aydoğmuş ve Erdal, 2016). Çalışmada bu iki istatistiksel ölçüm kullanılmıştır.

3.2.1. YSA Tabanlı Tahmin Modeli

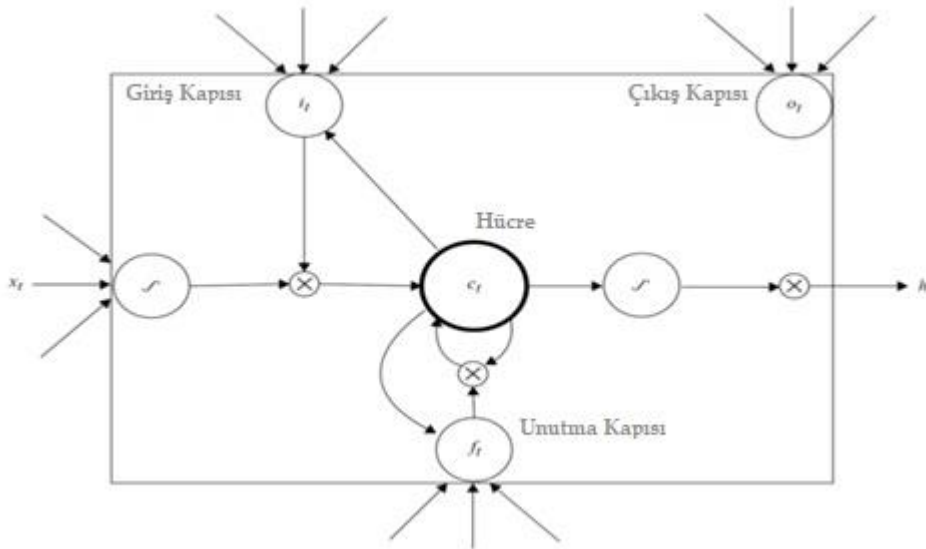
Bu modelde LSTM ağları, bir zaman serisini analiz edip tahmin yapabilen bir sinir ağı geliştirmek için seçilmiştir. LSTM, tekrarlayan bir sinir ağı (Recurrent Neural Network - RNN) yapısıdır. LSTM, standart ileri beslemeli sinir ağlarından farklı şekilde geri bildirim bağlantılarına sahiptir. İç

bellek katmanlarına sahiptirler, bu da onlara yakalama modelleri, otomatik korelasyonlar ve ardışık zaman noktaları arasındaki kısmi oto korelasyonlarda önemli bir avantaj sağlamaktadır. Bu yetenek, bir zaman serisini başarılı bir şekilde analiz etmek ve kesin tahminler yapmak için son derece önemlidir.

Tekrarlayan sinir ağları, mevcut sinir ağında kullanılmak üzere kalıcı geçmiş bilgileri kullanır ve tipik kısa süreli belleğe sahiptirler. LSTM, tekrarlayan sinir ağlarına uzun süreli bellek sunmaktadır. Belirli bir sinir ağındaki çeşitli ağırlıklarda yapılan güncellemeler gittikçe küçüldüğünden, sinir ağının öğrenmeyi durdurduğu yer olan kaybolan gradyan problemini hafifletir.

İşlem Şekil 2'de görüldüğü gibi tamamlanmaktadır (Gall, 2018):

Şekil 2'de üç tip kapı bulunduğu görülmektedir. Bunlardan ilki, hücreye giriş katmanı olan ölçeklendirme girdisidir (yazma). İkincisi, çıktıyı hücreye dönüştüren (okuma) çıkış katmanıdır. Son kapı ise, eski hücre değerini ölçeklendiren (sıfırlama) unutma katmanıdır. Her kapı, okuma / yazmayı kontrol eden bir anahtar gibi davranarak uzun süreli bellek işlevini modelle ilişkilendirmektedir.



Şekil 2. LSTM Ağı (Gall, 2018)

LSTM mimarisinin diğer sinir ağlarına (özellikle MLP'ler üzerinden) kıyasla çok önemli bir başka avantajı, LSTM ağı ile keras-timeerisgenerator işlevinin kullanılabilirliğidir. Bir zaman serisi verisini bir girdi değişkeni olarak bir sinir ağına doğrudan beslemek mümkün olmadığından, diğer sinir ağları için verilerin uzun ve karmaşık bir ön işleme gereklidir. MLP'lerin model performansı zaman serisi tahminlerinde oldukça iyi olsa bile, zaman serisi girdi verilerinin ayarlanması ve modele anlamlı eşlemelerin beslenmesi gerekmektedir. Bununla birlikte, keras.timeseriesgenerator işlevi, zaman serisi verilerini girdi olarak almakta ve bunları, LSTM modelinin kendisini eğitebileceği ve üzerinde

tahminler yapabileceği uygulanabilir forma dönüştürmektedir.

Zaman serisi verilerinde tahminler yapmak için bir LSTM modeli oluşturmak için aşağıdaki adımların gerçekleştirilmesi gerekmektedir:

- **Açıklayıcı Veri Analizi:** Temel istatistiksel parametreler pandas kitaplığının `df.describe` yöntemi ile elde edilebilmektedir. Zaman serisi veri setinde, veri noktaları sıralı olduğundan, aykırı değerler normal bir regresyon modeli olarak silinemez. Zaman serileri için açıklayıcı veri analizinin en önemli kısmı, verilerdeki eksik değerleri ele almaktır. Bu verileri komşu değerlere bağlı olarak doldurmak, sonuçları önemli ölçüde etkilemeden eksik değerleri ele almak için iyi bir yöntem olabilmektedir.

- **ACF - PACF Grafikleri:** Otokorelasyon ve kısmi oto korelasyon fonksiyon grafikleri, zaman serisi verilerinin özelliklerini anlamak için çok önemlidir. Otokorelasyon fonksiyonu (Autocorrelation function - ACF), herhangi iki değeri arasındaki korelasyonun sinyallerinin, bu iki değer arasındaki korelasyon ayrımı değiştikçe nasıl değişeceğini göstermektedir (Nounou, 2000). Kısmi bir otokorelasyon, bir zaman serisindeki bir gözlem ile önceki zaman adımlarındaki gözlemler arasındaki ilişkinin, araya giren gözlemlerin ilişkileri kaldırılmış olan ilişkisinin bir özetidir (Brownlee, 2017). Bu grafikler sayesinde bitişik zaman noktası verilerinin ne kadar benzer veya farklı olduğu görülebilmekte ve kaç gecikme verisinin benzerlik gösterdiği bulunabilmektedir.
- **Veri Kümelerini Eğitmek ve Test Etmek için Verileri Bölme:** Makine öğrenme ve derin öğrenme modellerinin çoğu, aşırı uyum sorunu yaşayabilmektedir. Aşırı uyum, modelin eğitilen veri setine oldukça iyi uyması anlamına gelir, ancak yeni veriler üzerinde tahminlerde bulunmak başarılı sonuçlara ulaştırmaz. Bu sorunu önlemek için, yaygın bir yöntem, veri setinin eğitimi ve test etmek için veri setlerini bölmek gerekmektedir. Zaman serileri dışındaki çoğu problemde bu, verilerin % 75'i eğitim ve % 25'i test için karıştırılarak yüzdelere bölünmesi yöntemiyle yapılmaktadır (Han, Kamber ve Pei, 2011). Ancak bu, zaman serileri için yapılamaz çünkü veri noktaları yalnızca gerçek sıraları ile anlamlıdır. Zaman serisi analizinde, test verileri eğitim verilerinin hemen ardından başlamalı ve karıştırma yapılmamalıdır.
- **Verileri Ölçeklendirme:** Makine ve derin öğrenme modelleri birçok farklı değişkeni ele almak için kullanılmaktadır. Bu değişkenler bu kadar farklı ölçeklere sahip olabileceğinden, çok faydalıdır ve bazı modellerde verileri sıfır ile bir arasında ölçeklendirmek zorunludur.
- **Zaman Serisi Üretici:** Zaman serisi verileri doğrudan sinir ağlarına beslenemediğinden, zaman serisi oluşturma aracı çok kullanışlı hale gelmiştir. Zaman serisi verilerini ilk önce kendi başına analiz etmek çok önemlidir, çünkü zaman serisi üreticinin en kritik girdisi geriye bakma değeridir. Bu değer, zaman serisi verilerindeki kopyalar analiz edilerek tahmin edilebilmektedir.
- **LSTM Model Oluşturma:** Bir girdi katmanı, bir unutma katmanı ve bir çıktı katmanı bir LSTM

modelini oluşturmaktadır. Düğüm sayısı, etkinleştirme işlevi seçimi ve unutma eşiği gibi ayarlanması gereken bazı hiperparametreler vardır. Bundan sonra modelin seçilen optimize edici ve kayıp fonksiyonu ile derlenmesi gerekmektedir.

- **Eğitilmiş Verilere LSTM Modelini Uydurma:** LSTM modelinin zaman serisi verilerinin özelliklerini öğrenmesine izin vermek için, modelin eğitilen veri setine uydurulması gerekmektedir. Burada epochs sayısı parametresi çok önemlidir. Kayıp değerlerin bozulma oranı izlenerek belirlenebilmektedir. Bir eğitim diyagramı bu durumda gerçekten yardımcı olabilmektedir.
- **Test Veri Kümesindeki Değerleri Tahmin Etme:** LSTM modeli zaman serisi verilerini öğrendikten sonra, yeni verilerin tahmin yeteneğini test etmemiz gerekmektedir. Test veri seti üzerinde tahmin yapmak, modeli zorlama yoluyla gerçekleştirilmektedir.
- **Önleme Değerlerinin Ölçeğini Küçültme:** Eğitim ve test veri kümeleri, onları LSTM modeline beslemek için ölçeklendiğinden, bunları gerçek değerlerle karşılaştırabilmek için ölçeklerinin kaldırılması gerekmektedir.
- **Gerçek ve Tahmin Edilen Değerleri Karşılaştırma:** Model çıktıları ve gerçek değerler karşılaştırılmalı ve gerekirse model hiperparametrelerinin (dönem sayısı, zaman serisi oluşturucunun geriye bakma değeri, öğrenme oranı vb.) ayarlanması gerekmektedir.

3.2.2 ARIMA Modeli

YSA tabanlı tahmin modelinin etkinliğini kontrol etmek için başka bir zaman serisi tahmin modeli olan ARIMA modeli oluşturulmuş ve tahmin değerleri karşılaştırılmıştır. Model geliştirme aşamasında en kritik nokta, parametrelerin seçimi ve ARIMA modelinin türünün belirlenmesi olmuştur. Bu parametreleri belirlemek için Python'un çok yararlı araçları olsa bile, zaman serisi verilerinin kendi başına analiz edilmesi gerekmektedir. Özellikle dönemsellik unsuru ARIMA parametrelerini belirlemede kilit bir faktördür. Python'un dönemsel ayrıştırma grafikleri, zaman serisi verilerinin dönemsellik özelliklerini anlamaya gerçek manada yardımcı olmaktadır. Bu karar verildikten sonra dönemsellik kriterlerinin python'un auto.arima fonksiyonuna

beslenmesi gerekmekte ve bu yapılarak çok verimli ARIMA parametreleri elde edilmektedir. Model geliştirme ve çalıştırma aşamalarının geri kalanı YSA'da açıklandığı gibi gerçekleşmiştir. Model, çalışmadaki zaman serisi verilerini öğrenmek için eğitim veri setlerine yerleştirilmiş, daha sonra modelin test verileri üzerinden tahmini yapılmış ve tahmin edilen değerler gerçek değerlerle karşılaştırılmıştır. Sonuç olarak beklenen değerler elde edilmediğinde, ARIMA model parametrelerinin tekrardan ayarlanması gerekmektedir.

4. Bulgular

4.1 Veri Kümesi

Elektrik enerjisi veri seti, 01.01.2015 ile 31.12.2018 arasındaki tarihleri kapsayan saatlik elektrik üretim ve tüketim verilerini içermektedir. Orijinal veri setinde elektrik enerjisi üretim verileri doğalgaz, rüzgâr, güneş vb. üretim kaynaklarına göre verildiği için, yirmiden fazla sütun bulunmaktadır. Analiz için bu detay gerekmediğinden tüm üretim verileri satır bazında toplanmış ve toplam elektrik enerjisi üretim saatlik verileri alınarak "üretim" sütununa eklenmiştir. Böylelikle veri seti sadeleştirilmiş ve Tablo 1'de görüldüğü gibi oluşturulmuştur:

Tablo 1
Veri Kümesi Özeti

Zaman	Üretim	Tüketim
2014-12-31 23:00:00+00:00	28251.0	25385.0
2015-01-01 00:00:00+00:00	27818.0	24382.0
2015-01-01 01:00:00+00:00	26796.0	22734.0
2015-01-01 02:00:00+00:00	25223.0	21286.0
2015-01-01 03:00:00+00:00	24620.0	20264.0

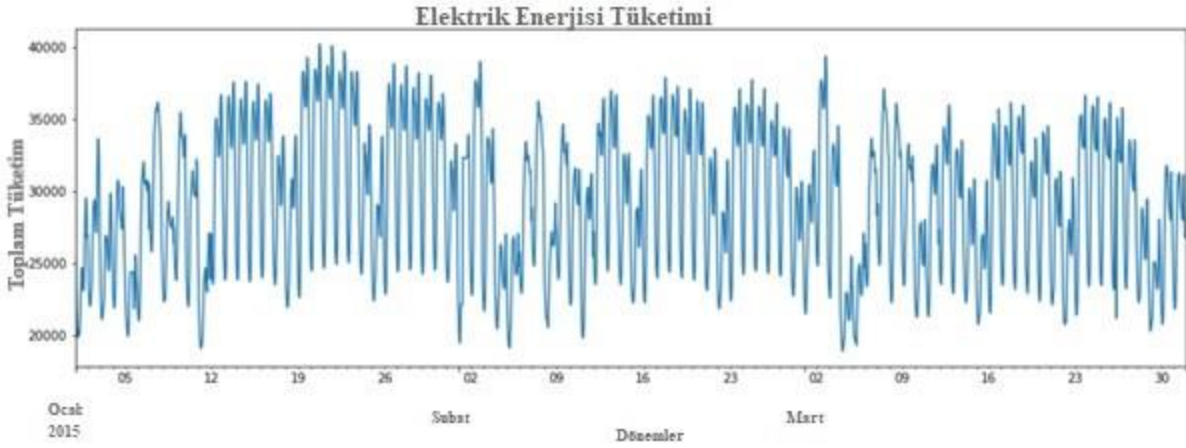
Tablo 2
Tanımlayıcı İstatistikler

	Üretim	Tüketim
Miktar	35064.000000	35064.000000
Ort	28623.286162	28697.608573
std	4233.491084	4575.872425
min	0.000000	18041.000000
25%	25441.000000	24806.750000
50%	28454.000000	28902.000000
75%	31568.000000	32194.250000
max	42310.000000	41015.000000

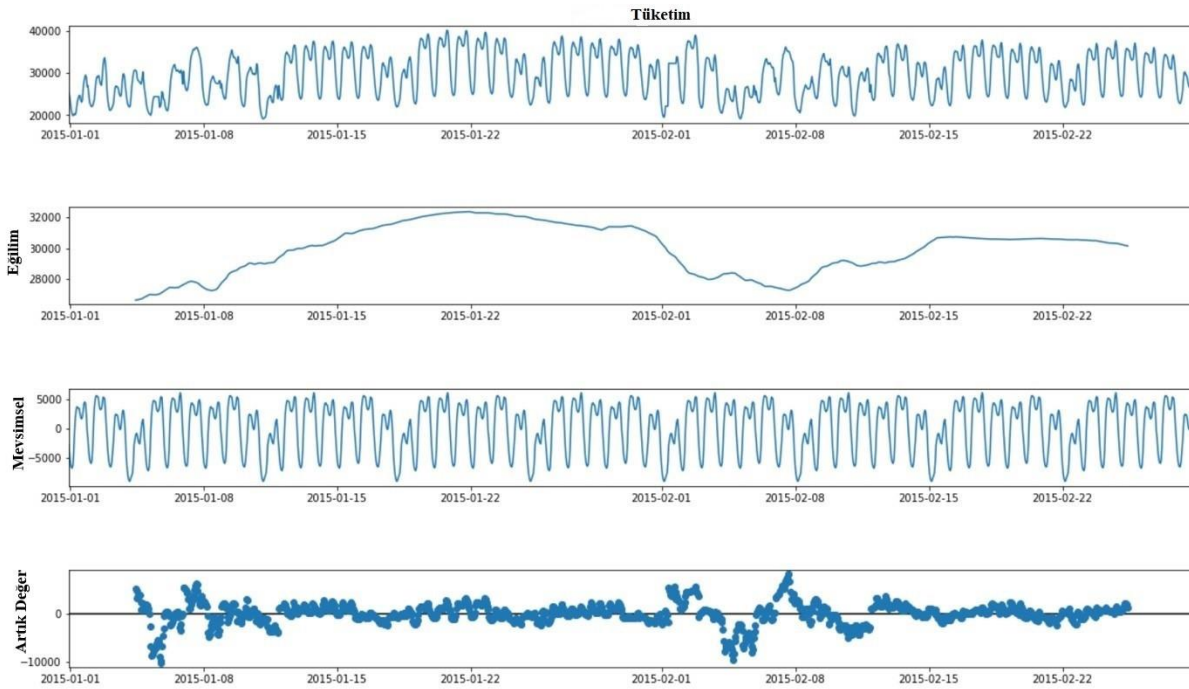
Veri kümesinin 35064 satırı vardır ve bahsedilen değişiklikten sonra 3 sütun haline getirilmiştir. İlk sütun zaman noktalarını temsil etmektedir. Bu sütun indeks olarak kullanılmıştır. Veri seti çok iyi organize edilmekle birlikte çok sınırlı sayıda boş değer bulunmaktadır. Bu boş değerler, enterpolasyonla doldurulmuştur. Veri setinin açıklayıcı istatistiksel analizinin bir özeti Tablo 2'de gösterilmiştir. Hem üretim hem de tüketim sütunlarının ortalama değerleri neredeyse eşittir çünkü elektrik depolanmadığı gibi talep kadar üretilmesi gerekmektedir. Ayrıca tüketimdeki standart sapmanın, üretimden biraz daha fazla olduğu da görülebilir. Çünkü talep üretimden daha fazla değişebilir ve elektrik santralleri talep dalgalanması kadar esnek olmayabilir. Bu fark, tüketimi tahmin etmenin önemini göstermektedir.

4.2Dönemsel Ayrışma

Bir zaman serisi, verilerin özelliklerini anlamak için dönemsel, trend ve artık bileşenleri içermektedir. Şekil 3'de tüketim verilerinin ilk kısmı (2015 yılına ait ilk üç ay) görülmektedir. Ancak dönemsel ayrıştırma uygulandıktan sonra, zaman serilerinin tüm bileşenleri analiz edilebilmektedir. Bir gün içinde veriler belirli bir düzende dalgalanmakta ve ayrıca her hafta sonu azalmaktadır. Bu hafta bazındaki dönemsel, her iki geliştirilmiş modelde de kullanılmıştır (haftalık döngü 168 veri noktasından oluşmaktadır), çünkü günlük dönemseliği de kapsamaktadır. Ayrıştırma grafikleri ise Şekil 4'de yer almaktadır.



Şekil 3. 2015 Tüketim Verileri (İlk üç ay)

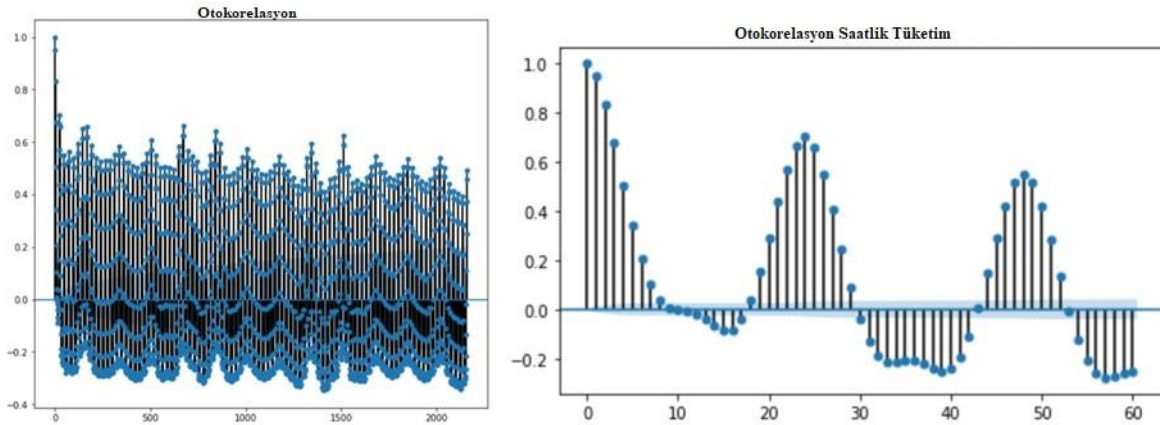


Şekil 4. Ayrıştırma Grafikleri

4.3 Oto-korelasyon İşlevleri (ACF)

ACF grafiklerinden tüketim verilerinde çok güçlü bir oto-korelasyon olduğu görülebilir. Daha net bir görselleştirme yapmak için Şekil 5'de 60 saatlik bir ACF grafiği gösterilmiştir. Çoğu gecikmede hem

pozitif hem de negatif yönde önemli korelasyonların olduğu görülebilmektedir.

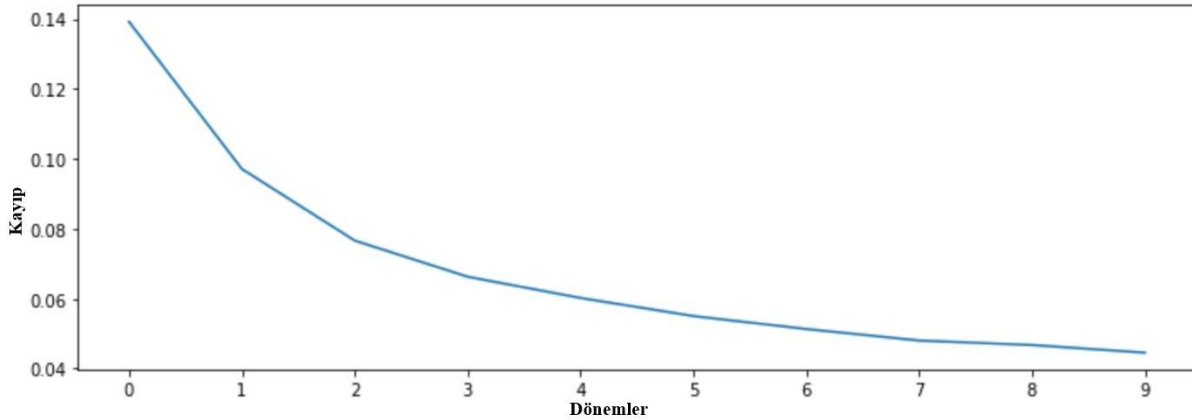


Şekil 5. ACF Grafikleri

4.4 YSA Modeli ve Çıktıları

YSA modeli 100 düğüme sahip bir LSTM katmanından, 100 düğüme sahip bir bırakma katmanından ve 1 düğüme sahip yoğun bir katmandan oluşmaktadır. Kayıp fonksiyonu olarak Adam optimizyer ve Ortalama mutlak hata (mae)

kullanılmıştır. Çalışmalar neticesinde 1 yılı kapsayan ve 10 dönemden oluşan veri setinin eğitilmesiyle model oturmuştur. Söz konusu kayıp fonksiyonunun eğim diyagramı Şekil 6'da görülmektedir.




Şekil 6. Kayıp Fonksiyonunun Eğim Şeması

Yapılan çalışmada, model 1 yıllık verilerle eğitildikten sonra, eğitilen veri setinde 1 yıllık verilerden sonra 1 hafta sonrasına ait test veri setinin değerleri tahmin edilmeye çalışılmıştır. Görselleştirilmiş sonuçlar Şekil 7'de gösterilmektedir. Tahminlerin ortalaması

28697.6085 ve karekök ortalama hatası 7069.1917 çıkmıştır.

Şekil 7'ye göre model haftanın bazı günleri doğru gerçekleşmiş, fakat günler arasındaki ani artış ve düşüşler tahmin edilememiştir.




Şekil 7. Gerçek Verilerle Karşılaştırmalı YSA Modeli Tahminleri

4.5 ARIMA Modeli ve Çıktıları

YSA modelinin sonuçlarını karşılaştırmak için bir ARIMA modeli geliştirilmiştir. ARIMA modelinin parametreleri python'un auto-arima fonksiyonu ile elde edilmiştir. Karar verilen model bir SARIMAX (2,1,2) (0,1,0,168) modelidir. Bu model, dönemsel bir ARIMA modelidir. İlk üç parametre (2,1,2)

normal ARIMA modeline, son 4 parametre (0,1,0,168) ise dönemsel operatöre aittir.

ARIMA modeli, YSA metodu ile kıyaslama yapılabilmesi açısından aynı zaman periyodu ile eğitilmiş ve test edilmiştir. Tahminlere ait RMSE değeri 4992.951, ve MAE değeri ise 3927.225 şeklinde elde edilmiştir.



Şekil 8. Gerçek Verilerle Karşılaştırmalı ARIMA Modeli Tahminleri

Şekil 8'e göre, ARIMA modeli de haftanın bazı günlerini tahmin etmeyi başarmış ancak günler arasında ani artış ve düşüşleri tahmin edememiştir. Auto.arima fonksiyonları parametre seçim özelliğinden kaynaklanmaktadır. Bu sayede ARIMA modeline uygun parametreler beslenebilmekte ve çok fazla eğitim verisine ihtiyaç duymadan tahminler yapılabilmektedir.

5. Sonuç

Bu çalışmada, saatlik elektrik enerjisi verileri YSA yapısında, tekrarlı sinir ağı mimarisi olan LSTM temel alınarak analiz edilmiş ve elde edilen sonuçlar zaman serisi analiz sonuçlarıyla karşılaştırılmıştır. Bu karşılaştırmalar neticesinde elektrik yüklemesinde LSTM ağlarının uygulanmasıyla başarılı tahminler yapmak çalışmanın amacını oluşturmaktadır. Tarihsel verilere dayalı olarak bir

LSTM modeli ve bir ARIMA modeli geliştirilmiş ve her iki modelin tahmin sonuçları karşılaştırılmıştır. Bu karşılaştırmaya göre her iki model de benzer performanslar vermiştir. Ancak temel farklılıklar, model oluşturma ve eğitim aşamalarındadır. YSA tabanlı model daha çok bir kara kutu gibidir. Ön analiz yerine, modelin performansını artırmak için çok sayıda hiperparametre ayarı gereklidir. Bunu yapmak için, her dönemin günlük çalışma sürelerinin olması nedeniyle çok fazla hesaplama gücüne ihtiyaç duyulmaktadır. Buna ek olarak, YSA modeli ARIMA modelinden çok daha fazla eğitim verisine ihtiyaç duymaktadır. Çünkü modeli eğitmeden önce ARIMA'daki gibi herhangi bir parametre girilmemektedir. Modelin kendisi, zaman serisinin özelliklerini öğrenmek için yeterlidir. Bu faktör aynı zamanda çalışma sürelerini de arttırmaktadır. YSA model kullanımının temel avantajı, daha yüksek boyutlu çok değişkenli tahmin problemlerinde çok yüksek hesaplama gücünün olmasıdır.

ARIMA modeli, dönemsel ARIMA parametrelerini belirlemek için daha fazla ön veri analizi gerektirmektedir. Özellikle dönemsel faktörünün çok hassas bir şekilde belirlenmesi gerekmektedir. Diğer parametreler yeniden çalıştırılarak ayarlanabilmektedir. Bu parametreler başarılı bir şekilde belirlenebilirse, ARIMA modeli daha düşük eğitim verisi ile iyi tahminler yapabilmektedir. Bu faktör, kişisel bilgisayarlarının hesaplama gücü yüksek olan araştırmacılar için ARIMA modelinin kullanımını daha kolay hale getirmektedir. ARIMA modelinin bir diğer avantajı da veri hazırlama ve zaman serisi oluşturucu kullanımı gerektiren YSA modelinin aksine, zaman serisi verilerini doğrudan modele beslemenin mümkün olmasıdır. Daha önce belirtildiği gibi, açıklayıcı veri analizi, otokorelasyonlar ve dönemsel ayrıştırmaların, modeli oluşturmadan önce çok hassas bir şekilde gerçekleştirilmesi gerekmektedir. ARIMA modeli, kara kutu gibi olan YSA modelinden daha kolay anlaşılabilir.

Bu çalışma, tek değişkenli bir zaman serisi analizini ve tahminini kapsamaktadır. Gelecekteki bir çalışma hedefi olarak, hava faktörleri modele dâhil edilebilir, 4 yıllık verinin tamamı kullanılarak çok değişkenli bir zaman serisi tahmin problemi ele alınabilir.

Araştırmacıların Katkısı

Bu araştırmada Eren KAMBER, problemin incelenmesi, literatür taraması ve yazımı; Sencer KÖRPÜZ, verilerin elde edilmesi ve analizi; Melih CAN, literatür taraması, yazımı ve makalenin yazım kurallarına göre düzenlenmesi; Hacer YUMURTACI AYDOĞMUŞ, verilerin elde edilmesi, analizi, kaynakçanın yazımı ve düzenlenmesi; Mehmet GÜMÜŞ, verilerin elde edilmesi ve analizi konularında katkı sağlamışlardır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- AlFuhaid, A. S., El-Sayed, M. A. ve Mahmoud M. S. (1997). Cascaded Artificial Neural Networks For Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, 12(4), 1524–1529. Doi: <https://doi.org/10.1109/59.627852>
- Amjady, N. (2001). Short-Term Hourly Load Forecasting Using Time Series Modeling with Peak Load Estimation Capability. *IEEE Transactions on Power Systems*, 16, 798–805. Doi: <https://doi.org/10.1109/59.932287>
- Aydinalp, M., Ugursal, V.I. ve Fung A. (2002). Modeling of the Appliance, Lighting, and Space Cooling Energy Consumptions in the Residential Sector Using Neural Networks. *Applied Energy*, 72(2), 87–110. Doi: [https://doi.org/10.1016/S0306-2619\(01\)00049-6](https://doi.org/10.1016/S0306-2619(01)00049-6)
- Bakirtzis, A.G., Petridis, V., Kiartzis, S.J., Alexiadis, M.C. ve Maissis, A.H. (1996). A Neural Network Short Term Load Forecasting Model for The Greek Power System. *IEEE Transactions on Power Systems*, 11, 858–863. Doi: <https://doi.org/10.1109/59.496166>
- Bakirtzis, A.G., Theocharis, J.B., Kiartzis, S.J. ve Satsois, K.J. (1995). Short Term Load Forecasting Using Fuzzy Neural Networks. *IEEE Transactions on Power Systems*, 10(3), 1518–24. Doi: <https://doi.org/10.1109/59.466494>
- Beccali, M., Cellura, M., Lo Brano, V. ve Marvuglia, A. (2004). Forecasting Daily Urban Electric Load Profiles Using Artificial Neural Networks. *Energy Conversion and Management*, 45, 2879–2900.

- Doi: <https://doi.org/10.1016/j.enconman.2004.01.006>
- Bouktif, S., Fiaz, A., Ouni, A. ve Serhani, MA. (2018). Optimal Deep Learning LSTM Model for Electric Load Forecasting Using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches. *Energies*, 11(7):1636. Doi: <https://doi.org/10.3390/en11071636>.
- Bouktif, S., Fiaz, A., Ouni, A. ve Serhani, MA. (2020). Multi-Sequence LSTM-RNN Deep Learning and Metaheuristics for Electric Load Forecasting. *Energies*, 13(2):391. Doi: <https://doi.org/10.3390/en13020391>.
- Box, G. E. P. ve Jenkins G. M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco.
- Bozkurt, Ö. Ö., Biricik, G. ve Tayşi, Z. C. (2017). Artificial Neural Network and Sarıma Based Models for Power Load Forecasting in Turkish Electricity Market. *PLoS ONE* 12(4): e0175915. Doi: <https://doi.org/10.1371/journal.pone.0175915>.
- Bridger, M. M., Ross, J. W. ve Park, R. E. (1986). A Short Guide to Electric Utility Load Forecasting. Rand, Santa Monica, ISBN:0-8330-0714-9.
- Broomhead, D. S. ve Lowe, D. (1988). Multivariable Functional Interpolation and Adaptive Networks. *Complex Syst.*, 2, 321-355.
- Brownlee, J. (2017). A Gentle Introduction to Autocorrelation and Partial Autocorrelation. Machine Learning Mastery, Erişim Adresi: <https://machinelearningmastery.com/gentle-introduction-autocorrelation-partial-autocorrelation/>
- Carpinteiro, O., Reis, A. ve Silva, A. (2004). A Hierarchical Neural Model in Short-Term Load Forecasting, *Applied Soft Computing*, 4, 405-412. Doi: <https://doi.org/10.1016/j.asoc.2004.02.005>
- Charytoniuk, W., Chen, M. S. ve Van Olinda, P. (1998). Nonparametric Regression Based Shortterm Load Forecasting. *IEEE Transactions on Power Systems*, 13, 725-730. Doi: <https://doi.org/10.1109/59.708572>
- Cho, M. Y., Hwang, J. C. ve Chen, C.S. (1995). Customer Short-Term Load Forecasting By Using Arima Transfer Function Model. *Proc Int Conf Energy Manage Power Deliv.*, 1, 317-322. Doi: <https://doi.org/10.1109/EMPD.1995.500746>
- Drezga, I. ve Rahman, S. (1998). Input Variable Selection for Ann-Based Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, 13, 1238-1244. Doi: <https://doi.org/10.1109/59.736244>
- Drezga, I. ve Rahman, S. (1999). Short-Term Load Forecasting with Local Ann Predictors. *IEEE Transactions on Power Systems*, 14, 844-850. Doi: <https://doi.org/10.1109/59.780894>
- Dudek, G., Pelka, P. ve Smyl, S. (2021). A Hybrid Residual Dilated LSTM and Exponential Smoothing Model for Midterm Electric Load Forecasting. *IEEE Transactions On Neural Networks And Learning Systems*, 1-13, Doi: <https://doi.org/10.1109/TNNLS.2020.3046629>.
- Elman, J. L. (1990). Finding Structure in Time. *Cognit. Sci.*, 14, 179-211. Doi: [https://doi.org/10.1016/0364-0213\(90\)90002-E](https://doi.org/10.1016/0364-0213(90)90002-E)
- Elman, J. L. (1991). Distributed Representations, Simple Recurrent Networks, and Grammatical Structure. *Mach. Learn*, 7, 95-126. Doi: <https://doi.org/10.1007/BF00114844>
- Fan, J. Y. ve McDonald, J. D. (1994). A Real-Time Implementation of Short-Term Load Forecasting for Distribution Power Systems. *IEEE Transactions on Power Systems*, 9, 988-994. Doi: <https://doi.org/10.1109/59.317646>
- Feinberg, E. A. ve Genethliou, D. (2005). Load forecasting, chapter 12 in Applied Mathematics for Restructured Electric Power Systems: Optimization Control, and Computational Intelligence, Springer-Verlag, New York.
- Gall, R. (2018). What does LSTM stand for? Erişim adresi: <https://hub.packtpub.com/what-is-lstm/#:~:text=LSTM%20stands%20for%20long%20short.in%20the%20current%20neura%20network.>
- Gers, F. A., Schmidhuber, J. ve Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12 (10), 2451-2471. Doi: <https://doi.org/10.1162/089976600300015015>
- Gers, F. A., Schraudolph, N. N. ve Schmidhuber, J. (2003). Learning precise timing with LSTM recurrent networks. *Journal of Machine Learning Research*, 3, 115-143. Doi: <https://doi.org/10.1162/153244303768966139>
- Gross, G. ve Galiana, F. D. (1987). Short-term load forecasting, *Proceedings of the IEEE*, 75(12),

- 1558–1573. Doi: <https://doi.org/10.1109/PROC.1987.13927>
- Hagan, M. T. ve Behr, S. M. (1987). The time series approach to short term load forecasting. *IEEE Trans Power Syst*, 2, 785–91. Doi: <https://doi.org/10.1109/TPWRS.1987.4335210>
- Haida, T. ve Muto, S. (1994). Regression based peak load forecasting using a transformation technique. *IEEE Trans Power Syst*, 9, 1788–94. Doi: <https://doi.org/10.1109/59.331433>
- Han, J., Kamber, M., ve Pei, J. (2011). Data mining concepts and techniques third edition. *The Morgan Kaufmann Series in Data Management Systems*, 5(4), 83-124.
- Hasan, M. N., Toma, R. N., Nahid, A. A., Islam, M. M. M. ve Kim, J. M. (2019). Electricity Theft Detection in Smart Grid Systems: A CNN-LSTM Based Approach. *Energies*, 12(17):3310. Doi: <https://doi.org/10.3390/en12173310>.
- Hernández, L., Baladrón, C., Aguiar, J. M., Carro, B., Sánchez-Esguevillas, A. ve Lloret, J. (2013). Short-Term Load Forecasting for Microgrids Based on Artificial Neural Networks. *Energies*, 6, 1385-1408; Doi: <https://doi.org/10.3390/en6031385>
- Hernández, L., Baladrón, C., Aguiar, J. M., Carro, B., Sánchez-Esguevillas, A., Lloret, J., Chinarro, D., Gómez, J. J. ve Cook, D. (2013). A multi-agent system architecture for smart grid management and forecasting of energy demand in virtual power plants. *IEEE Commun. Mag.* 51, 106–113. Doi: <https://doi.org/10.1109/MCOM.2013.6400446>
- Hill, T., OConnor, M. ve Remus, W. (1996). Neural networks models for time series forecasts. *Manage Sci*, 1082–92. Doi: <https://doi.org/10.1287/mnsc.42.7.1082>
- Hippert, H. S., Pedreira, C. E. ve Souza, R. C. (2001). Neural networks for short-term load forecasting: a review and evaluation. *IEEE Transactions on Power Systems*, 16(1), 44–55. Doi: <https://doi.org/10.1109/59.910780>
- Ho, K. L., Hsu, Y. Y., Chen, C. F., Lee, T. E., Liang, C. C., Lai, T. S. ve Chen, K. K. (1990). Short term load forecasting of Taiwan power system using a knowledge-based expert system. *IEEE Trans. Power Syst.* 5, 1214–1221. Doi: <https://doi.org/10.1109/59.99372>
- Ho, K. L., Hsu, Y. Y. ve Yang, C. C. (1992). Short term load forecasting using a multilayer neural network with and adaptative learning algorithm. *IEEE Trans. Power Syst.* 7, 141–149. Doi: <https://doi.org/10.1109/59.141697>
- Irisarri, G. D., Widergren, S. E. ve Yehsakul, P. D. (1982). On-line load forecasting for energy control center application. *IEEE Trans Power Appar Syst*, 101, 71–78. Doi: <https://doi.org/10.1109/TPAS.1982.317242>
- Kiartzis, S. J. ve Bakirtzis, A. G. (2000). A fuzzy expert system for peak load forecasting: application to the Greek power system. In: *Proceedings of the 10th mediterranean electrotechnical conference*, 3, 1097–1100. Doi: <https://doi.org/10.1109/MELCON.2000.879726>
- Kohonen, T. (1990). The Self-organizing Map. *Proc. IEEE*, 78, 1464–1480. Doi: [10.1109/5.58325](https://doi.org/10.1109/5.58325)
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y. ve Zhang, Y. (2019). Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network, in *IEEE Transactions on Smart Grid*, Vol. 10, No. 1, 841-851. Doi: [10.1109/TSG.2017.2753802](https://doi.org/10.1109/TSG.2017.2753802)
- Le, T., Vo, M. T., Vo, B., Hwang, E., Rho, S. ve Baik, S. W. (2019). Improving Electric Energy Consumption Prediction Using CNN and Bi-LSTM. *Applied Sciences*, 9(20):4237. Doi: doi.org/10.3390/app9204237
- Lee, K.Y., Cha, Y. T. ve Park, J. H. (1992). Short-term load forecasting using an artificial neural network. *IEEE Trans. Power Syst.* 7, 124–132. Doi: <https://doi.org/10.1109/59.141695>
- Lu, C. N., Wu, H. T. ve Vemuri, S. (1993). Neural network based short term load forecasting. *IEEE Trans. Power Syst.* 8, 336–342. Doi: <https://doi.org/10.1109/59.221223>
- McMenamin, J. S. ve Monforte, F. A. (1998). Short-term energy forecasting with neural networks. *Energy J.* 19, 43–61. Doi: <https://doi.org/10.5547/ISSN0195-6574-EJ-Vol19-No4-2>
- Miranda, V. ve Monteiro, C. (2000). Fuzzy inference in spatial load forecasting. In: *Proceedings of IEEE power engineering winter meeting*, vol. 2; pp. 1063–8. Doi: <https://doi.org/10.1109/PESW.2000.850087>
- Muzaffar, S. ve Afshari, A. (2019). Short-Term Load Forecasts Using LSTM Networks. *Energy Procedia*, 158, 2922-2927. Doi: <https://doi.org/10.1016/j.egypro.2019.01.952>

- Nounou, M. N. ve Bakshi, B. R. (2000). Multiscale Methods for Denoising and Compression. *Data Handling in Science and Technology*, 22(5), 119-150. Doi: [https://doi.org/10.1016/S0922-3487\(00\)80030-1](https://doi.org/10.1016/S0922-3487(00)80030-1)
- Rodrigues, F., Cardeira, C. ve Calado, J. M. F. (2014). The daily and hourly energy consumption and load forecasting using artificial neural network method: a case study using a set of 93 households in Portugal. *Energy Procedia*, 62, 220 - 229. Doi: <https://doi.org/10.1016/j.egypro.2014.12.383>
- Ryu, S., Noh, J. ve Kim, H. (2017). Deep Neural Network Based Demand Side Short Term Load Forecasting. *Energies*, 10, 3; doi: <https://doi.org/10.3390/en10010003>
- Srinivasan, D., Chang, D. S. ve Liew, A. C. (1995). Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting. *IEEE Trans Power Syst.* 10(4), 1897-903. Doi: <https://doi.org/10.1109/59.476055>
- Srinivasan, D., Liew, A. C. ve Chang, C. S. (1994). Forecasting daily load curves using a hybrid fuzzy-neural approach. *IEE Proc. Gener. Transm. Distrib.* 141, 561-567. Doi: <https://doi.org/10.1049/ip-gtd:19941288>
- Papalexopoulos, A. D., Hao, S. ve Peng, T. M. (1994). An implementation of a neural network based load forecasting models for the EMS. *IEEE Trans. Power Syst*, 9, 1956-1962. Doi: <https://doi.org/10.1109/59.331456>
- Papalexopoulos, A. D. ve Hesterberg, T. C. (1989). A regression based approach to short term system load forecasting. In: *Proceedings of PICA conference*, 3, 414-23. Doi: <https://doi.org/10.1109/PICA.1989.39025>
- Pankratz, A. (1983). Forecasting with Univariate Box-Jenkins Models: Concepts and Cases. Wiley, New York.
- Park, D. C., El-Sharkawi, M. A., Marks, R. J., Atlas, L. E. ve Damborg, M. J. (1991). Electric load forecasting using an artificial neural network. *IEEE Trans. Power Syst.* 6, 442-449. Doi: <https://doi.org/10.1109/59.76685>
- Rahman, S. ve Hazim, O. (1996). Load forecasting for multiple sites: development of an expert system-based technique. *Electr Power Syst Res*, 39, 161-169. Doi: [https://doi.org/10.1016/S0378-7796\(96\)01114-5](https://doi.org/10.1016/S0378-7796(96)01114-5)
- Reşat, H. G. (2020). Sürdürülebilir enerji yönetimi için yapay sinir ağları ve ARIMA metotları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: Tütün endüstrisinde vaka çalışması. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 35(3), 1129-1140. Doi: <https://doi.org/10.17341/gazimmfd.591248>
- Rumelhart, D., Hinton, G. ve Williams, R. (1996). Learning internal representations by error propagation. In *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*; Rumelhart, D., McClelland, J.L., Eds., MIT Press Cambridge: Cambridge, MA, USA, 318-362.
- Taylor, J. W. (2012). Short-Term Load Forecasting with Exponentially Weighted Methods. *IEEE Transactions on Power Systems*, 27, 458-646. Doi: <https://doi.org/10.1109/TPWRS.2011.2161780>
- Topalli, A. K., Erkmen, I. ve Topalli, I. (2006). Intelligent short-term load forecasting in Turkey. *International Journal of Electrical Power & Energy Systems*, 28(7), 437-447. Doi: <https://doi.org/10.1016/j.ijepes.2006.02.004>
- Türkan, Y. S., Yumurtacı Aydoğmuş, H. Ve Erdal, H. (2016). The prediction of the wind speed at different heights by machine learning methods. *An International Journal of Optimization and Control: Theories & Applications (IJOCTA)*, 6(2), 179-187. Doi: <https://doi.org/10.11121/ijocta.01.2016.00315>
- Ünlü, R. (2019). A Comparative Study of Machine Learning and Deep Learning for Time Series Forecasting: A Case Study of Choosing the Best Prediction Model for Turkey Electricity Production. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(2), 635-646. Doi: <https://doi.org/10.19113/sdufenbed.494396>
- Wang, Y., Gan, D., Sun, M., Zhang, N., Lu, Z. ve Kang, C. (2019). Probabilistic Individual Load Forecasting Using Pinball Loss Guided LSTM. *Applied Energy*, Vol. 235, 10-20. Doi: <https://doi.org/10.1016/j.apenergy.2018.10.078>